

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

MARIANI OLIVEIRA DE SOUZA

**CLASSIFICAÇÃO INTELIGENTE DE FALHAS DE ROLAMENTO EM MOTORES
ELÉTRICOS DE INDUÇÃO TRIFÁSICOS UTILIZANDO A TRANSFORMADA
RÁPIDA DE FOURIER E A ANÁLISE DE COMPONENTES PRINCIPAIS**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO
2018

MARIANI OLIVEIRA DE SOUZA

**CLASSIFICAÇÃO INTELIGENTE DE FALHAS DE ROLAMENTO EM MOTORES
ELÉTRICOS DE INDUÇÃO TRIFÁSICOS UTILIZANDO A TRANSFORMADA
RÁPIDA DE FOURIER E A ANÁLISE DE COMPONENTES PRINCIPAIS**

Trabalho de Conclusão de Curso de graduação, apresentado à disciplina TCC 2, 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
2018



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



FOLHA DE APROVAÇÃO

Mariani Oliveira de Souza

Classificação inteligente de falhas de rolamento em motores de indução trifásicos utilizando transformada rápida de Fourier e análise de componentes principais

Trabalho de conclusão de curso apresentado às 15:00hs do dia 12/06/2018 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). Dr(a). Marcelo Favoretto Castoldi - (Membro)

Prof(a). Dr(a). Rodrigo Henrique Cunha Palacios (Membro)

AGRADECIMENTOS

Agradeço a Deus pela minha vida, por todas as bênçãos e por sempre me fortalecer em meio as tempestades.

Agradeço aos meus pais por todo apoio, dedicação, inspiração e carinho para que eu conseguisse chegar até aqui, por sempre acreditarem em mim e não me deixarem desanimar.

Agradeço ao Rodrigo por fazer parte da minha trajetória até aqui, estando ao meu lado em todos os momentos.

Agradeço ao meu amigo e companheiro de pesquisas Mateus pelo imenso auxílio, por estar sempre presente me ajudando em todos os momentos.

Aos amigos que a faculdade me trouxe, em especial ao meu grande amigo Luiz, que deixou este mundo tão cedo, mas que trouxe grande aprendizado, alegria e companheirismo durante a faculdade.

Ao meu orientador, prof. Wagner Godoy, pela sua orientação, apoio e todo conhecimento repassado.

A todos os professores da UTFPR que passaram pela minha vida e contribuíram grandemente para minha formação profissional.

Tudo posso naquele que me fortalece
(Filipenses 4.13)

RESUMO

SOUZA, Mariani de O. **Classificação inteligente de falhas de rolamento em motores de indução trifásicos acionados por inversores de frequência, utilizando transformada rápida de Fourier e análise de componentes principais**. 2018. 45 f. Trabalho de Conclusão de Curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2018.

Motores de indução trifásicos desempenham um papel importante na indústria, o correto diagnóstico e classificação de falhas nestas máquinas é essencial, pois assim tem-se diminuição das paradas não programadas para manutenção corretiva e conseqüentemente um aumento na produtividade. Assim, este trabalho apresenta um estudo relacionado ao diagnóstico de falhas de rolamento em motores de indução trifásicos acionados por inversores de frequência. O diagnóstico consiste em detectar falha e sua severidade. Para a aplicação do método foi realizado primeiramente, um pré-processamento dos sinais de corrente utilizando a Transformada Rápida de Fourier e realizando a Análise de Componentes Principais. Para avaliar a precisão de classificação frente aos diversos níveis de severidade das falhas, foram comparados a precisão de classificação de duas redes: (i) Rede *Perceptron* Multicamadas e (ii) rede *Fuzzy* ARTmap.

Palavras-chave: Análise de componentes principais, Falhas de rolamento, *Fuzzy* ARTmap, Motores de indução trifásicos, *Perceptron* Multicamadas, Transformada Rápida de Fourier.

ABSTRACT

SOUZA, Mariani de O. **Intelligent classification of bearing faults in three-phase induction motors driven by frequency inverters using fast Fourier transform and principal component analysis**. 2018. 45 f. Trabalho de Conclusão de Curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2018.

Three-phase induction motors play an important role in the industry, so the correct diagnosis and classification of faults in these machines is essential, as this reduces unscheduled downtimes for corrective maintenance and consequently increases productivity. Thus, this work presents a study related to the diagnosis of bearing faults in three - phase induction motors driven by frequency inverters. For the application of the method, a pre-processing of the current signals used in the Fast Fourier Transform was performed and the Principal Component Analysis was performed. In order to evaluate the classification accuracy in relation to the different levels of fault severity, the classification accuracy of two networks were compared: (i) Multi-layered Perceptron Network and (ii) Fuzzy ARTmap network.

Keywords: Bearing faults, Fast Fourier transform, *Fuzzy* ARTmap, Multilayer perceptron network, Principal component analysis, Three-phase induction motors.

LISTA DE ABREVIATURAS

FAM	<i>Fuzzy</i> ARTmap
FFT	<i>Fast Fourier Transform</i>
MIT	Motor de Indução Trifásico
PCA	Principal Component Analysis
PMC	<i>Perceptron</i> Multicamadas
RNA	Redes Neurais Artificiais
rpm	Rotações por minuto

LISTA DE TABELAS

Tabela 1 – Parâmetros e características do MIT.....	28
Tabela 2 – Parâmetros e características dos inversores.....	28
Tabela 3 – Número de aquisições.....	29
Tabela 4 – Parâmetros e especificações do rolamento.....	30
Tabela 5 – Proporção de dados para a criação das redes.....	32
Tabela 6 – Parâmetros da rede <i>Perceptron</i> Multicamadas.....	32
Tabela 7 – Parâmetros da rede <i>Fuzzy ARTmap</i>	33
Tabela 8 – Topologia da rede PMC – Classificação simples.....	33
Tabela 9 – Topologia da rede PMC - Severidade.....	34
Tabela 10 – Características da Classificação.....	35
Tabela 11 – Matriz Confusão falha ou saudável inversor MM440.....	36
Tabela 12 – Matriz Confusão falha ou saudável inversor G110.....	36
Tabela 13 – Matriz Confusão falha ou saudável inversor ATV.....	37
Tabela 14 – Matriz de confusão severidade inversor MM440.....	38
Tabela 15 – Matriz de confusão severidade inversor ATV.....	38
Tabela 16 – Matriz de confusão severidade inversor GTV.....	39
Tabela 17 - Precisão global de multiclassificação - Comparativo entre os resultados deste trabalho com os resultados de Godoy (2016) – Inversor MM440.....	40

SUMÁRIO

1	INTRODUÇÃO.....	11
1.1	Justificativa.....	12
2	OBJETIVOS.....	12
2.1	Objetivo geral.....	12
2.2	Objetivos específicos.....	12
3	FUNDAMENTAÇÃO TEÓRICA.....	14
3.1	Motor de Indução Trifásico.....	14
3.2	Acionamento por Inversor de Frequência.....	15
3.3	Falhas em MIT.....	15
3.3.1	Falha de Rolamento.....	16
3.3.2	Detecção de Falhas.....	19
3.4	Transformada de Fourier.....	19
3.4.1	Transformada Discreta de Fourier.....	20
3.4.2	Transformada Rápida de Fourier.....	20
3.5	Análise de componentes principais.....	21
3.5.1	Definição de componentes principais.....	21
3.6	Classificação inteligente de falhas.....	22
3.6.1	Redes neurais artificiais.....	22
3.6.2	Rede <i>Perceptron</i> Multicamadas.....	23
3.6.3	<i>Fuzzy</i> ARTmap.....	24
4	METODOLOGIA.....	27
4.1	Banco de dados.....	27
4.1.1	Características do motor e inversores.....	27
4.2	Inserção de falhas de rolamento.....	29
4.3	Pré-processamento.....	31
4.4	Estrutura de classificação.....	32
5	RESULTADOS EXPERIMENTAIS.....	35
5.1	Resultados de classificação	35
5.1.1	Classificação simples.....	35
5.1.2	Multiclassificação.....	37
6	CONSIDERAÇÕES FINAIS.....	41
6.1	Perspectivas para trabalhos futuros.....	42
	REFERÊNCIAS.....	43

1 INTRODUÇÃO

De toda energia elétrica produzida no Brasil, cerca de 35% é utilizada pelo setor industrial, deste percentual, cerca de 68% é consumida pelo sistema motriz, (SAUER et al., 2015). Sendo uma parcela significativa de energia, é imprescindível que esta seja utilizada da forma mais racional possível. Neste contexto, destaca-se o motor elétrico de indução trifásico, pois dentre os diversos tipos de motores existentes, este é o que melhor atende às necessidades econômicas, apresentando simplicidade, baixo custo, robustez, alto rendimento e confiabilidade (BELLINI et al., 2008). Tais características justificam o fato deste motor ser o mais utilizado na maioria das aplicações industriais.

O acionamento por inversores de frequência vem ganhando grande destaque, pois permite o controle de velocidade, partida suave, rápida resposta dinâmica, além de proteção do motor contra sobretensão/subtensão, sobrecorrente, sobretemperatura e sobrecarga (GODOY, 2016).

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). Logo, a detecção de falhas ainda na fase inicial, é essencial para a adequada manutenção evitando-se, assim, danos mais severos que o motor poderia vir a desenvolver e também, paradas não programadas para a realização de manutenção corretiva.

Dentre as falhas que podem vir a ocorrer nos motores elétricos, cerca de 69% correspondem a falhas nos rolamentos. Realizar o monitoramento desta falha é essencial, visto que, falhas nos rolamentos influenciam diretamente no desempenho da máquina (SUETAKE, 2012).

Assim, a proposta deste trabalho consiste em apresentar uma classificação inteligente de falhas de rolamento em motores elétricos de indução trifásicos, acionados por inversores de frequência, através de dados de corrente em regime permanente.

1.1 Justificativa

O motor de indução trifásico, conforme mencionado, é o tipo de máquina elétrica mais difundida e utilizada no setor industrial brasileiro, portanto, devida atenção deve ser dada a este, pois uma parada devido a uma falha pode vir a comprometer um processo industrial por inteiro. Desta forma, a detecção antecipada de falhas nestes motores é imprescindível para garantir condições operacionais seguras, aumento da vida útil das máquinas e conseqüentemente uma maior continuidade do processo produtivo.

Logo, torna-se importante o estudo de técnicas de detecção de falhas precoces, de maneira a possibilitar a programação das manutenções corretivas a serem realizadas, garantindo maior agilidade na atividade de manutenção e eliminando paradas não programadas na indústria.

2 OBJETIVOS

Nesta seção serão apresentados o objetivo geral e os objetivos específicos deste trabalho.

2.1 Objetivo geral

O objetivo geral deste trabalho é realizar a classificação inteligente de falhas de rolamento em motores elétricos de indução trifásicos, acionados por inversores de frequência, utilizando a transformada rápida de Fourier e análise de componentes principais através de sinais de corrente do motor.

2.2 Objetivos específicos

Os objetivos específicos deste trabalho são divididos em:

- Analisar sinais de corrente de motores elétricos de indução trifásicos com falhas;
- Realizar o pré-processamento destes sinais por meio da transformada rápida de Fourier e da análise de componentes principais, utilizando o *software* MATLAB®;
- Diagnosticar falhas de rolamentos empregando as redes *Perceptron* Multicamadas e *Fuzzy ARTmap*, utilizando o *software* MATLAB®;

- Diagnosticar a severidade da falha de rolamentos empregando as redes *Perceptron* Multicamadas e *Fuzzy ARTmap*, utilizando o *software* MATLAB® 2011;
- Analisar se os resultados obtidos com a análise no domínio da frequência foram melhores que os resultados no domínio do tempo apresentados por Godoy (2016).

3 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, é feita uma descrição dos motores de indução trifásicos e do acionamento destes por inversores de frequência, em seguida são introduzidos os conceitos básicos envolvendo as principais falhas que ocorrem nestes motores. É dada ênfase nas falhas de rolamento e nas técnicas de pré-processamento de sinais, transformada rápida de Fourier e análise de componentes principais e, também, nas redes neurais *Perceptron* multicamadas e *Fuzzy ARTmap*.

3.1 Motor de Indução Trifásico

Motores de Indução Trifásicos (MIT) são os principais elementos de conversão eletromecânica de energia no setor industrial, devido às suas características de robustez, baixo custo e versatilidade (SUETAKE, 2012).

O motor de indução trifásico é constituído pelo estator, entreferro e o rotor, não existindo conexões físicas entre o rotor e o estator. No estator encontra-se o enrolamento de armadura, e este é alimentado por corrente alternada e, então, por indução, correntes são induzidas no rotor. Os fluxos no rotor e no estator giram em sincronismo, porém, o rotor não gira em sincronismo com o fluxo da armadura, o que resulta em um escorregamento (FITZGERALD; KINGSLEY; UMANS, 2003). A Figura 1, representa um motor de indução trifásico.

Figura 1 – Motor de Indução Trifásico, modelo w22 premium, WEG.



Fonte: (WEG, 2013b)

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 Acionamento por Inversor de Frequência

O acionamento por inversores de frequência é um dos métodos mais eficientes para controlar a velocidade dos motores de indução. Os inversores transformam a tensão da rede, de amplitude e frequência constantes, em uma tensão de amplitude e frequência variável. Desta forma, é possível obter-se a velocidade desejada de rotação.

O acionamento por inversor de frequência também é caracterizado por fornecer proteção ao motor contra sobretensão/subtensão, sobrecorrente, sobrecarga e também sobretemperatura (FAIZ; GHORBANIAN; EBRAHIMI, 2012b). Assim, as aplicações envolvendo este dispositivo vêm ganhando espaço frente aos acionamentos de corrente contínua (GODOY, 2016).

3.3 Falhas em Motores de Indução Trifásicos

Apesar das inúmeras características consolidadas anteriormente, os motores de indução trifásicos acionados por inversores de frequência, 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).

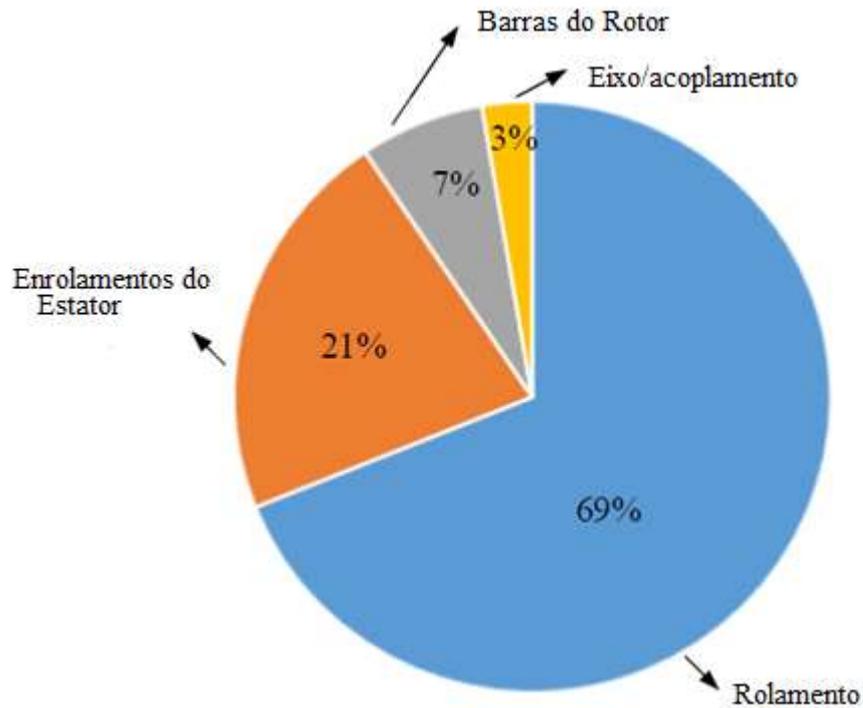
Portanto, o monitoramento da operação desses motores a fim de detectar falhas ainda no estado inicial, permite tratá-las adequadamente, evitando paradas não programadas para a manutenção, o que se traduz em uma redução do custo de manutenção e conseqüentemente, redução do custo de estoque de peças. Além de não comprometer o processo industrial no qual as máquinas estão inseridas (DRIF; CARDOSO, 2007).

Tais benefícios justificam a necessidade da detecção de falhas em motores elétricos de indução trifásicos, acionados por inversores de frequência.

As principais falhas que ocorrem nos motores de indução dividem-se em internas e externas que, por sua vez, podem ser divididas em falhas internas elétricas e falhas internas mecânicas, já as externas em elétricas, mecânicas e ambientais. As falhas elétricas internas, podem ocorrer no estator, rotor, anéis quebrados e conexões. Já internas mecânicas classificam-se em falhas de rolamentos, excentricidade e desgaste do acoplamento (GODOY, 2016).

Dentre estas falhas, de acordo com Bonnett e Yung (2008), a Figura 2 representa a distribuição estatística de cada uma.

Figura 2 – Distribuição estatística dos tipos de falha



Fonte: Adaptado de Bonnett e Yung (2008).

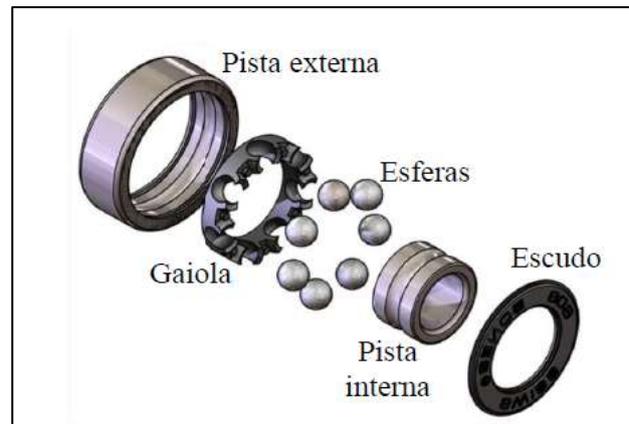
Assim, é possível identificar que as principais falhas que ocorrem nos motores de indução trifásicos são falhas de rolamento, justificando, a necessidade de se detectar previamente este tipo de falha.

3.3.1 Falha de Rolamento

Rolamentos são os elementos de máquina mais comuns na indústria. Sua função é sustentar o eixo e substituir a fricção de deslizamento entre o eixo e o mancal por uma fricção rolante (SILVA, 2008).

Conforme ilustrado na Figura 3, um rolamento é composto por uma pista externa, pista interna, esferas, gaiola e escudo.

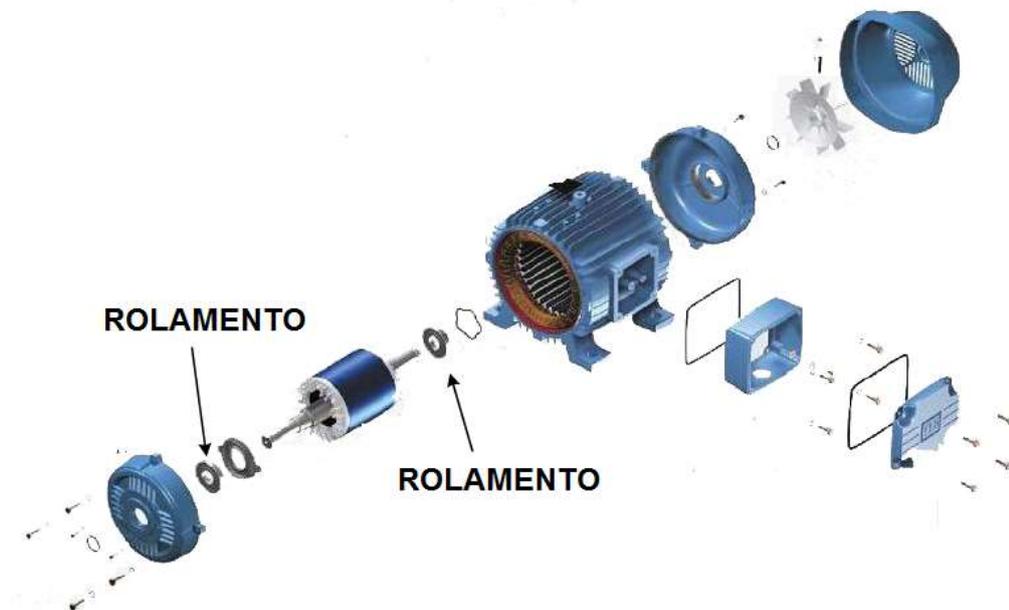
Figura 3 – Partes constituintes de um rolamento



Fonte: Adaptado de Bones (2011).

A Figura 4, representa o local onde os rolamentos se encontram no motor.

Figura 4 – Rolamentos no motor



Fonte: Adaptado de WEG (2013b).

A substituição de rolamentos defeituosos é a manutenção corretiva mais barata, em relação aos outros tipos de falhas. Porém, a detecção deste tipo de falha é a mais complexa, e também, é a falha que mais resulta em quebras de motores (SILVA, 2008).

As principais causas de falhas de rolamento são devido a fatores externos como:

- Lubrificação insuficiente ou excessiva;
- Lubrificante incorreto;

- Contaminação devido a sujeiras ou outras partículas;
- Montagem imprópria do rolamento na máquina.
- Desalinhamento mecânico do eixo;
- Sobrecarga mecânica;
- Exposição à umidade.

As falhas de rolamento classificam-se em falhas distribuídas, representada na Figura 5, e falhas localizadas, representada na Figura 6. Sendo que a primeira determina uma falha que afeta toda uma região do rolamento, e a segunda afeta um único ponto do rolamento (GONGORA, 2013).

Figura 5 – Falha de rolamento distribuída



Fonte: NSK DO BRASIL (2012)

Na Figura 5, tem-se uma falha de rolamento distribuída que ocorreu devido ao aquecimento demasiado em que a peça foi submetida. Já na Figura 6, tem-se uma falha distribuída devido ao excesso de carga.

Figura 6 – Falha de rolamento localizada



Fonte: NSK DO BRASIL (2012)

Quando um motor começa a desenvolver um tipo de falha, ocorrem mudanças nos sinais de vibração, alteração no fluxo magnético, variação na temperatura, variação na corrente do estator, ruídos, entre outras (ARAÚJO, 2011). Desta forma, a detecção de falha, pode ser realizada através de técnicas de processamento de sinais (GODOY, 2016).

3.3.2 Detecção de falhas

Existem muitos métodos que podem ser utilizados para a detecção de falhas em motores de indução, dentre eles 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 REIS (2010). Assim, neste trabalho, será utilizado sinais de corrente como forma de diagnosticar falhas.

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).

Ao aplicar a transformada de Fourier em um sinal, a informação no domínio do tempo passa a ser representada no domínio da frequência, sendo essa representação denominada espectro. No espectro de um sinal é possível identificar as principais componentes de frequência.

3.4 Transformada de Fourier

Considerando uma função $x = x(t)$, a transformada de Fourier desta função, é definida por:

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (1)$$

onde $X(\omega)$ é o sinal $x(t)$ representado no domínio da frequência (ω).

3.4.1 Transformada Discreta de Fourier

A equação 2, no domínio de tempo discreto, é denominada Transformada Discreta de Fourier, descrita por (OPPENHEIM; SCHAFER; BUCK, 1998):

$$X(m) = \sum_{n=0}^{N_a-1} x(n)e^{-j(2\pi/N_a)mn} \quad (2)$$

onde:

n é um número inteiro, entre $[0...N_a]$;

m é um número inteiro, entre $[0...N_a]$;

N_a é a quantidade total de amostra.

Portanto, de acordo com a equação 2, o cálculo da Transformada Discreta de Fourier, equivale ao cálculo da transformada de Fourier em N_a amostras de frequência $\omega_m = 2\pi m/N_a$ (SUETAKE, 2012).

3.4.2 Transformada Rápida de Fourier (FFT)

A Transformada Rápida de Fourier, é um algoritmo utilizado no processamento de sinais, que possibilita o cálculo da Transformada Discreta de Fourier (DFT) com menos esforço computacional, pois reduz o número de somas e multiplicações aritméticas (SUETAKE, 2012).

A quantidade de amostras N_a da janela de dados, deve ser em função da potência de 2, de acordo com (SUETAKE, 2012):

$$N_a = 2^v \quad (3)$$

onde v é um número inteiro positivo.

Para se representar o sinal com o mínimo de perda de informação, é necessário aplicar o teorema de Nyquist. De acordo com este teorema, a frequência de amostragem deve ser igual ou maior a duas vezes a maior frequência do espectro desse sinal.

3.5 Análise de Componentes Principais

No processo de diagnóstico de falhas de rolamento, diversas características são obtidas a partir dos sinais. Tais características carregam informações referentes à condição do equipamento. Assim, através da análise de componentes principais (PCA), é possível processar todas as características de falhas e em seguida selecionar as que contribuem mais significativamente para a solução (SILVA, 2008).

A Análise de Componentes Principais é uma técnica estatística que tem por finalidade reduzir a dimensionalidade de um conjunto de dados, onde há um grande número de variáveis inter-relacionadas. Essa redução é realizada de forma a obter um novo e reduzido conjunto de variáveis não correlacionadas, denominadas componentes principais. Posteriormente, as componentes são ordenadas de forma que as primeiras tenham a maior parte de variância (SILVA, 2008).

3.5.1 Definição de Componentes Principais

Considerando um vetor x de p variáveis aleatórias, a técnica PCA é utilizada de forma a analisar as variâncias e correlações dessas variáveis. O primeiro passo é encontrar a função linear a'_1x dos elementos de x que contém máxima variância, onde a_1 é um vetor de p constantes, de forma que:

$$a'_1x = \sum_{j=1}^p a_1 x_j \quad (4)$$

O segundo passo é determinar a função linear a'_2x , não correlacionada com a'_1x , que contém variância máxima, e assim por diante, até que o k -ésimo estágio da função linear a'_kx seja determinado, com a máxima variância possível não correlacionada com $a'_1x, a'_2x, \dots, a'_{1k-1}x$ (SILVA, 2008).

3.6 Classificação inteligente de falhas

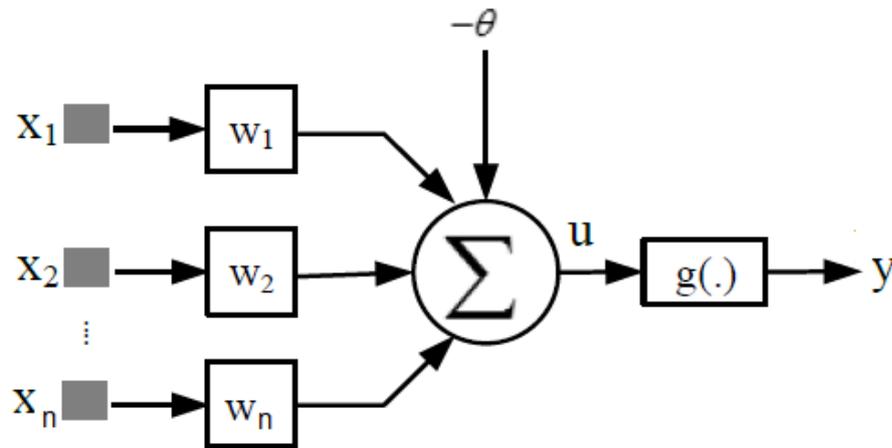
A proposta deste trabalho considera o emprego dos classificadores *Perceptron* Multicamadas e *Fuzzy ARTmap*, que serão descritas detalhadamente nas próximas seções.

3.6.1 Redes Neurais Artificiais

Redes neurais artificiais (RNAs) são modelos computacionais inspirados no funcionamento do sistema nervoso de seres vivos. Estas redes são compostas por um conjunto de neurônios artificiais interligados (SILVA; SPATTI; FLAUZINO, 2010).

A estrutura mostrada na Figura 7 representa o neurônio artificial, também conhecido como nó ou elemento de processamento, estas estruturas são os elementos básicos de uma rede neural.

Figura 7 – Neurônio artificial



Fonte: Adaptado de Silva, Spatti e Flauzino (2010)

Assim, de acordo com a Figura 7 é possível observar que o neurônio artificial é constituído por sete elementos básicos:

- Sinais de entrada $\{x_1, x_2, \dots, x_n\}$;
- Pesos sinápticos $\{w_1, w_2, \dots, w_n\}$;
- Combinador linear $\{\Sigma\}$;
- Limiar de ativação $\{\theta\}$;
- Potencial de ativação $\{u\}$;
- Função de ativação $\{g\}$;

- Sinal de saída $\{y\}$.

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 $\{w_1, w_2, \dots, w_n\}$, os resultados obtidos são posteriormente agregados. O limiar de ativação $\{\theta\}$ determina o patamar para que seja gerado um valor de disparo em direção à saída do neurônio, o potencial de ativação $\{u\}$ é dado pela diferença entre o resultado do combinador linear e o limiar de ativação, assim, se $u \geq \theta$, o neurônio produz potencial excitatório e se $u < \theta$ produz potencial inibitório, a função de ativação $\{g\}$ tem como objetivo limitar a saída do neurônio (SILVA; SPATTI; FLAUZINO, 2010).

No contexto de diagnóstico de falhas em máquinas elétricas, as RNAs têm sido objeto de consideráveis pesquisas recentes (GODOY, 2016). Um dos motivos, está no fato de a arquitetura de processamento das RNAs fornecer um desempenho superior a modelos convencionais, pois estas redes são capazes de aprender e principalmente generalizar o conhecimento adquirido (GONGORA, 2013). Além disso, as RNAs 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).

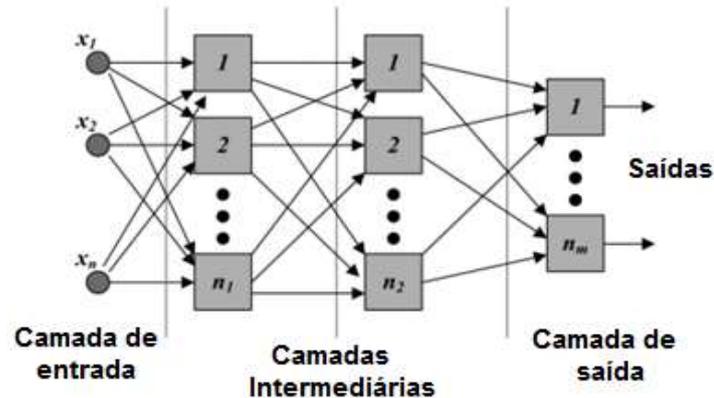
3.6.2 Rede *Perceptron* Multicamadas

A rede *Perceptron* multicamadas (PMC) é caracterizada por apresentar pelo menos uma camada intermediária de neurônios, entre a camada de entrada e a camada de saída. Estas redes pertencem a arquitetura *feedforward* de múltiplas camadas, com treinamento supervisionado (SILVA; SPATTI; FLAUZINO, 2010).

De acordo com a Figura 8, segundo Silva, Spatti e Flauzino (2010), as redes neurais artificiais são constituídas por três camadas, sendo elas:

- Camada de entrada: recebe os sinais externos da rede.
- Camadas intermediárias, multicamadas ou escondidas: extraem informações inerentes ao sistema.
- Camadas de saída: fornece os sinais processados pela rede.

Figura 8 – Representação de uma Rede PMC



Fonte: Adaptado de Godoy, 2016

Na rede PMC, o ajuste dos pesos e do limiar de cada neurônio é realizado através do treinamento supervisionado, ou seja, para cada amostra dos dados de entrada obtém-se uma respectiva saída desejada (SILVA; SPATTI; FLAUZINO, 2010).

Para realizar o processo de treinamento do *Perceptron* multicamadas é utilizado comumente o algoritmo de aprendizagem *backpropagation* ou regra Delta generalizada. Este algoritmo possui duas etapas distintas: na primeira, denominada *forward*, os dados de entrada são propagados por todas as camadas até a saída, já a segunda, denominada *backward*, é realizado o processo inverso, ou seja, o valor da saída é retornado à entrada.

Ao final da primeira etapa, o sinal de resposta na saída é verificado e comparado com o sinal de resposta desejado para esta saída. Assim, se o erro obtido nesta comparação não estiver dentro do esperado, inicia-se a segunda etapa, de forma a retropropagar o erro camada por camada, ajustando os pesos sinápticos dos neurônios (GODOY, 2016).

Este procedimento é repetido até que se tenha na saída uma resposta de acordo com a desejada.

3.6.3 Fuzzy ARTmap

A rede *Fuzzy ARTmap* (FAM) foi desenvolvida por Carpenter e Grossberg (1987), e está baseada na teoria da ressonância adaptativa (ART). Esta rede é caracterizada por

apresentar estabilidade e plasticidade. Pois, após a inclusão de novos padrões, esta é capaz de continuar a aprender, mantendo as informações relacionadas aos padrões anteriores (CARPENTER, 1992).

A arquitetura *Fuzzy* ARTmap também é caracterizada por ser um sistema de aprendizagem supervisionado auto-organizável, ou seja, é apresentado um conjunto de padrões a rede juntamente com as saídas desejadas, assim, a rede é capaz de ajustar os pesos para obter as saídas corretas em função das entradas.

A estrutura desta rede é composta por um par de módulos *Fuzzy* ART, que estão interconectados por um módulo de memória Inter-ART (CARPENTER et al., 1992; LIM; HARRISON, 1997; LOPES et al., 2005).

De acordo com Carpenter et al. (1992), a rede neural *Fuzzy* ARTMAP possui uma entrada referente ao módulo *Fuzzy* ART_a, representada por um vetor a , $a = [a_1 \dots a_{M_a}]$, M_a -dimensional, e outra referente ao módulo *Fuzzy* ART_b, representada por um vetor b , $b = [b_1 \dots b_{M_b}]$, M_b -dimensional, que corresponde à saída desejada. Estes vetores de entrada são normalizados e complementados, sendo representados por um vetor $\mathbf{I}^a = [\bar{a} \bar{a}^c]$ e $\mathbf{I}^b = [\bar{b} \bar{b}^c]$.

Assim, o primeiro passo do treinamento da rede consiste na apresentação de cada padrão de entrada para a camada F_1^a , onde são obtidos os vetores complementares.

Os parâmetros utilizados na rede *Fuzzy* ARTmap, de acordo com Carpenter et al. (1992), podem ser definidos como: parâmetro de escolha (α), taxa de treinamento (β), parâmetro de vigilância do módulo *Fuzzy* ART_a (ρ_a), parâmetro de vigilância do módulo *Fuzzy* ART_b (ρ_b), parâmetro de vigilância do módulo Inter-ART (ρ_{ab}).

Todos os pesos da rede *Fuzzy* ARTmap ($W_{(N \times 2M_a)}^a$, $W_{(N \times 2M_b)}^b$ e $W_{(N \times N)}^{ab}$) possuem inicialmente valor igual a 1, ou seja, nenhuma categoria está ativa (CARPENTER, 1992).

Para cada módulo ART (ART_a e ART_b) calcula-se as funções de escolha, definidas como T_j^a e T_k^b , para as respectivas entradas \mathbf{I}^a e \mathbf{I}^b (CARPENTER, 1992):

$$T_j^a = \frac{|I^a \wedge W_j^a|}{\alpha + |W_j^a|} \quad (5)$$

$$T_k^b = \frac{|I^b \wedge W_k^b|}{\alpha + |W_k^b|} \quad (6)$$

Assim, após a inicialização, calcula-se a categoria ativa e o processo de escolha é inicializado. Através do processo de competição (*winner takes all*), o maior valor para a função de escolha da categoria é escolhido. Em seguida, verifica-se a condição de ressonância (GODOY, 2016):

$$\frac{|I^a \wedge W_{jv}^a|}{|I^a|} \geq \rho_a \quad (7)$$

$$\frac{|I^b \wedge W_{kv}^b|}{|I^b|} \geq \rho_b \quad (8)$$

Portanto, se a condição de ressonância falhar, o mecanismo *reset*, é acionado, outra categoria é selecionada e o processo de verificação da condição de ressonância é realizado novamente. Este processo é executado até que se encontre uma categoria ativa que satisfaça a condição de ressonância.

Após encontrada uma categoria que satisfaça a condição de ressonância, inicia-se o processo de aprendizado, realizando-se a adaptação dos pesos, conforme as equações 9 e 10 (GODOY, 2016).

$$W_{jv}^{a(novo)} = \beta(I^a \wedge W_{jv}^{a(antigo)}) + (1 - \beta)W_{jv}^{a(antigo)} \quad (9)$$

$$W_{kv}^{b(novo)} = \beta(I^b \wedge W_{kv}^{b(antigo)}) + (1 - \beta)W_{kv}^{b(antigo)} \quad (10)$$

onde $0 \leq \beta \leq 1$ é a taxa de aprendizagem.

4 METODOLOGIA

Conforme mencionado, apesar de apresentarem características construtivas robustas, os MITs podem vir a apresentar falhas, dentre elas, a falha de rolamento representa 69% dos defeitos nestes motores.

De maneira a se analisar o comportamento destas falhas, o banco de dados utilizado foi criado por meio de ensaios em laboratório, simulando várias falhas e condições de operação, buscando aproximar as condições do ambiente industrial.

Assim, este trabalho propõe um método para a detecção de falhas e análise de severidade através de sinais de corrente obtidos, com o motor operando sem falha e em quatro situações distintas de desgaste, a saber: desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Logo, são realizados dois tipos de análise, a saber: detecção de falha e detecção da severidade da falha, considerando o motor sendo acionamento por três inversores de frequência diferentes.

Primeiramente é realizado um pré-processamento nos sinais de corrente, através da aplicação da transformada rápida de Fourier e da análise de componentes principais, criando-se as matrizes de entrada das redes neurais. Por fim, é realizado as análises com as redes supracitadas.

4.1 Banco de dados

O banco de dados utilizado neste trabalho também foi utilizado em Lopes (2016), Bazan (2016), Godoy (2016), Palácios (2016) e Broniera (2014). A seguir é descrito as características do motor e dos inversores utilizados neste trabalho e, também, as especificações do rolamento e a metodologia que foi utilizada para a inserção de falhas.

3.1.1 Características do motor e inversores

Os parâmetros e características do motor utilizados neste trabalho são apresentados 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
Acionamento	Inversor de frequência

Na Tabela 2 tem-se os modelos dos inversores utilizados neste trabalho, bem como suas características básicas.

Tabela 2: Parâmetros e características dos inversores

Parâmetros	Sinamics G110	Micromaster MM440	ATV12H075M2
Fabricante	Siemens	Siemens	Schneider
Aceleração (s)	3	3	3
Desaceleração (s)	3	3	3
Tipo de controle	V/f	V/f-Vetorial	V/f
Freq. Chaveam. (kHz)	8	8	4

A Tabela 3 resume as características gerais e a quantidade de dados adotadas do banco de dados utilizado no contexto deste trabalho. Cada aquisição corresponde a um sinal de corrente no tempo de 5 segundos, sendo a frequência de amostragem 25 KHZ, portanto 125000 pontos.

Tabela 3: Número de aquisições

Condições	Micromaster		
	Sinamics G110	MM440	ATV12H075M2
Saudável	91	91	91
Falha inicial (15 minutos)	73	91	90
Falha médio (30 minutos)	75	89	90
Falha avançado (60 minutos)	74	90	90
Falha severo (90 minutos)	75	89	90
Número total de aquisição	388	450	451

Os dados utilizados, englobam o inversor operando na faixa de 12 a 60 Hz, com intervalos de 6Hz entre cada amostra, e o torque de carga variando em 0,5-1,0-1,5-2,0-2,5-3,0-3,5-4,0-4,5 e 5,0 N.m.

4.2 Inserção de falhas de rolamento

No desenvolvimento do banco de dados utilizado, buscou-se reproduzir defeitos no rolamento do motor, de forma a aprofundar a investigação de uma falha causada pelo desgaste gradual de um rolamento ao longo do tempo de operação da máquina.

Assim, de acordo com Godoy (2016), para a execução dos testes utilizou-se conjuntos de rolamentos novos, removeu-se as blindagens de proteção lateral e substituiu-se o lubrificante por pasta abrasiva, marca Brasilex, composta de carbono, silício, graxa e óleo.

Em seguida, foi considerado quatro situações distintas de desgaste: inicial, médio, avançado e severo.

O motor foi acionado diretamente na rede operando a vazio de forma interrupta para cada um dos períodos de desgaste definidos, a saber: 15, 30, 60 e 90 minutos.

Para os testes foi utilizado o rolamento rígido de esferas, modelos NSK 6204, na Tabela 4 encontra-se as especificações do rolamento utilizado (GODOY, 2016).

Tabela 4: Parâmetros e especificações do rolamento

Parâmetros	Especificações
Diâmetro do furo (mm)	20
Diâmetro externo (mm)	47
Largura (mm)	14
Carga dinâmica (kN)	13,5
Carga estática (kN)	6,55
Velocidade (rpm)	32000
Velocidade limite (rpm)	17000

A Figura 9 demonstra o desgaste do rolamento após a execução dos testes.

Figura 9 – Desgaste do rolamento após período de execução dos testes

Fonte: Godoy (2016)

Após o processo de desgaste, é perceptível a formação de folgas entre as partes componentes do rolamento, similar a característica observada nas peças com desgaste excessivo por tempo de operação ou falta de lubrificação (GODOY, 2016).

4.3 Pré-processamento

Nessa seção são expostas as transformações realizadas no conjunto de dados de forma a torná-los mais adequados para a aplicação na rede neural. Essas transformações incluem a aplicação da transformada rápida de Fourier, a normalização e a análise de componentes principais dos dados.

Para a análise, primeiramente é realizado um janelamento dos dados no domínio do tempo, dividindo-se o sinal em janelas de 4096 pontos, em seguida é realizado a FFT.

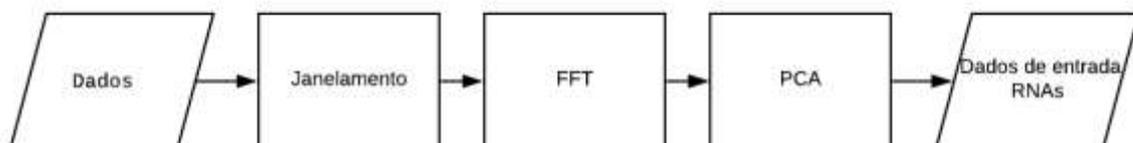
Após a aplicação da transformada rápida de Fourier tem-se o sinal no domínio da frequência contendo 2048 entradas, assim, aplicou-se a técnica estatística PCA obtendo-se um conjunto reduzido de 8 entradas, contendo apenas as componentes principais, ou seja, componentes mais relevantes do banco de dados.

Com um banco de dados no domínio da frequência contendo apenas as componentes mais relevantes do sinal, é necessário normalizar estes dados, visando diminuir a influência causada por valores que se destacam excessivamente em relação aos demais, ou seja, diminuir a distância entre os valores das variáveis (REIS, 2010).

Após o pré-processamento realizado nos dados, realizou-se a aplicação da rede *Perceptron Multicamadas* e da rede *Fuzzy ARTmap*.

A Figura 10 resume as etapas do pré-processamento.

Figura 10 – Fluxograma



Fonte: autoria própria

4.4 Estrutura de classificação

Neste trabalho são utilizadas duas estruturas de classificação, sendo elas: rede *Perceptron* Multicamadas e rede *Fuzzy ARTmap*.

Com os dados pré-processados, ajustados e normalizados, estes são aleatoriamente apresentados para as redes, de maneira que as amostras apresentadas representem todo o domínio de operação do motor.

O conjunto de dados foi dividido em dois blocos, sendo eles treinamento e teste da rede. Uma vez criada a rede é treinada e testada. As matrizes de treinamento e de teste são divididas, aleatoriamente, sempre em quantidades proporcionais fixas de acordo com a Tabela 5.

Tabela 5 – Proporção de dados para criação das redes

Etapa	Percentual
Treinamento	80%
Teste	20%

Na etapa de classificação foi realizada duas análises, primeiramente analisou-se o desempenho da rede na classificação simples de apenas dois padrões: motor saudável e motor com falha. Em seguida, realizou-se uma análise do desempenho da rede na multiclassificação de falha, considerando o motor operando com falha durante os seguintes períodos: 15 minutos, 30 minutos, 60 minutos e 90 minutos.

Para a rede *perceptron* multicamadas utilizou-se os parâmetros apresentados na Tabela 6, tanto na análise simples quanto na multiclassificação.

Tabela 6 – Parâmetros da rede *Perceptron* Multicamadas

Função de ativação das camadas ocultas	Tangente hiperbólica
Função de ativação da camada de saída	Linear
Algoritmo de treinamento	<i>Backpropagation</i>

O algoritmo de treinamento da rede *perceptron* multicamadas é o *backpropagation*, este de acordo com GODOY (2016), tem a finalidade de encontrar as derivadas da função de erro com relação aos pesos e bias da RNA. Definiu-se as funções de ativação a serem utilizadas com base em testes realizados, observando o melhor desempenho da rede.

Para a rede FAM, utilizou-se os parâmetros apresentados na Tabela 7, tanto na análise simples quanto na multiclassificação.

Tabela 7 – Parâmetros da rede *Fuzzy ARTmap*

Vigilância (ρ)	0.75
Taxa de aprendizagem (β)	1
Escolha (α)	0,001

De acordo com Godoy (2016), elevados valores do parâmetro de vigilância (ρ), impactam na formação de um número maior de categorias na camada de saída, os quais degradam os resultados de classificação. A taxa de aprendizagem foi definida como 1, visando aprendizagem rápida.

O parâmetro de escolha, conforme Godoy (2016), foi mantido como um pequeno valor próximo a zero, definido neste trabalho como 0,001.

Na rede PMC, para a classificação simples as amostras de sinais de corrente do motor com falha e do motor saudável receberam, respectivamente, uma classificação de saída desejada, sendo 1 para dados com falha e 0 para dados do motor saudável.

Em seguida, partindo de uma quantidade mínima de neurônios nas camadas, foi-se incrementando o número de neurônios de acordo com o desempenho da rede, até encontrar a topologia com melhores resultados. Na Tabela 8 encontra-se essa topologia.

Tabela 8 – Topologia da rede PMC – Classificação simples

Quantidade de neurônios de entrada	8
Quantidade de neurônios na camada oculta	2
Quantidade de neurônios na camada de saída	1
Número de camadas escondidas	1
Iterações	100

A Tabela 9 representa a melhor topologia para a rede PMC na classificação de severidade da falha.

Tabela 9 – Topologia da rede PMC - Severidade

Quantidade de neurônios de entrada	10
Quantidade de neurônios na segunda camada	20
Quantidade de neurônios na camada de saída	5
Número de camadas escondidas	1
Iterações	100

A Tabela 10 representa a classificação definida para os sinais de motor saudável, com falha inicial, média, avançada e severa.

Tabela 10 – Características da Classificação

Característica	Saída desejada
Saudável	0 0 0 0 1
Falha inicial	0 0 0 1 0
Falha média	0 0 1 0 0
Falha avançada	0 1 0 0 0
Falha severa	1 0 0 0 0

5 RESULTADOS EXPERIMENTAIS

Nesta seção são apresentados os resultados obtidos a partir da implementação do sistema desenvolvido para a detecção de falhas de rolamento no MIT, utilizando como entrada dados de corrente do estator, no domínio da frequência, sendo o MIT acionado por modelos distintos de inversores de frequência, conforme descrito no capítulo 4. Por fim, são expostos os dados obtidos através das matrizes de confusão.

Destaca-se que neste trabalho foi utilizado o processador Intel® Core(TM) i3-3110M 2.40GHz.

5.1 Resultados de classificação

Como mencionado anteriormente, no contexto deste trabalho, foi realizada uma classificação simples (motor com falha e motor saudável), bem como uma classificação da severidade da falha (inicial, média, avançada e severa).

5.1.1 Classificação simples

A Tabela 11 representa os resultados obtidos de classificação do conjunto composto por 12096 amostras, do motor sendo acionado pelo inversor MM440. Tem-se assim 9677 dados utilizados para treinamento e 2419 dados utilizados para teste. A partir dos testes realizados foi gerada uma matriz de confusão. Nesta é possível verificar o quanto o classificador de falhas confunde uma classe com outra. De acordo com a Tabela 11 é possível observar que a rede *Perceptron* multicamadas atingiu 100% de precisão global, já a rede *Fuzzy ARTmap* atingiu 99,75%. O tempo de processamento da rede PMC foi de 16.2 segundos, e da rede FAM foi de 1.42 segundos.

A matriz de confusão da Tabela 11 mostra que a rede PMC atingiu 100% de precisão para a classificação de falha e 100% de precisão para a classificação de motor saudável. A rede FAM atingiu precisão de 99,7% para diagnóstico de motor saudável e 99,76% para identificação de falha.

Tabela 11 – Matriz Confusão falha ou saudável inversor MM440

Classe				
PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	342	0	341	1
Falha	0	2077	5	2072

A Tabela 12 representa os resultados obtidos de classificação do conjunto composto por 10476 amostras, do motor sendo acionado pelo inversor G110. Tem-se assim 8380 dados utilizados para treinamento e 2096 dados utilizados para teste. De acordo com a Tabela 12 é possível observar que a rede PMC apresentou melhor precisão global em relação a rede *Fuzzy* ARTmap, atingindo 100%, já a rede *Fuzzy* ARTmap atinge 99,71%. O tempo de processamento da rede PMC foi de 4.37 segundos, e da rede FAM foi de 1.23 segundos.

De acordo com a matriz de confusão da Tabela 12, a rede PMC atingiu 100% de precisão para a classificação de motor com falha e motor saudável, já a rede FAM atingiu 99,1% de precisão para a classificação de motor saudável e 99,83% para a classificação de motor com falha.

Tabela 12– Matriz Confusão falha ou saudável inversor Sinamics G110

Classes				
PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	337	0	334	3
Falha	0	1759	3	1756

A Tabela 13 representa os resultados obtidos de classificação do conjunto composto por 12366 amostras, do motor sendo acionado pelo inversor ATV, sendo 9893 dados utilizados para treinamento e 2473 dados utilizados para teste. Assim, é possível observar que a rede PMC apresenta novamente melhor precisão global, atingindo 100%, já a rede FAM apresenta 99,96%.

De acordo com a matriz de confusão da Tabela 13, é possível observar que a rede PMC atinge novamente 100% de precisão para a classificação de motor com falha e 100% de

precisão para a classificação de motor saudável. A rede FAM apresenta 100% de precisão para a classificação de motor saudável e 99,95% de precisão para a classificação de motor com falha. O tempo de processamento da rede PMC foi de 11.85 segundos, e da rede FAM foi de 1.48 segundos.

Tabela 13 – Matriz Confusão falha ou saudável inversor ATV

		PMC		FAM	
		Classes		Classes	
Classes		Saudável	Falha	Saudável	Falha
Saudável		310	0	310	0
Falha		0	2163	1	2162

5.1.2 Multiclassificação

A Tabela 14 ilustra o desempenho das redes na detecção de severidade da falha para o motor acionado pelo inversor MM440, a rede PMC apresentou melhores resultados, atingindo 99,90% de precisão global, já a rede FAM apresentou 99,42%. O tempo de processamento da rede PMC foi de 151.74 segundos e da rede FAM foi de 46.38 segundos.

De acordo com a Tabela 14 é possível observar que a rede PMC apresenta 99,36% de precisão para o diagnóstico de motor saudável e índices de precisão respectivamente de 100%, 99,62%, 100% e 100% para classificação de falhas no rolamento com desgaste inicial, médio, severo e avançado. Nesse cenário a rede FAM obteve índices de precisão de 98,66%, 100%, 99,8% e 99,25%, respectivamente e 99,36% de precisão para o diagnóstico de motor saudável.

Tabela 14 – Matriz de confusão severidade inversor MM440

Classes										
PMC						FAM				
Classes	S.	15	30	60	90	S.	15	30	60	90
S.	309	0	0	0	2	309	0	0	2	0
15	0	523	0	0	0	0	516	0	6	1
30	0	0	535	0	2	0	0	535	0	0
60	0	0	0	517	0	0	0	0	516	1
90	0	0	0	0	533	0	0	0	4	529

A Tabela 15 representa a matriz de confusão obtida para a classificação de severidade do motor acionado pelo inversor ATV, nessa situação a rede PMC apresentou melhor índice de precisão, atingindo 88,3% de precisão global e tempo de processamento 158.11 segundos, enquanto a rede FAM apresentou 86,90% e tempo de processamento 72.18 segundos.

De acordo com a Tabela 15, a rede PMC apresenta 99,33% de precisão na classificação de motor saudável e 90,8%, 94,2%, 61,17% e 100% respectivamente para a classificação de motor com desgaste inicial, médio, avançado e severo. Nesse cenário a rede FAM apresenta 93,39%, 99,81%, 76,32% e 70,33% respectivamente e para a classificação de motor saudável a rede apresentou 100% de precisão.

Tabela 15 – Matriz de confusão severidade inversor ATV

Classes										
PMC						FAM				
Classes	S.	15	30	60	90	S.	15	30	60	90
S.	301	0	0	0	2	303	0	0	0	0
15	0	494	0	0	50	0	509	0	18	18
30	0	0	520	0	32	0	0	551	1	0
60	0	0	0	323	205	0	14	3	403	108
90	0	0	0	0	546	0	20	2	140	384

A Tabela 16 representa a matriz de confusão obtida para a classificação de severidade do motor acionado pelo inversor G110, a rede PMC apresentou 93,5% de precisão

global e tempo de processamento 175.65 segundos enquanto a rede FAM apresentou 93.42% e tempo de processamento 11.41 segundos.

De acordo com a Tabela 16, a rede PMC apresentou 99,68% para a classificação de motor saudável, e 99,05%, 69,85%, 99,33% e 100% para a classificação de desgaste inicial, médio, avançado e severo. Já a rede FAM apresentou 100%, 84,11%, 100% e 85,32%, respectivamente e para a classificação de motor saudável a rede apresentou 100% de precisão.

Tabela 16 – Matriz de confusão severidade inversor GTV

Classes										
PMC						FAM				
Classes	S.	15	30	60	90	S.	15	30	60	90
S.	316	0	0	0	1	317	0	0	0	0
15	0	419	0	0	4	0	423	0	0	0
30	0	0	299	0	129	0	29	360	1	38
60	0	0	0	448	3	0	0	0	451	0
90	0	0	0	0	477	0	27	42	1	407

Na Tabela 17 é apresentado os resultados de precisão obtidos pelo método desenvolvido neste trabalho e os resultados apresentados por Godoy (2016).

O método de multiclassificação de falhas apresentado por Godoy (2016) utiliza os mesmos sinais apresentados neste trabalho, porém, no domínio do tempo.

De acordo com Godoy (2016) a frequência fundamental atuante na tensão de alimentação dos MIT acionados por inversor de frequência exerce impacto direto na amplitude e no período dos sinais de corrente, tornando ainda mais difícil o desenvolvimento de um sistema de diagnóstico e classificação de falhas no domínio do tempo. Assim, o gráfico representado pela Figura 11 apresenta uma comparação entre os resultados obtidos com as duas metodologias, buscando identificar se a análise no domínio da frequência apresenta melhor desempenho do que a análise no domínio do tempo.

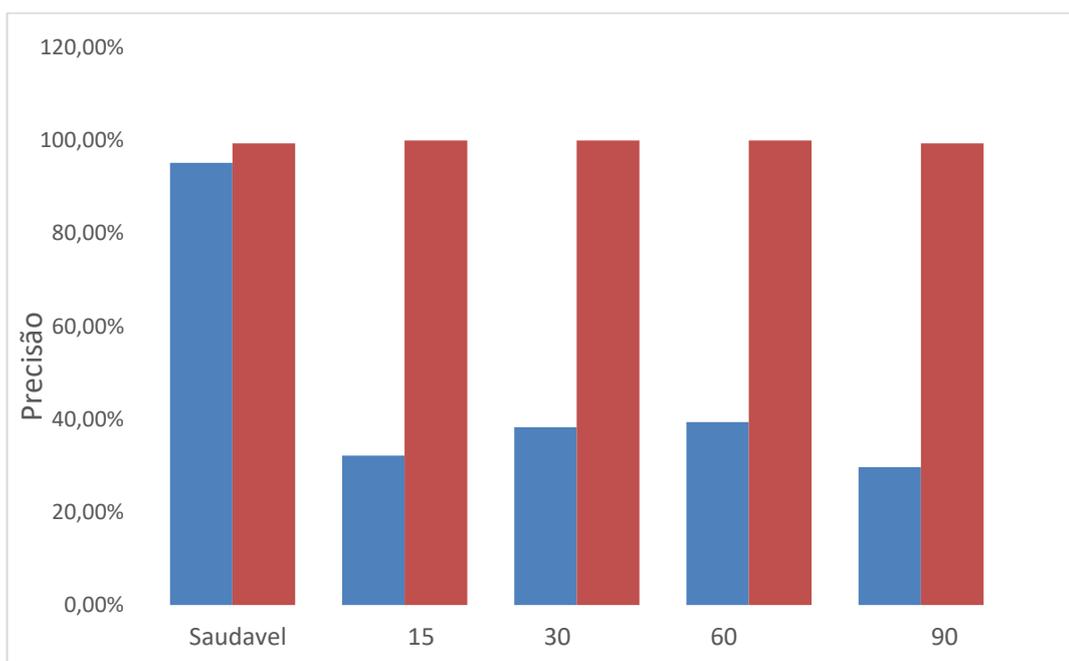
Na metodologia proposta por Godoy (2016) os melhores resultados foram obtidos a partir dos dados coletados do inversor MM440, com o algoritmo PMC, assim estes dados são comparados com os obtidos neste trabalho para o mesmo inversor e considerando a mesma rede. Os dados apresentados no gráfico são referentes a precisão global da multiclassificação das falhas de rolamento.

Tabela 17 – Precisão global de multiclassificação - Comparativo entre os resultados deste trabalho com os resultados de Godoy (2016) – Inversor MM440

Característica	Precisão (%)	
	Godoy (2016)	Este Trabalho
Saudável	95,2	99,36
Falha inicial (15 minutos)	33,2	100
Falha média (30 minutos)	38,3	99,63
Falha avançada (60 minutos)	39,4	100
Falha severa (90 minutos)	29,7	100

Assim, de acordo com os dados da Tabela 17 e com o gráfico da Figura 11 é possível observar que a metodologia empregada neste trabalho obteve resultados superiores às outras.

Figura 11 – Precisão global de multiclassificação - Comparativo dos resultados deste trabalho com os resultados de Godoy (2016) – Inversor MM440



Fonte: Autoria própria.

6 CONSIDERAÇÕES FINAIS

Este trabalho apresentou um método de diagnóstico de falha de rolamento, baseado em dados experimentais de um motor de indução trifásico, acionado por inversor de frequência, ao longo de uma ampla faixa de frequência e variação de carga mecânica no eixo da máquina.

Foi utilizada a transformada rápida de Fourier e a análise de componentes principais para se obter os dados no domínio da frequência e assim realizar o diagnóstico do motor através de algoritmos classificadores inteligentes, buscando identificar a ocorrência de falhas e sua severidade.

Este trabalho também buscou comparar o desempenho da multiclassificação de falhas de rolamento utilizando dados no domínio da frequência, com o proposto por Godoy (2016) que realiza, em parte de seu trabalho a multiclassificação de falhas de rolamento considerando sinais no domínio do tempo. Conclui-se que a detecção de severidade de falha no domínio da frequência apresenta melhores resultados.

Foram detectadas falhas de rolamento com diferentes níveis de severidade. De acordo com os resultados globais obtidos, tanto a rede *Perceptron* multicamadas quanto a rede *Fuzzy ARTmap* podem ser utilizadas para a classificação de falhas de rolamento do motor de indução trifásico, independente do inversor utilizado para acionamento, da velocidade de operação do motor e das condições de carga ou mesmo.

Para os casos de classificação simples a rede PMC apresentou 100% de precisão em todos as análises, já a rede FAM apresentou precisão em torno de 99% em todos os casos considerados, porém o tempo de processamento da rede PMC foi superior ao da rede FAM em todos os casos considerados.

Na multiclassificação de falhas de rolamento do motor, em relação a precisão global, a rede PMC apresentou resultado superior de precisão em todos os casos considerados, em relação a rede FAM.

Para o diagnóstico de motor saudável e de falha inicial as duas redes atingiram 100% de precisão. Para o diagnóstico de falha média a rede FAM atingiu 100% com o motor sendo acionado pelo inversor MM440, e a melhor precisão obtida neste caso pela rede PMC foi de 99,63% com o inversor MM440. Para o diagnóstico de falha avançada as duas redes atingiram 100% de precisão, a rede PMC no inversor MM440 e a rede FAM no G110.

Finalmente, na análise de falha severa a rede PMC atingiu 100% de precisão nos três inversores e a melhor precisão obtida pela rede FAM foi de 99,35% no inversor MM440.

As menores precisões atingidas foram durante a análise de classificação de falha média, no inversor G110 a rede PMC atingiu 69,85% de precisão, classificando erroneamente 129 dados como sendo de falha severa. Na análise de falha avançada com o inversor ATV, a rede PMC atingiu 61,17% de precisão, confundindo 205 dados com falha severa.

Ainda considerando a multiclassificação de falhas, a rede FAM apresentou menor tempo de processamento em todas as análises em relação a rede PMC.

Comparando-se o resultado global de precisão dos três inversores, as análises com o inversor MM440 foram as que apresentaram melhores resultados de precisão.

Portando, os resultados obtidos neste trabalho comprovam a viabilidade do método proposto para a classificação simples e a multiclassificação da severidade de falhas de rolamento em motores de indução trifásicos.

6.1 Perspectivas para trabalhos futuros

Os trabalhos futuros relacionados a esta pesquisa, tem o intuito de aperfeiçoar os métodos aqui propostos. Por tanto, a partir dos resultados obtidos neste trabalho sugere-se as seguintes perspectivas:

- Aplicar a metodologia deste trabalho para a identificação de outros tipos de falhas presentes em MIT e aperfeiçoar o método para a multiclassificação geral de falhas;
- Desenvolver métodos para diagnóstico de falhas durante o regime transitório de máquinas acionadas por inversores de frequência;
- Implementar o sistema de diagnóstico em *hardware*;

REFERÊNCIAS

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.

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

BONES, B. **Manutenção e limpeza dos rolamentos**. 2011. Disponível em: <<http://localzonly-wordpress.com/2011/06/28/manutencao-e-limpeza-de-rolamentos/>>. Acesso em: 20 de novembro de 2016.

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

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 ELECTRIC MACHINES & DRIVE CONFERENCE (IEMDC), 2007. **Proceedings...** [S.I.:s.n], 2007. p.1440-1445.

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.

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.. **Deteção 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: <<http://ecatalog.weg.net/files/wegnet/WEG-motorcom-sistema-de-levantamento-das-escovas-folheto-50042391-catalogo-portugues-br.pdf>>. Acesso em: 20 de novembro de 2016.