

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE ENGENHARIA ELÉTRICA
CURSO DE ENGENHARIA ELÉTRICA

JONATHAN JOSÉ EVANGELISTA

**ANÁLISE DE FALHAS DE ROTOR UTILIZANDO DEEP NEURAL
NETWORKS**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO
2019

JONATHAN JOSE EVANGELISTA

**ANÁLISE DE FALHAS DE ROTOR UTILIZANDO DEEP NEURAL
NETWORKS**

Proposta de trabalho de conclusão de curso, apresentado à disciplina TCC2, do curso de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para a obtenção do título de Bacharel.

Orientador: Prof. Dr. Wagner Fontes Godoy

CORNÉLIO PROCÓPIO
2019



Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio
Departamento Acadêmico de Elétrica
Curso de Engenharia Elétrica



FOLHA DE APROVAÇÃO

Jonathan José Evangelista

Análise de falhas em rotor utilizando Deep Neural Networks

Trabalho de conclusão de curso apresentado às 9:00hs do dia 24/06/2019 como requisito parcial para a obtenção do título de Engenheiro Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

Prof(a). Dr(a). Wagner Fontes Godoy - Presidente (Orientador)

Prof(a). Me(a). Marco Antonio Ferreira Finocchio - (Membro)

Prof(a). Esp. Carlos Alberto Paschoalino - (Membro)

A folha de aprovação assinada encontra-se na coordenação do curso

AGRADECIMENTOS

Agradeço a Deus, por sempre ter me fortalecido nos momentos difíceis e por ter me permitido chegar até o fim do curso de engenharia elétrica.

Agradeço a meu pai, que pelo curto tempo de vida me proporcionou uma ótima educação, me deu bons conselhos, ótimos ensinamentos, me fez ver e refletir o quanto a vida é importante e o quanto ela é bonita. Obrigado por tudo pai.

A minha mãe, não tenho palavras para descrever o quanto ela significa para mim e o quanto ela é importante. Sempre estive ao meu lado ao longo do curso, sempre me incentivando, sempre me aconselhando, me fazendo acreditar que era possível e, realmente, é. Quero deixar claro que sem você este sonho de graduação não se tornaria realidade.

Agradeço também aos meus avós, principalmente a minha avó martinha, um exemplo de mulher, forte e doce, que desde pequeno me proporcionou ensinamentos e que sempre cuidou de mim.

Aos meus amigos queridos pelo tempo que permanecemos na universidade e pelo tempo que ainda vamos permanecer juntos, deixo meus agradecimentos. Victor Soares, William Vieira, Larissa Pinho, kelvin Ícaro Marcela Fujihara, Rafaela Tavares, Thiago Teixeira e Marcelo Correia. Agradeço também ao meu amigo prof. Vinicius Suterio pelo tempo disponibilizado e pela sua colaboração neste trabalho.

Agradeço imensamente ao meu orientador prof. Wagner Godoy por sua orientação, pelo seu apoio e pelos conhecimentos adquiridos ao longo deste trabalho. Agradeço também ao prof. Rodrigo Palácios pela ajuda e conselhos.

RESUMO

EVANGELISTA, Jonathan J. **ANÁLISE DE FALHAS DE ROTOR UTILIZANDO DEEP NEURAL NETWORKS**. 2019. 26 f. Proposta de trabalho de conclusão de curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2019.

Mais da metade da energia total destinada ao setor industrial é consumida por motores. Uma parada na produção para correção de falhas do sistema motriz pode gerar alguns riscos e também sérios prejuízos para uma determinada empresa. A determinação precoce dessas falhas pode evitar uma manutenção não-programada e uma parada no processo de produção.

Considerando um motor de indução trifásica e avaliando seu sistema elétrico, podemos prevenir algumas falhas relacionadas ao rotor, onde esta proposta de trabalho de conclusão de curso expõe um estudo relacionado ao diagnóstico de falhas do rotor de um MIT, utilizando sinais de corrente no domínio da frequência, onde a classificação das falhas será feita a partir da Deep Neural Network

Palavras-chave: Classificação de falhas, Rotor, Motor de indução trifásico, Deep Neural Network.

ABSTRACT

EVANGELISTA, Jonathan J. **ANALYSIS OF ROTOR FAILURES USING DEEP NEURAL NETWORKS**. 2019. 26 f. Proposal of work of conclusion of course (graduation) - Electrical Engineering. Federal Technological University of Paraná. Cornélio Procópio, 2019.

More than half of the total energy destined for the industrial sector is consumed by engines. Stopping production to correct motor system failures can generate some risks and also serious losses for a given company. Early determination of these faults can prevent unscheduled maintenance and a halt in the production process.

Considering a three-phase induction motor and evaluating its electrical system, we can prevent some rotor-related faults, where this proposal of completion work exposes a study related to the diagnosis of rotor faults of an MIT, using current signals in the field of frequency, where the classification of failures will be made from Deep Neural Network.

Key words: Fault Classification, Rotor, Three-Phase Induction Motor, Deep Neural Network.

LISTA DE ABREVIATURAS

DNN	Deep Neural Network
MIT	Motor de Indução Trifásico

LISTA DE TABELAS

Tabela 1-	Parâmetros e características do MIT.....	22
Tabela 2-	Número de amostras utilizadas.....	23
Tabela 3-	Distribuição de dados para a criação da rede.....	24
Tabela 4-	Topologia DNN.....	25
Tabela 5-	Características de classificação.....	25

LISTA DE FIGURAS

Figura 1-	Motor de indução trifásico.....	13
Figura 2-	Distribuição dos tipos de falha em um MIT.....	14
Figura 3-	Partes constituintes de um motor em gaiola.....	15
Figura 4-	Rotor no motor de indução trifásico.....	16
Figura 5-	Efeitos nas correntes do estator e do rotor devido a simetria do rotor.....	16
Figura 6-	Rachadura do anel de um motor.....	17
Figura 7-	Barra do rotor danificado.....	17
Figura 8-	Neurônio artificial.....	19
Figura 9-	Representação neural network.....	21
Figura 10-	Rotor com quebra forçada nas barras.....	24
Figura 11-	Matriz de treinamento.....	26
Figura 12-	Matriz de teste.....	27
Figura 13-	Matriz de validação.....	28
Figura 14-	Matriz confusão.....	29
Figura 15-	Histograma de precisão.....	30

SUMÁRIO

1	INTRODUÇÃO.....	11
1.1	Justificativa.....	12
2	OBJETIVOS.....	12
2.1	Objetivo geral.....	12
2.2	Objetivos específicos.....	12
3	FUNDAMENTAÇÃO TEÓRICA.....	13
3.1	Motor de indução trifásico.....	14
3.2	Falhas em motores de indução trifásicos.....	14
3.2.1	Falha no rotor.....	15
3.3	Detecção de falhas	18
3.4	Classificação inteligente de falhas.....	18
3.4.1	Redes neurais artificiais.....	19
3.4.1.1	Deep neural network.....	20
4	METODOLOGIA.....	21
4.1	Banco de dados.....	22
4.1.1	Características do motor de indução trifásico.....	22
4.1.2	Inserção de falhas.....	23
4.1.3	Método de classificação.....	24
5	RESULTADOS.....	26
5.1	Resultados de classificação.....	26
6	CONSIDERAÇÕES FINAIS.....	31
7	REFERÊNCIAS.....	32

1 INTRODUÇÃO

De toda energia elétrica produzida no país, o setor industrial brasileiro consome 33,9%, em que aproximadamente 68% da energia consumida nesse referido setor é utilizada em sistemas motrizes (EPE, 2014). Isso faz com que o mercado industrial invista cada vez mais em melhorias e novos recursos na área de motores, evitando falhas que podem ocasionar paradas não-programadas na linha de produção.

Os motores de indução trifásico são vastamente empregados em grande parte das indústrias devido a sua construção simples, robustez e grande confiabilidade e a possibilidade do emprego de inversores de frequência em seu acionamento (BELLINI, 2008) o que o torna, dentre os demais, a melhor escolha para o uso industrial.

Apesar de possuírem características construtivas robustas, os motores elétricos de indução são expostos a uma variedade de condições ambientais, operando sob diversos tipos de cargas, tais fatores juntamente com o envelhecimento natural contribuem para que os motores possam vir a desenvolver falhas (SUETAKE, 2012).

Segundo Bonnet and Yung (2008), as porcentagens de falhas em MIT podem ser distribuídas em:

- Rolamentos (69%);
- Enrolamento do estator (21%);
- Barra do rotor (7%);
- Eixo (3%).

Dentre estas, a proposta deste estudo irá focar nas falhas da barra do rotor, onde segundo Vas (1993), essas falhas podem ser identificadas nas componentes de sua estrutura principal (corpo do rotor). Dentre essas falhas identificadas, a quebra na barra do rotor e as rachaduras nos anéis compartilham de 5% a 10% das falhas em máquinas de indução (Bellini, 2008).

A classificação das falhas do rotor, de um motor de indução trifásico, será através da Deep Neural Network a partir da obtenção dos sinais de corrente pré-processadas.

1.1 Justificativa

Como o setor motriz obtém a maior parte da energia consumida do mercado industrial, falhas referentes a motores surge grande impacto dentro de um processo fabril. Essas falhas podem desestabilizar a linha de produção e garantir vários prejuízos financeiros.

O controle e acompanhamento dos motores de indução podem prevenir e identificar falhas futuras que possam acontecer, evitando assim algumas paradas indesejáveis no processo de produção, aumentando assim o rendimento e a eficiência da indústria.

2 OBJETIVOS

Os objetivos gerais e específicos são mostrados nas seções abaixo, especificando o que se espera alcançar através dessa proposta de conclusão de curso.

2.1 Objetivo geral

O objetivo geral deste trabalho é realizar a classificação inteligente de falhas de rotor em motores elétricos de indução trifásicos, utilizando dos sinais de corrente no domínio do tempo e a classificação pela DNN.

2.2 Objetivos específicos

Para os objetivos específicos:

- Analisar sinais de corrente de motores elétricos de indução trifásicos;
- Diagnosticar falhas de rotor a partir dos sinais de corrente discretizadas empregando a DNN.
- Analisar os dados gerados com o estudo das falhas do rotor obtidos através da DNN.

3 FUNDAMENTAÇÃO TEÓRICA

No processo de identificação e classificação das falhas do rotor de um motor de indução trifásica, é necessário primeiramente obter um pré-processamento dos sinais de corrente. Logo após esse pré-processamento será aplicado o processo inteligente com a ajuda da Deep Neural Networks que irá analisar e classificar as falhas provenientes do rotor.


3.1 Motor de indução trifásico

Motores de Indução Trifásicos (MIT) são amplamente utilizados em grande parte das aplicações industriais devido à sua construção simples, robustez, elevada confiabilidade e devido ao emprego de inversores de frequência, em que diferentes estratégias de controle eficiente pode ser aplicadas nestas máquinas (BELLINI, 2008).

O motor de indução trifásico é constituído por vários componentes, dentre os principais:

- Rolamentos;
- Estator;
- Barra do rotor;
- Eixo.

Figura 1 – Motor de Indução Trifásico



Fonte: Adaptado Fitzgerald; Kingsley; Umans (2003)

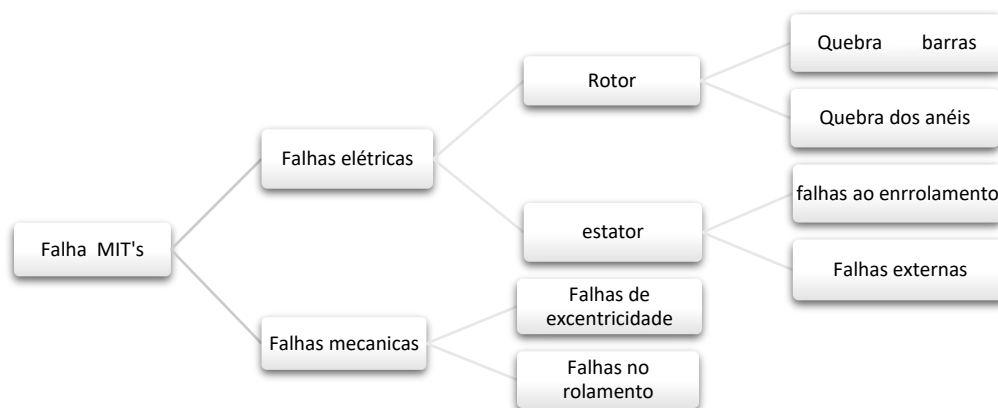
O rotor de um motor de indução, pode ser bobinado ou gaiola de esquilo, sendo o último o mais utilizado devido a sua simplicidade e robustez de construção (FITZGERALD; KINGSLEY; UMANS, 2003).

3.2 Falhas em motores de indução trifásicos

Os motores de indução trifásicos, podem vir a apresentar diversas falhas, já que, além do envelhecimento natural, estes são constantemente expostos a uma variedade de condições ambientais, operando sob diversos tipos de cargas (SUETAKE, 2012).

As principais falhas que ocorrem nos motores de indução podem ser distribuídas em falhas elétricas e falhas mecânicas.

Figura 2 – Distribuição dos tipos de falha em um MIT.



Fonte: Adaptado de Godoy(2016).

De acordo com Bonnett e Yung (2008), as porcentagens de falhas em MIT podem ser distribuídas em:

- Rolamentos (69%);
- Enrolamento do estator (21%);
- Barra do rotor (7%);
- Eixo (3%).

Estes 7% de falhas presentes no rotor são caracterizados entre a quebra da barra do rotor e as rachaduras nos anéis finais.

3.2.1 Falha no rotor

Embora uma falha no rotor não provoque em alguns casos problemas imediatos, verifica-se que este tipo de falha pode levar a efeitos adicionais, como a ocorrência de vibrações na máquina, elevação da temperatura e o comprometimento do seu isolamento (CARDOSO, 1991).

O Rotor, que se caracteriza como a parte móvel de um MIT, pode, segundo Bonnett e Yung (2008) ser responsável por 7% das falhas totais de um motor de indução trifásico.

Dentre as falhas classificadas, a quebra na barra do rotor e as rachaduras nos anéis finais compartilham de 5% a 10% das falhas em máquinas de indução (Belline et al., 2008).

Conforme ilustrado na Figura 3, um rotor é composto por barra do rotor e anéis.


Figura 3 – Partes constituintes de um rotor em gaiola.



Fonte: Adaptado de WEG (2013).

A Figura 4, representa o local onde o rotor se encontram no motor de indução.

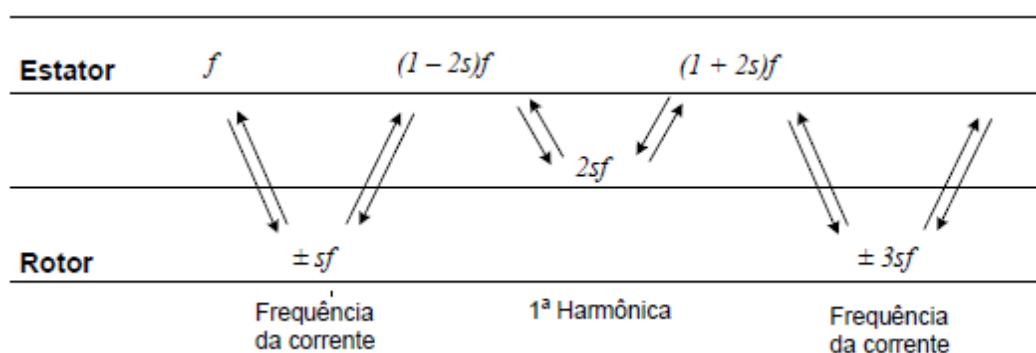
Figura 4 – Rotor no motor de indução trifásico



Fonte: Adaptado de WEG (2013).

Um motor de indução operando com uma falha no rotor gera uma sequência negativa de corrente devido a assimetria do rotor. Isto induz uma componente principal na corrente do estator, a qual varia na frequência de $(1-2s)f$. Além disso, as frequências de assinatura do rotor são $\pm sf, \pm 3sf, \dots$; como esboçado na figura 5. (BELLINI, 2008).

Figura 5 – Efeitos nas correntes do estator e do rotor, devido a simetria do rotor.



Fonte: Bellini (2008).

A dificuldade em se detectar falhas nos rotores está justamente na classificação das linhas de frequência presentes nos sinais. Onde os sistemas inteligentes tem sido muito utilizados para mapear estes processos (BELLINI, 2008).

As falhas no rotor se classificam em quebra de barra do rotor e rachadura nos anéis.

Figura 6 – Rachadura do anel de um rotor



Fonte: Autor desconhecido

Na Figura 6, tem-se uma falha de rotor de uma bomba d'água referente ao alto aquecimento da peça. Já na Figura 7, tem-se barra danificada de um rotor.

Figura 7 – Barra do rotor danificada.



Fonte: NSK do Brasil (2012)

As redes neurais combinados com os diferentes métodos compõem diversas estruturas para um sistema de diagnóstico, principalmente naqueles métodos responsáveis pela extração de característica do sinal. Estas

determinadas falhas de quebra da barra do rotor e a rachadura nos anéis podem ser analisadas pela forma do sinal de corrente utilizando redes neurais conforme constatado em Arabaci and Bilgin (2009).

3.3 Detecção de falhas

Segundo Seshadrinath, Singh e Panigrahi (2014) e Seera (2014), mostram que o diagnóstico de falhas em MIT com inversor de frequência tem atraído a atenção de vários pesquisadores nos últimos anos.

Reis (2010), afirma que os métodos não invasivos são os mais promissores, pois para coletar informações não é necessário interromper o funcionamento do motor, caracterizando-os como práticos e de baixo custo. Assim, neste trabalho, será utilizado sinais de corrente como forma de diagnosticar falhas.

Os sistemas inteligentes, tem sido utilizados na identificação e resolução de diversos problemas relacionados ao controle e acionamento de máquinas elétricas sendo capaz de classificar e determinar a origem de falhas ainda em sua fase prematura.

A principal etapa no processo de detecção de falhas constitui na análise de sinais e na extração de características relevantes, o que pode ser realizado através de uma transformação ou decomposição do correspondente sinal (OLIVEIRA H. M., 2007). Desta forma, a análise no domínio da frequência através da transformada de Fourier é um dos métodos mais utilizados (VITOR, 2016).

3.4 Classificação inteligente de falhas

Este trabalho considera o emprego da Deep Neural Network que será descrita detalhadamente nas próximas seções.


3.4.1 Redes neurais artificiais

Segundo Simon (2001), uma rede neural é um processador maciçamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torna-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem
- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.

A Figura 8 apresenta o modelo de um neurônio artificial, que forma a base para o projeto de redes neurais artificiais

Figura 8 – Neurônio artificial



Fonte: Simon (2001)

Assim, de acordo com a Figura 8 é possível observar que o neurônio artificial é constituído por sete elementos básicos:

- Sinais de entrada $\{x_1, x_2, \dots, x_m\}$;
- Pesos sinápticos $\{w_{k1}, w_{k2}, \dots, w_{km}\}$;
- Combinador linear $\{\Sigma\}$;
- Limiar de ativação $\{b_k\}$;
- Potencial de ativação $\{v_k\}$;

- Função de ativação $\{\varphi\}$;
- Sinal de saída $\{y_k\}$.

Os sinais advindos de estruturas externas são representados como entradas $\{x_1, x_2, \dots, x_n\}$, em seguida, estas são ponderadas através dos pesos sinápticos $\{w_{k1}, w_{k2}, \dots, w_{kn}\}$, os resultados obtidos são posteriormente agregados. O limiar de ativação $\{b_k\}$ determina o patamar para que seja gerado um valor de disparo em direção à saída do neurônio, o potencial de ativação $\{v_k\}$ é dado pela diferença entre o resultado do combinador linear e o limiar de ativação, assim, se $v_k \geq b_k$, o neurônio produz potencial excitatório e se $v_k < b_k$ produz potencial inibitório, a função de ativação $\{\varphi\}$ tem como objetivo limitar a saída do neurônio (SILVA; SPATTI; FLAUZINO, 2010).


As redes neurais artificiais são caracterizadas por serem capazes de lidar com problemas que possuem grandes volumes de variáveis e conjunto de dados e também, possuem a habilidade de mapear sistemas não-lineares e variantes no tempo (SUETAKE, 2012). Para classificar esses dados, usaremos a Deep Neural Network.

3.4.1.1 Deep Neural Network

Para Silva, Spatti e Flauzino (2010), as redes neurais artificiais contêm três camadas, sendo:

- Camada de entrada: Recebem os dados inseridos na rede;
- Camadas intermediárias: Analisa os dados inseridos na rede;
- Camadas de saída: Apresenta os dados processados pela rede.

Figura 9 – Representação Neural Network



Fonte: Adaptado software MatLab R2018a.

Através do treinamento da Rede Neural, obtém-se uma saída para cada amostra de dados inserido. Para este treinamento é utilizado o algoritmo de aprendizagem *backpropagation* que possui uma rede denominada *feed-forward* de duas camadas, que pode classificar vetores arbitrariamente, onde os dados de entradas são analisados e processados passando por todas as camadas gerando uma saída que novamente retorna a entrada para um novo treinamento.

Este processo de treinamento é repetido até que a resposta de saída esteja de acordo com a desejada.

4 METODOLOGIA

Para analisar as falhas de rotor de uma MIT, foi utilizado um banco de dados obtidos em laboratório, simulando vários tipos de falhas que podem vir a ocorrer em rotores, se aproximando ao máximo de um ambiente real.

A análise para detecção de falhas se dá através dos sinais de corrente obtidos nas simulações para 5 tipos de situações, como o motor operando sem falhas, motor operando com uma barra danificada, duas barras danificadas, motor operando com duas barras quebradas opostas (quatro barras) e motor operando com quatro barras quebradas consecutivas.

Como os dados de corrente analisados já foram processados, não haverá a necessidade de um pré-processamento através da transformada de Fourier ou Wavelet.

4.1 Banco de dados

Para este trabalho foi utilizado o mesmo banco de dados utilizado em Broniera(2014), Lopes(2016), Bazan(2016), Godoy(2016) e Palácios(2016). A Seguir é apresentado as características do MIT e a forma com que as falhas foram inseridas.

4.1.1 Características do motor de indução trifásico

As características e os parâmetros do motor utilizado podem ser vistos na Tabela 1.

Tabela 1: Parâmetros e características do MIT

Parâmetro	Motor
Fabricante	WEG
Potência (KW)	0,74
Frequência (Hz)	60
Tensão de alimentação (V)	220/380
Corrente (A)	3,02/1,75
Velocidade (rpm)	1730
Número de polos	4
Número de ranhuras	36
Torque nominal (N.m)	4,1

Para a Tabela 2, apresenta as características das falhas e a quantidade de amostras adotadas do banco de dados utilizado para análise.

Tabela 2: Número de amostras utilizadas

Característica	Quantidade
Saudável	956
Falha em um barramento	1145
Falha em dois barramentos	1194
Falha em dois barramentos opostos	1657
Falha em quatro barramentos consecutivos	109
Número total de amostras	5061

4.1.2 Inserção de falhas do rotor

Neste trabalho, as correntes foram adquiridas de um motor de indução trifásico com especificações apresentadas na Tabela 1. Foram utilizados cinco rotores diferentes para cada tipo de falha.

Para a inserção das falhas no rotor, foi utilizado um procedimento apresentado por Suetake (2012), que seria um cisalhamento das barras que compõem a gaiola do rotor. A quebra é realizada com a perfuração por uma furadeira de bancada utilizando uma broca com diâmetro suficientemente maior que a barra, tendo como resultado um conjunto de rotores para os ensaios em bancada (Godoy, 2016), que pode ser observada na Figura 10.

Figura 10: Rotor com quebra forçada das barras.



Fonte: Godoy (2016)

Este tipo de falha normalmente é atribuído ao excesso de vibração, desalinhamento ou excentricidade (SUETAKE, 2012). A carga excessiva no eixo também é capaz de provocar a ruptura ou trinca. Em adicional, fatores como altas temperaturas que podem ser consequência dos outros problemas, ou mesmo fadiga do motor, também podem provocar este tipo de defeito (BACCARINI, 2005).

As principais consequências refletem no aumento da oscilação do conjugado, vibração excessiva, ruído, centelhamento, além de baixa dinâmica de partida (SUETAKE, 2012; BACCARINI, 2005).

Levando em consideração as falhas que são encontradas nos rotores, as redes neurais têm sido cada vez mais utilizada como ferramenta para detecção destas falhas para minimizar os problemas que estas falhas apresentam.

4.1.3 Método de classificação

Para esta etapa, juntamos todos os conjuntos de dados que representam o domínio de operação do motor em uma matriz e apresentamos para a rede. O conjunto de dados foi dividido em três blocos, sendo o treinamento, teste e validação apresentadas na Tabela 3.

Tabela 3: Distribuição de dados para criação da rede

Etapa	Percentual
Treinamento	70%
Teste	15%
Validação	15%

A Tabela 4, apresenta a quantidade de neurônios e a quantidade de camadas da rede, onde foi-se ajustando esta quantidade de acordo com a resposta de saída que a rede proporcionava.

Tabela 4: Topologia da DNN

Quantidade de neurônios de entrada	30
Quantidade de neurônios na camada oculta	25
Quantidade de neurônios na camada de saída	5
Número de camadas escondidas	1
Iterações	116

A Tabela 5 representa a lógica escolhida para definir os sinais do motor saudável, com falha em um barramento, falha em dois barramentos, falha em dois barramentos opostos e falha em 4 barramentos consecutivos.

Tabela 5: Características de Classificação

Características	Saída
Saudável	00001
Falha em um barramento	00010
Falha em dois barramentos	00100
Falha em dois barramentos opostos	01000
Falha em quatro barramentos consecutivos	10000

5 RESULTADOS EXPERIMENTAIS

Os resultados obtidos com os dados implementados na Neural Network serão apresentados nesta seção, onde os dados inseridos são os sinais de corrente adquiridos na simulação de inserção de falhas de um MIT.

5.1 Resultados de classificação

Como apresentado na Tabela 3, as etapas de classificação foram divididas em 3, treinamento, teste e validação. Depois de inseridos os dados na DNN, a rede foi treinada, ou seja, passou por um processo de aprendizagem das conexões entre os neurônios que segue um processo supervisionado, no qual consiste em entradas e saídas desejadas.

Os dados obtidos na Figura 11, representa a quantidade de amostras utilizadas em cada característica, onde foram empregadas 70% do total de amostras para o treinamento.

Figura 11: Matriz de treinamento

Output Class	1	2	3	4	5	
1	495 14.0%	36 1.0%	23 0.6%	52 1.5%	0 0.0%	81.7% 18.3%
2	28 0.8%	501 14.1%	79 2.2%	53 1.5%	5 0.1%	75.2% 24.8%
3	9 0.3%	84 2.4%	541 15.3%	126 3.6%	0 0.0%	71.2% 28.8%
4	150 4.2%	164 4.6%	201 5.7%	922 26.0%	72 2.0%	61.1% 38.9%
5	2 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	72.4% 27.6%	63.8% 36.2%	64.1% 35.9%	80.0% 20.0%	0.0% 100%	69.4% 30.6%
	1	2	3	4	5	
	Target Class					

Fonte: Autoria própria

Pode-se observar que para o treinamento de classificação o motor saudável apresentou uma precisão de 81,7%, para falha com um barramento a precisão é de 75,2%, com dois barramentos 71,2%, falha com dois barramentos opostos 61,1% e falha com 4 barramentos 0% de precisão.

Para a etapa de teste, mostrada na Figura 12, a quantidade de amostras utilizadas foi de 15% do total de amostras.

Figura 12: Matriz de teste

Output Class	1	2	3	4	5	
1	94 12.4%	6 0.8%	5 0.7%	19 2.5%	0 0.0%	75.8% 24.2%
2	1 0.1%	100 13.2%	25 3.3%	12 1.6%	1 0.1%	71.9% 28.1%
3	0 0.0%	29 3.8%	120 15.8%	26 3.4%	0 0.0%	68.6% 31.4%
4	33 4.3%	41 5.4%	40 5.3%	186 24.5%	20 2.6%	58.1% 41.9%
5	0 0.0%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	0.0% 100%
	73.4% 26.6%	56.8% 43.2%	63.2% 36.8%	76.2% 23.8%	0.0% 100%	65.9% 34.1%
	1	2	3	4	5	
	Target Class					

Fonte: Autoria própria

Para o motor saudável, a precisão foi de 75,8%, na falha com um barramento a precisão foi de 71,9%, falha com dois barramentos 68,6%, falha com dois barramentos opostos a precisão é de 58,1 e para 4 barramentos consecutivos a precisão é de 0%.

Na etapa de validação, que nada mais é que uma comprovação, que torna a rede válida, utiliza 15% do total das amostras. A Figura 13 apresenta a quantidade de amostras para cada característica.

Figura 13: Matriz de validação

Validation Confusion Matrix

Output Class	1	110 14.5%	12 1.6%	1 0.1%	20 2.6%	0 0.0%	76.9% 23.1%
	2	6 0.8%	122 16.1%	22 2.9%	7 0.9%	0 0.0%	77.7% 22.3%
	3	2 0.3%	17 2.2%	104 13.7%	39 5.1%	0 0.0%	64.2% 35.8%
	4	26 3.4%	33 4.3%	33 4.3%	194 25.6%	11 1.4%	65.3% 34.7%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
			76.4% 23.6%	66.3% 33.7%	65.0% 35.0%	74.6% 25.4%	0.0% 100%
		1	2	3	4	5	
		Target Class					

Fonte: Autoria própria

Para o motor saudável a etapa de validação a precisão foi de 76,9%, para o motor com uma falha de barramento a precisão foi de 77,7%, com dois barramentos 64,2%, falha com dois barramentos opostos 65,3% e com 4 barramentos consecutivos a precisão não foi calculada.

Na determinação do nível de confiança da classificação, utilizamos a matriz confusão que mostra de forma global a exatidão da rede. A matriz confusão é a junção de todas as etapas do processo de classificação, o treinamento, teste e validação, mostrada na Figura 14.

Figura 14: Matriz confusão

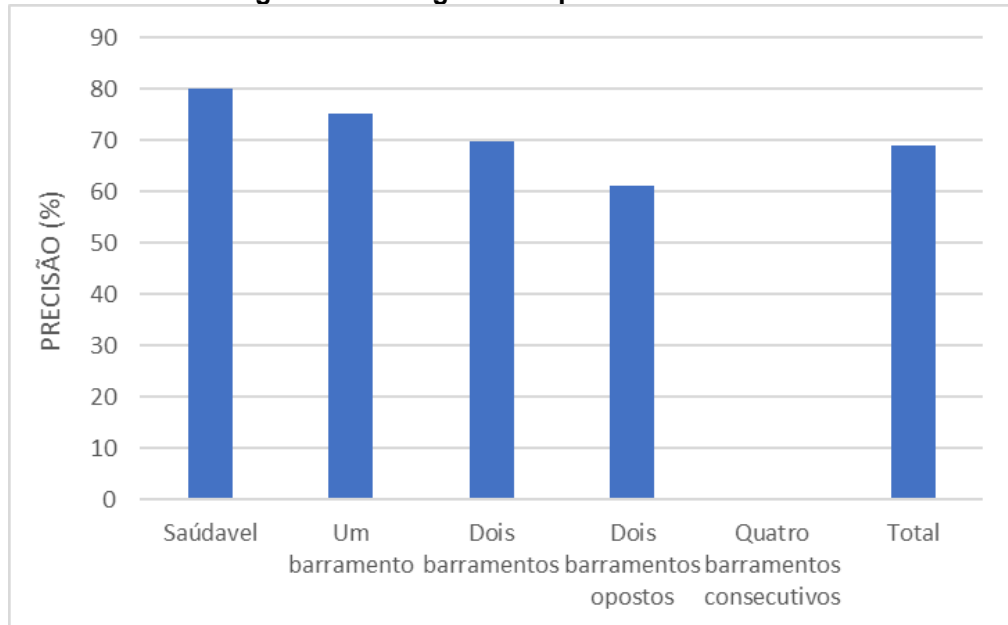
All Confusion Matrix

Output Class	1	699 13.8%	54 1.1%	29 0.6%	91 1.8%	0 0.0%	80.1% 19.9%
	2	35 0.7%	723 14.3%	126 2.5%	72 1.4%	6 0.1%	75.2% 24.8%
	3	11 0.2%	130 2.6%	765 15.1%	191 3.8%	0 0.0%	69.7% 30.3%
	4	209 4.1%	238 4.7%	274 5.4%	1302 25.7%	103 2.0%	61.2% 38.8%
	5	2 0.0%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	0.0% 100%
			73.1% 26.9%	63.1% 36.9%	64.1% 35.9%	78.6% 21.4%	0.0% 100%
		1	2	3	4	5	
		Target Class					

Fonte: Autoria própria

Analisando a matriz confusão, que contém o conjunto de mostra total, percebemos que o motor saudável apresentou uma exatidão de 80,1%, motor com falha em um barramento 75,2%, com falha em dois barramentos uma exatidão de 69,7%, motor com falha em dois barramentos opostos 61,2% e com quatro barramentos consecutivos uma exatidão de 0%.

A Figura 15 apresenta o histograma de precisão das características de falhas do rotor e a precisão total da DNN para o conjunto de dados utilizado.

Figura 15: Histograma de precisão

Fonte: Autoria própria

6 CONSIDERAÇÕES FINAIS

Neste trabalho, foi utilizada a Deep Neural Network, que serviu como um método para a determinação de falhas de rotor por meio de um conjunto de dados de sinais de corrente coletados experimentalmente em laboratório através de simulações de um motor de indução trifásico.

Estas simulações foram feitas para quatro tipos de falhas em rotor, falha em um barramento, falha em dois barramentos, em dois barramentos opostos e quatro barramentos consecutivos, contando também com a simulação de motor saudável (sem presença de falhas). Os dados manipulados já haviam sido devidamente tratados e classificados.

Após a entrada de dados na rede, foi feito o treinamento desses dados utilizando 70% do total para esta etapa. Para o teste 15% e 15% para a validação. A precisão para o treinamento foi de 69,4%, para o teste encontrou-se uma precisão de 65,9% e na validação 69,8%.

A Matrix confusão, que representa 100% dos dados, apresentou uma precisão de 68,9%. Levando em consideração a porcentagem de precisão para cada tipo de característica de falha desta matriz, observou-se que a precisão de falha em quatro barramentos consecutivos foi de 0%, teste valor baixo se dá pela baixa quantidade de dados coletados para este tipo de falha, o que se diverge das outras características de falha, que contém uma quantidade maior de dados. Esta disparidade influência no resultado da rede, podendo assim diminuir sua precisão.

Portanto, com os resultados obtidos neste trabalho, podemos concluir a viabilidade do método de classificação de falhas em rotor em motores de indução trifásicos.

7 REFERENCIAS

ARAÚJO, R. d. S. **Desgaste Prematuro e Falhas Recorrentes em Rolamentos de Motores de Indução Alimentados por Inversores: Análise e Proposta de Solução.** Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2011.

BACCARINI, L. M. R. **Detecção e diagnostico de falhas em Motores de Indução.** Tese(Doutorado)- Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2005.

BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G.-A. Advances in diagnostic techniques for induction machines. **IEEE Transaction on Industrial Eletronics**, 2008. V. 55, n.12, p.4109-4126, 2008.

BONNETT, A.; YUNG, C. **Increased efficiency versus increased reliability.** IEEE IndustryApplications Magazine, v. 14, n. 1, p. 29–36, jan./feb. 2008.

CARDOSO, A.J.M. **Diagnóstico de avarias em motores de indução trifásicos.** Coimbra editora, 1991.

CARPENTER, G.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS.; ROSEN, D. Fuzzy artmap: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, 1992. v.3, n.5, p. 698-713, Sep 1992.

DRIF, M. H.; CARDOSO, A. J. M. Rotor Cage Fault Diagnostic in Three-Phase Induction Motors by the Instantaneous Phase-Angle Signature Analysis. In: IEE INTERNATIONAL ELETRIC MACHINES & DRIVE CONFERENCE (IEMDC), 2007. **Proceedings...** [S.l.:s.n], 2007. p.1440-1445.

EPE, .Balanço energético nacional 2014 – ano base 2013 – relatório final. **Empresa de Pesquisa Energética – Ministério de Minas e Energia**, 2014. P 288, 2014.

FAIZ, J.; GHORBANIAN, V.; EBRAHIMI, B. Locating broken bars in line-start and inverter-fed induction motors using modified winding function method. **Electromagnetics**, 2012. v. 32, n. 3, p. 173-192, 2012.

FITZGERALD, A.; KINGSLEY, C.; UMANS, S. **Electric machinery**. Boston, MA: McGraw-Hill Companies, Incorporated, 2003. (Electrical Engineering Series).

GODOY, W. F.; SILVA, I. N.; GOEDEL, A.; PALÁCIOS, H. C.; GRACIOLA, C. L.; BRONIERA, P. **Rede Fuzzy ARTMAP para a classificação de falhas em estator em motores de indução trifásicos**. XX Congresso Brasileiro de Automática, Belo Horizonte, 2014.

GODOY, W. F. **Multiclassificador Inteligente de falhas no domínio do tempo em motores de indução trifásicos alimentados por inversores de frequência**. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo – Escola de Engenharia de São Carlos, 2016.

GONGORA, W. S. **Uma abordagem neural no diagnóstico de falhas em rolamento em motores de indução trifásicos** . Tese (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, Mestrado em Engenharia Elétrica, Cornélio Procópio, 2013.

OLIVEIRA, H. M. **Análise de Fourier e Wavelets: Sinais Estacionários e não Estacionários**. Recife: Editora Universitária, UFPE, 2007. 342 p.

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. **Discrete-Time Signal Processing**. 2nd.ed. Upper Saddle River, New Jersey: Prentice Hall, 1998.

REIS, A. J. S. **Reconhecimento de Padrões de Falhas em Motores Trifásicos Utilizando Redes Neurais**. UFRN, Natal, 2010.

SANTOS, F. M. d. C.; SILVA, I. N. d.; SUETAKE, M. Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução – uma visão geral. **Sba: Controle & Automação Sociedade Brasileira de Automática**. 2012. Scielo, v.13, p.553 -569, 10 2012. ISSN 0103-1759.

SESHADRINATH, J.; SINGB, B.; PANIGRAHI, B. Investigation of vibration signatures for multiple fault diagnosis in variable frequency drives using complex wavelets. *IEEE Transactions on Power Electronics*, 2014.v.29,n.2, p. 936-945, Feb 2014.

SILVA, J. G. B. **Aplicação da análise de componentes principais (PCA) no diagnóstico de defeitos em rolamentos através da assinatura elétrica de motores de indução**. Tese (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Itajubá, 2008.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. São Paulo: ArtLiber, 2010. 399 p.

SUETAKE, M. **Sistemas Inteligentes para o Diagnóstico de Falhas em Motores de Indução Trifásicos**. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo – Escola de Engenharia de São Carlos, 2012.

SAUER, I. L.; TATIZAWA, H.; SALOTTI, F. A. M.; MERCEDES, S. S. A comparative assessment of brazilian electric motors performance with minimum efficiency standards. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 41, p. 308 – 318, 2015.

VITOR, A. L. de O.. **Detecção de falhas de estator em motores de indução trifásicos utilizando transformada Wavelet, medida RMS e potência de previsão**. Tese (Mestrado) – Pós-graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

WEG. **Motor de Indução Trifásico: Rotor Bobinado com Sistema Motorizado de Levantamento das Escovas**. 2013. Disponível em: Acesso em: 18 de outubro de 2017.