

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
ENGENHARIA ELÉTRICA

FERNANDO BONFIM MARTINS

**UTILIZAÇÃO DA WAVELET PACKAGE PARA CLASSIFICAÇÃO DE
FALHAS DE ROLAMENTO EM MOTORES DE INDUÇÃO TRIFÁSICOS
ACIONADOS POR INVERSORES DE FREQUÊNCIA**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO
2020

FERNANDO BONFIM MARTINS

**UTILIZAÇÃO DA WAVELET PACKAGE PARA CLASSIFICAÇÃO DE
FALHAS DE ROLAMENTO EM MOTORES DE INDUÇÃO TRIFÁSICOS
ACIONADOS POR INVERSORES DE FREQUÊNCIA**

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
2020



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



FOLHA DE APROVAÇÃO

Fernando Bonfim Martins

Utilização da Wavelet Package para classificação de falhas de rolamentos em motores de indução trifásicos acionados por inversores de frequência

Trabalho de conclusão de curso apresentado às 14:00hs do dia 29/10/2020 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). Dr(a). Márcio Mendonça - (Membro)

RESUMO

MARTINS, Fernando B. **Utilização da *Wavelet Package* para a classificação de falhas de rolamentos em motores de indução trifásicos acionados por inversores de frequência.** 2020. 43 f. Proposta de trabalho de conclusão de curso (graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2020.

Esta proposta de trabalho de conclusão de curso propõe um estudo referente a identificação de falhas de rolamentos em motores de indução trifásicos acionados por inversores de frequência. O trabalho utiliza a transformada *wavelet* e a Análise de componentes principais como método de pré-processamento de sinais de corrente do motor. Para efetuar a classificação das falhas serão utilizadas a rede *Fuzzy ARTmap* e a rede *Perceptron* Multicamadas.

Palavras-chaves: Motores de indução trifásico. Falhas de rolamento. Transformada *Wavelet*. Análise de componentes principais. Redes neurais artificiais.

ABSTRACT

MARTINS, Fernando B. **Use of Wavelet Package for the classification of bearing failure in three-phase induction motors driven by frequency inverters.** 2020. 43 f. Proposal of work of school conclusion (graduation) – Electrical Engineering. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2020.

The aim of this work was to identify the bearing failures in three-phases induction motors driven by frequency inverters. The study was carried out using the wavelet transform and the Principal Components Analysis as a method of preprocessing the motor current signals. Besides, the Fuzzy ARTmap and the Multilayer Perceptron networks were applied in order to faults classify.

Keywords: Three-phase induction motors. Bearing failures. Wavelet transform. Principal components analysis. Artificial neural networks.

LISTA DE FIGURAS

Figura 1 – Motor de indução trifásico, W22 IR4 Super premium, WEG	14
Figura 2 - Componentes de um rolamento.	17
Figura 3 – Localização do rolamento no MIT.	18
Figura 4 – Exemplo de uma falha distribuída.	19
Figura 5 – Exemplo de um defeito localizado.	20
Figura 6 – Representação tempo x frequência DWT.	23
Figura 7 – Decomposição multinível por transformada wavelet packet.	24
Figura 8 – Representação de uma rede PCM.	27
Figura 9 – Fluxograma de pré-processamento e classificação de falhas.	34
Figura 10 – Resultado das precisões globais das redes neurais.	43

LISTA DE TABELAS

Tabela 1 – Porcentagem de falhas mecânicas internas.....	17
Tabela 2 – Porcentagem de falhas mecânicas internas.....	21
Tabela 3 – Parâmetros e características do MIT.....	31
Tabela 4 – Parâmetros e características dos inversores.....	32
Tabela 5 – Quantidade de aquisições por defeitos.	32
Tabela 6 – Especificações do Rolamento.	33
Tabela 7 – Parâmetros da rede Perceptron.	35
Tabela 8 – Topologia PMC – Classificação simples.....	36
Tabela 9 – Topologia PMC – Multiclassificação.....	36
Tabela 10 – Classificação Simples.....	37
Tabela 11 – Multiclassificação.....	37
Tabela 12 – Topologia FAM.	37
Tabela 13 – Matriz confusão – MM440.	38
Tabela 14 – Matriz confusão – G110.	39
Tabela 15 – Matriz confusão – ATV.	39
Tabela 16 – Matriz confusão multiclassificador – MM440.	40
Tabela 17 – Matriz confusão multiclassificador – G110.	41
Tabela 18 – Matriz confusão multiclassificador – ATV.	42

LISTA DE ABREVIATURAS

FAM	<i>Fuzzy ARTmap</i>
MIT	Motor de Indução Trifásico
PCA	<i>Principal Component Analysis</i>
PMC	<i>Perceptron Multicamadas</i>

SUMÁRIO

1	INTRODUÇÃO.....	10
1.1	DELIMITAÇÃO DO TEMA.....	12
1.2	PROBLEMAS E PREMISSAS.....	12
1.3	OBJETIVOS.....	12
1.3.1	Objetivos gerais.....	13
1.3.2	Objetivos específicos.....	13
2	FUNDAMENTAÇÃO TEÓRICA.....	14
2.1	MOTOR DE INDUÇÃO TRIFÁSICO.....	14
2.1.1	Acionamento por inversor de frequência.....	15
2.2	DIFERENÇA ENTRE DEFEITO E FALHA.....	15
2.3	FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICO.....	16
2.3.1	Falhas de Rolamento.....	17
2.4	VIDA ÚTIL DOS ROLAMENTOS.....	20
2.5	DETECÇÃO DE FALHAS.....	21
2.5.1.	Transformada Wavelet.....	22
2.5.1.1	Decomposição Wavelet Packet.....	23
2.5.2	Análise de Componentes Principais.....	24
2.5.2.1	Definição de Componentes Principais.....	25
2.6	CLASSIFICAÇÃO INTELIGENTE DE FALHAS.....	25
2.6.1	Redes Neurais.....	25
2.6.1.1	Rede Perceptron Multicamadas.....	26
2.6.1.2	Rede FUZZY ARTmap.....	28
3	METODOLOGIA.....	31
3.1	Banco de Dados.....	31
3.2	Aquisição de Falhas – Desgastes nos Rolamentos.....	32

3.3	Pré-processamento e Classificação.....	33
3.3.1	Estrutura de pré-processamento.....	34
3.3.2	Estrutura de Classificação de Dados.....	35
4	RESULTADOS EXPERIMENTAIS.....	38
4.1	<i>WAVELET</i> – Classificação Simples.....	38
4.2	<i>WAVELET</i> – Multiclassificação.....	40
5	ANÁLISE DOS RESULTADOS EXPERIMENTAIS.....	43
6	CONSIDERAÇÕES FINAIS.....	45
	REFERÊNCIAS.....	46

1 INTRODUÇÃO

A concorrência no setor industrial aumenta diariamente com uma economia de mercado tão globalizada, acarretando assim numa busca maior pela diminuição dos custos e o aumento da qualidade, e que por consequência levam as máquinas a trabalharem de maneira ininterrupta. Devido a esse alto grau de produtividade, as paradas geram grandes prejuízos. Portanto, é de suma importância que ocorra uma otimização do uso das técnicas de manutenção.

De acordo com ARAÚJO (2011), os custos de manutenção representam a maior parte dos custos operacionais das plantas industriais, que em alguns casos, correspondem entre 15% a 30% dos custos dos bens produzidos. Devido a esta posição de relevância que a manutenção ocupa, vem se buscando constantemente diminuir os custos e aprimoramento das técnicas de detecção de falhas.

No setor industrial os motores de indução trifásicos (MIT) são amplamente utilizados, e são responsáveis por aproximadamente 68% do consumo de energia elétrica desta área (SAUER et al., 2015). O MIT é uma máquina que é bastante susceptível a falhas, pois ele está sempre sendo sujeito aos mais variados tipos de ambientes operacionais prejudiciais, como os esforços térmicos, elétricos e mecânicos, que contribuem de forma expressiva para a ocorrência da falha (ARAÚJO, 2011).

Estudos sobre a confiabilidade dos motores mostram que o rolamento é o componente que mais sofre com avarias durante a operação do motor de indução. Uma publicação de Bellini et al., (2008), mostra uma estatística de falha em motores elétricos, na qual 69% das falhas acontecem nos rolamentos.

Assim, para ajudar na melhoria da qualidade de manutenção, este trabalho irá realizar uma classificação inteligente das falhas nos motores elétricos de indução trifásicos, que são acionados por inversores de frequência, por meio de uma técnica não invasiva, utilizando os dados de corrente em regime permanente.

1.1 DELIMITAÇÃO DO TEMA

Devido ao fato das falhas nos rolamentos serem as principais responsáveis por ocasionar paradas nos motores elétricos de indução trifásicos, por meio da transformada *wavelet* e da análise de componentes principais, será realizado o pré-processamento dos sinais de corrente coletados, com o intuito de identificar falhas em motores, e posteriormente por intermédio da rede *Fuzzy ARTmap* e da rede *Perceptron* Multicamadas, realizar a classificação dessas falhas.

1.2 PROBLEMAS E PREMISSAS

Como o motor de indução trifásico é amplamente utilizado no setor industrial, ele requer uma atenção especial, pois qualquer parada inesperada dele, decorrente de algum defeito, pode acarretar em um grande prejuízo financeiro.

Diante das informações de consumo, está existindo uma busca crescente por processos mais racionais e econômicos, no que diz respeito a utilização eficiente da energia elétrica, visando principalmente a otimização das técnicas de manufaturas, e por consequência o MIT. Baseado nisso, este trabalho propõe-se a elaborar um método que identifica falhas de maneira precoce nos rolamentos dos motores, assim possibilitando uma programação de manutenções para que se possa realizar os ajustes necessários.

1.3 OBJETIVOS

Os objetivos gerais e específicos deste trabalho de conclusão de curso são descritos nas seções abaixo, buscando evidenciar os resultados que são esperados ao final do trabalho.

1.3.1 Objetivos gerais

O objetivo geral desse trabalho é realizar a classificação falhas de rolamentos em motores elétricos de indução trifásicos acionados por inversores de frequência.

1.3.2 Objetivos específicos

Os objetivos específicos são os listados abaixo:

- analisar sinais de corrente em motores elétricos de indução trifásicos com falhas;
- realizar o pré-processamento destes sinais através da transformada *wavelet* e análise de componentes principais, utilizando o *software* MATLAB®;
- diagnosticar falhas de rolamentos empregando as redes *Fuzzy* ARTmap e *Perceptron* Multicamadas.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão desenvolvidos os conceitos para o entendimento do trabalho.

A classificação inteligente de falhas requer um pré-processamento dos sinais de corrente, o qual vai ser realizado através da aplicação da transformada *wavelet*, com o propósito de verificar-se as características dos sinais de uma máquina com falha.

2.1 MOTOR DE INDUÇÃO TRIFÁSICO

Os motores de indução trifásicos tornaram-se equipamentos indispensáveis na maioria dos processos do setor produtivo, pelo fato de serem robustos e principalmente por possuírem um menor preço (SUETAKE, 2012).

Com relação ao aspecto construtivo, ele é constituído por um rotor, entreferro e um estator, onde o rotor e o estator não possuem nenhuma conexão física. No estator situa-se o enrolamento de armadura, o qual é alimentado por uma corrente alternada, e que por consequência induz correntes no rotor. Apesar dos fluxos do rotor e estator girarem em sincronismo, o rotor não gira em sincronismo com o fluxo de armadura, o que acaba gerando o escorregamento (FITZGERALD; KINGSLEY; UMANS, 2003).

A Figura 1, representa um motor de indução trifásico:

Figura 1 – Motor de indução trifásico, W22 IR4 Super premium, WEG



Fonte: (WEG, 2013b).

O rotor de um motor de indução trifásico pode ser de dois tipos, bobinado ou gaiola de esquilo. A extrema simplicidade e a robustez da construção em gaiola de esquilo representam vantagens notáveis para esse tipo de motor de indução (FITZGERALD; KINGSLEY; UMANS, 2003).

2.1.1 Acionamento por inversor de frequência

Com o progresso das tecnologias na área de eletrônica de potência, a presença dos inversores de frequência nos acionamentos industriais tem crescido de forma bastante considerável, pelo fato que eles podem oferecer uma proteção contra sobrecarga no motor, sobrecorrente, sobretensão/subtensão, além proteção contra altas temperaturas (FAIZ; GHORBANIAN; EBRAHIMI, 2012b).

O acionamento realizado por inversor de frequência permite realizar o controle da velocidade de rotação de um motor de indução. Os inversores recebem a tensão da rede, que possuem amplitude e frequência constantes, e apresentam em sua saída tensões com amplitudes e frequências variáveis.

2.2 DIFERENÇA ENTRE DEFEITO E FALHA

Frequentemente os conceitos de falha e defeito se confundem e diante disso esta seção do trabalho estará dedicada a esclarecer as principais diferenças dos mesmos.

- Falha: Término da condição (habilidade) ou a impossibilidade de um item realizar sua função requerida. O aparecimento de uma falha leva o item, invariavelmente, ao estado indisponível, por atuação automática de proteção ou por desligamento imediato da unidade devido ao caráter de urgência. Exemplo: A quebra do dente de uma engrenagem, para o funcionamento de uma máquina.

- Defeito: Alteração ou imperfeição do estado de um equipamento/instalação, não ao ponto de causar o término da habilidade em realizar a função requerida, já que a instalação/equipamento ainda pode operar com restrições. Neste caso, programa-se a realização de uma manutenção preventiva, “denominada manutenção preventiva não sistemática”, para evitar que o sistema chegue a falhar. Exemplo: Queima do giroflex de uma empilhadeira, necessita consertar, porém a empilhadeira funciona normalmente.

2.3 FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICO

Devido a relevância que o MIT ganhou no setor industrial, os estudos referentes a ele conseqüentemente também cresceram na mesma proporção, principalmente no que diz respeito à melhoria do seu desempenho, controle mais preciso, manutenção preventiva, detecção de falhas e eficiência energética.

Mesmo com características relevantes citadas anteriormente, os motores elétricos são acometidos por falhas que são inerentes às máquinas, que são um conjunto de um envelhecimento natural, com as diversas condições ambientais, operando sob vários tipos de cargas, que o motor é submetido (SUETAKE, 2012).

Diante dessa situação, com o intuito de evitar os danos, e conseqüentemente diminuir os custos de manutenção, assim como evitar o desligamento do setor industrial o qual a máquina está instalada, o monitoramento com a finalidade de detectar falhas no seu estágio inicial se torna imprescindível (DRIF; CARDOSO, 2007).

As principais falhas que um MIT está sujeito são distinguidas em falhas externas e internas, na qual as externas são divididas em falhas de natureza elétrica, mecânica e ambiental. Já as internas são separadas em mecânicas e elétricas (BELLINI et al., 2008). É nesse grupo de falhas internas mecânicas, que compreende falhas de rolamentos, excentricidade e desgaste de acoplamento, que está situado nosso objeto de estudo.

De acordo com Bellini et al. (2008), a porcentagem de falhas internas mecânicas, podem ser separadas segundo a tabela 1.

Tabela 1 – Porcentagem de falhas mecânicas internas.

Componente	Falhas
Rolamentos	69%
Estator	21%
Anéis/Barras do rotor	7%
Eixo/Acoplamento	3%


Com os dados observados na tabela, fica evidente o tamanho da proporção de falhas no rolamento no MIT, o que explica a importância da identificação dessas falhas no seu estágio inicial.

2.3.1 Falhas de rolamento

O rolamento constitui o componente que é mais afetado pela ocorrência de falhas em motores de indução trifásico. Ele tem como função sustentar o eixo e substituir o atrito que existe entre o eixo e o mancal, por uma fricção rolante.

Um rolamento é constituído por uma pista externa, pista interna, esferas, gaiola e escudo, que pode ser verificado na Figura 2.


Figura 2 - Componentes de um rolamento.



Fonte: Adaptado de Silva (2008).

Para as indústrias, a manutenção de rolamentos é um desafio. Somente 10% a 20% dos rolamentos alcançam sua vida útil projetada. A manutenção corretiva, no caso a substituição do rolamento defeituoso, é a ação mais barata, se comparada as outras a outros casos de falhas, porém é a mais complicada de se realizar (SILVA, 2008).

Figura 3 – Localização do rolamento no MIT.



Fonte: Adaptado de Romaco (2011).


De maneira geral, dificilmente os rolamentos falham devido ao próprio trabalho, eles falham normalmente em decorrência de fatores externos. Dentre os fatores, os principais são:

- Insuficiência de lubrificação;
- Uso de lubrificantes errados;
- Contaminação por sujeiras e outras partículas estranhas;
- Desalinhamento mecânico do eixo;
- Exposição a umidade;
- Sobrecarga mecânica;
- Montagem imprópria do rolamento da máquina.

Comumente, defeitos em rolamentos são verificados por meio das vibrações geradas pelos mesmos. Estes defeitos podem ser separados em dois grupos: defeitos distribuídos e defeitos localizados (SILVA, 2008).

Os defeitos distribuídos se referem as avarias generalizadas, que não estão em algum lugar específico. Na Figura 4, é possível observar um exemplo disso, onde ocorreu o escamamento ao longo da pista por causa de um desalinhamento durante a instalação.

Figura 4 – Exemplo de uma falha distribuída.



Fonte: NSK DO BRASIL.

Os defeitos localizados são os que estão presentes em locais mais específicos e podem ser vistos ao longo do rolamento. Eles podem ser caracterizados como rachaduras, cavidades ou buracos. Na Figura 5, pode-se observar um exemplo de defeito localizado, onde existe uma trinca na superfície da pista, decorrente de uma grande tensão do ajuste gerada pela diferença de temperatura entre o anel interno e o eixo.

Figura 5 – Exemplo de um defeito localizado.



Fonte: NSK DO BRASIL.

A partir do momento em que o motor tem início a algum tipo de falha ele começa a apresentar indícios de defeitos de inúmeras formas, como: mudanças nos sinais ligados as vibrações mecânicas, variação na temperatura de operação, ruídos audíveis, dentre outras (ARAÚJO, 2011). Diante disso, a técnica de processamento de sinais pode ser utilizada para realizar a detecção de falhas (GODOY, 2016).

2.4 VIDA ÚTIL DOS ROLAMENTOS

A vida útil dos rolamentos é determinada pelo número de rotações (ou números de horas de operação) em uma estipulada velocidade que o rolamento pode resistir antes do primeiro sinal de fadiga do metal aparecer na pista do anel ou em um elemento rolante (SKF).

De acordo com a SKF, as estimativas da vida útil do rolamento com base na fadiga de contato rolante não são muito precisas, pois testes em rolamentos aparentemente idênticos em condições de operações idênticas resultam em tempos de fadiga de metal diferentes, por isso é necessária uma abordagem estatística para determinar o tamanho da vida útil do rolamento.

A estimativa de desgaste dos rolamentos é determinada pela ISO 281, que com o passar dos anos foi submetida a revisões técnicas, devido ao avanço

da tecnologia de projeto, produção, materiais e tratamentos térmicos. Entretanto, a norma ainda deixa algumas lacunas referentes a não quantificação de alguns fatores da formulação da vida útil dos rolamentos, e por isso a indústria de rolamentos, por meio dos seus maiores representantes, criaram formulações próprias, a princípio, sem relação com a norma ISO em vigor, para buscar solucionar esse problema (CAMPANHA, 2008).

A empresa SKF, que é uma das maiores do segmento, baseada em suas formulações fez sua estimativa levando-se em conta principalmente o tipo de aplicação da máquina, e alguns exemplos são mostrados na Tabela 2, que pode ser vista logo abaixo:

Tabela 2 – Porcentagem de falhas mecânicas internas.

TIPO DE MÁQUINA	ESPECIFICAÇÃO DA VIDA ÚTIL (horas)
Máquinas agrícolas	300 até 3000
Guincho de elevação em oficinas	3000 até 8000
Elevadores	8000 até 12000
Máquinas para uso 8h por dia	10000 até 25000
Máquinas para uso 24h por dia	40000 até 50000
Máquinas de usina de geração de energia	100000 até 200000

Fonte: Site da SKF.

2.5 DETECÇÃO DE FALHAS

Existem inúmeros métodos disponíveis atualmente que podem ser utilizados para detectar falhas em motores de indução. De acordo com REIS (2010), esses métodos são separados em dois grupos, os que possuem uma abordagem invasiva, e os que possuem a abordagem não invasiva. Em virtude da facilidade e baixo custo de implementação, de não necessitar parar o motor para coletar informações, a técnica não invasiva é a que apresenta um futuro mais promissor.

O sinal de corrente será utilizado neste trabalho para realizar o diagnóstico de falhas. Segundo OLIVEIRA (2007), o processo de análise do sinal e extração das características relevantes, é considerado a principal etapa nesse método de detecção de falhas.

A transformada *wavelet* (TW) será responsável por realizar a análise do sinal neste trabalho. A TW permite representar o sinal em diferentes resoluções de tempo e frequência, criando um conteúdo espectral que se modifica com o tempo (BELLINI et al., 2008; BENBOUZID, 2000).

No momento em que um motor apresenta alguma falha, o espectro de corrente verificado se torna diferente do espectro de corrente de um motor saudável, dessa forma é possível fazer o diagnóstico da falha (VITOR, 2015).

2.5.1. Transformada Wavelet

A transformada *wavelet* é uma função capaz de decompor e descrever um sinal no domínio do tempo e da frequência, de modo a permitir uma análise desse sinal em várias escalas de frequência e de tempo, e pode ser definida como:

$$c(s, \tau) = \int_{-\infty}^{\infty} f(t) \varphi(t)_{s,\tau} dt \quad (1)$$

A função $\varphi(t)_{s,\tau}$ é gerada a partir de uma função $\varphi(t)$, denominada *wavelet* mãe, e pode ser definida por:

$$\varphi(t)_{s,\tau} = \frac{1}{\sqrt{s}} \varphi\left(\frac{t-\tau}{s}\right) \quad (2)$$

O parâmetro τ representa o deslocamento no espaço/tempo, e o parâmetro s é o fator de escala.


De acordo com MURILO (2003), a principal vantagem da TW é a sua capacidade de fazer uma análise local, isto é, realizar uma análise de um sinal

em um ponto específico. E quando tratasse de sinais elétricos, ela é capaz de localizar o momento preciso em que ocorreram os eventos transitórios.

2.5.1.1 Decomposição Wavelet Packet

A decomposição *wavelet packet* (DWT) permite uma análise de sinais em diferentes resoluções na frequência e no tempo, por meio de um janelamento variável, que pode ser visto na figura 6. Através de janelas curtas de alta frequência, pode-se verificar as discontinuidades no sinal.

Figura 6 – Representação tempo x frequência DWT.



Fonte: Adaptado de Biagi (2014).

A decomposição é obtida através da convolução do sinal e um par de filtros. O sinal $x[n]$ passa pelos filtros passa-alta, $h[n]$, e passa-baixa, $g[n]$, que são respectivamente componentes de aproximação e detalhe. Ambos os filtros podem ser representados pelas equações (4) e (5).

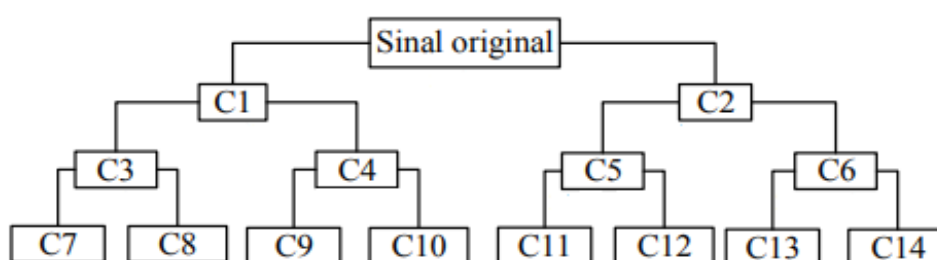
$$a[n] = x[n] * g[n] = \sum_{k=0}^{N-1} g[k] \cdot x[2n - k] \quad (3)$$

$$d[n] = x[n] * h[n] = \sum_{k=0}^{N-1} h[k] \cdot x[2n - k] \quad (4)$$

O filtro passa-baixa remove todas as componentes de alta frequência, restando somente uma representação mais suave o sinal original. Já o filtro

passa-alta elimina todas as componentes de baixa frequência do sinal, mostrando apenas as componentes de alta frequência. Na Figura 7 como resultado dessas operações, obtêm-se duas saídas, as quais respectivamente representam os coeficientes de aproximação (C1) e detalhes (C2) referentes ao primeiro nível. Decomposições em níveis seguintes são obtidas realizando o mesmo processo em cascata, e novos coeficientes são verificados (VITOR, 2015).

Figura 7 – Decomposição multinível por transformada wavelet packet.



Fonte: Adaptado de Biagi (2014).

O processo inverso da decomposição reconstruirá o sinal original, por meio da utilização dos componentes *wavelets* (BIAGI, 2014).

2.5.2 Análise de Componentes Principais

A partir dos sinais provenientes de uma máquina é possível verificar a condição em que um equipamento se encontra, mas esse diagnóstico não é uma tarefa tão simples. A análise de componentes principais (PCA) vem para facilitar esse processo, pois através dela é possível processar todas as características de falhas e posteriormente separar as que são mais significativas para a solução (SILVA, 2008).

A PCA é um método estatístico que busca reduzir a dimensionalidade de um conjunto de dados, onde há um grande número de variáveis inter-relacionadas. Essa redução é efetuada de forma a conseguir um novo e reduzido conjunto de variáveis não correlacionadas, denominadas componentes

principais. Em seguida as componentes são ordenadas de forma que as primeiras tenham a maior parte de variância (SILVA, 2008).

2.5.2.1 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:

$$a'_1x = \sum_{j=1}^p a_1 x_j \quad (5)$$

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).

2.6 CLASSIFICAÇÃO INTELIGENTE DE FALHAS

Esta proposta de trabalho considera a utilização dos classificadores *Fuzzy ARTmap* e *Perceptron* Multicamadas, que serão descritas adiante.

2.6.1 Redes Neurais

Redes neurais artificiais (RNA's) são métodos computacionais baseados no funcionamento do sistema nervoso dos seres vivos. Estas redes são feitas por um grupo de neurônios artificiais interligados (SILVA; SPATTI; FLAUZINO, 2010). Elas surgiram como um novo paradigma de programação para a computação, que são capazes de inserir um paralelismo em um processamento computacional, no qual cada neurônio pode ser considerado uma entidade que realiza determinado processamento (VIEIRA et al., 2003).

Na sua arquitetura, as redes neurais são organizadas em camadas, as quais são classificadas em três grupos: camada de entrada, onde os padrões são apresentados à rede, camadas intermediárias, onde é realizada a grande parte do processamento por meio das conexões ponderadas, e a camada de saída, que é onde o resultado final é concluído e apresentado (CARPENTER; GROSSBERG, 1987a).

No âmbito da classificação das falhas em máquinas elétricas, as RNA's têm se tornado base de importantes pesquisas recentes (GODOY, 2016). Isso se deve ao fato que as RNA's apresentam um melhor desempenho comparado aos modelos convencionais, visto que estas redes tem a capacidade de aprender e principalmente generalizar o conhecimento adquirido (GONGORA, 2013).

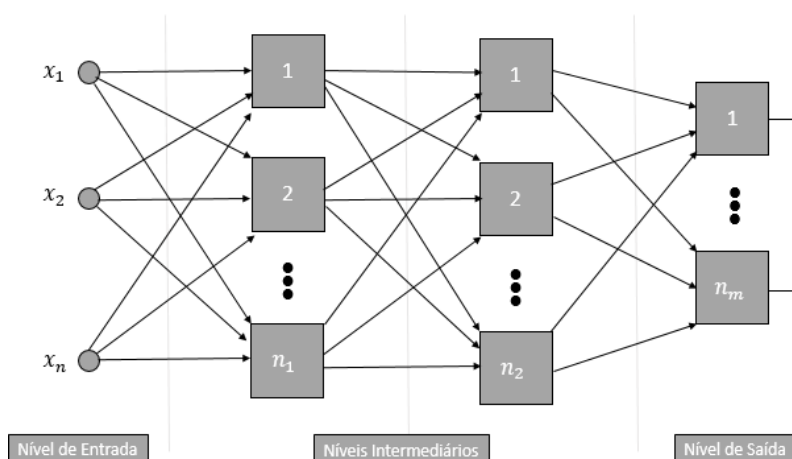
2.6.1.1 Rede Perceptron Multicamadas

A rede *perceptron* Multicamadas (PCM) é caracterizada por possuir pelo menos uma camada intermediária de neurônios, entre a camada de entrada e a camada de saída (SILVA; SPATTI; FLAUZINO, 2010).

De acordo com Silva, Spatti e Flauzino (2010), as RNA's são compostas por três camadas, que são descritas logo abaixo e podem ser vistas na Figura 8.

- Camada de entrada: recebe os sinais de entrada da rede.
- Camadas intermediárias: retiram informações inerentes ao sistema.
- Camada de saída: fornece os sinais processados a rede.

Figura 8 – Representação de uma rede PCM.



Fonte: Autoria Própria.

Para o ajuste de peso e do limiar de cada neurônio da rede PCM é realizado um treinamento supervisionado, para que com cada amostra de dados de entrada consiga-se obter a saída desejada (SILVA; SPATTI; FLAUZINO, 2010).

É utilizado normalmente o algoritmo de aprendizagem *blackpropagation*, para o processo de treinamento da rede PCM. Na primeira etapa desse treinamento, que é denominada *forward*, os dados de entrada são propagados por todas as camadas até a saída. Na segunda etapa, denominada *backward*, acontece o processo inverso, onde o valor de saída é retornado à entrada.

Quando se encerra a primeira etapa, é verificado se o valor de saída é próximo da saída desejada. Caso esse valor de saída não esteja dentro da variação estimada, inicia-se a segunda etapa, de modo a retropropagar o erro camada por camada, assim ajustando os pesos sinápticos dos neurônios (GODOY, 2016).

Este procedimento é repetido até que se obtenha o valor dentro de uma faixa de variação estipulada.

2.6.1.2 Rede FUZZY ARTmap

Desenvolvida por Carpenter e Grossberg (1987), a rede *Fuzzy ARTmap* (FAM) tem como base a teoria da ressonância adaptativa (ART). Ela tem como principal característica a estabilidade e a plasticidade, pois quando se insere novos padrões na rede, ela continua a aprender sem perder informações referentes aos padrões anteriores (CARPENTER, 1992).

A estrutura da rede é caracterizada 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).

A rede FAM contém 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 a saída desejada. Estes vetores de entrada são normalizados e complementados, e são representados por um vetor $I^a = [\underline{a} \ \underline{c}]$ e $I^b = [\underline{b} \ \underline{c}]$ (CARPENTER et al., 1992).

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

Segundo Carpenter et al. (1992), os parâmetros utilizados na FAM são 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 I^a e I^b (CARPENTER, 1992):

$$T_j^a = \frac{|I^a \wedge W_j^a|}{\alpha + |W_j^a|} \quad (6)$$

$$T_k^b = \frac{|I^b \wedge W_k^b|}{\alpha + |W_k^b|} \quad (7)$$

Logo após o início calcula-se a categoria ativa e o processo de escolha é inicializado. O maior valor para a função de escolha da categoria é escolhido através do processo de competição, e posteriormente verifica-se a condição de ressonância (KASUBA, 1993).

$$\frac{|I^a \wedge W_{jv}^a|}{|I^a|} \geq \rho_a \quad (8)$$

$$\frac{|I^b \wedge W_{kv}^b|}{|I^b|} \geq \rho_b \quad (9)$$

Diante disso, se a condição de ressonância não for atendida, o mecanismo *reset* é acionado, outra categoria é escolhida e o processo de validação da ressonância é iniciado novamente.

Com a condição de ressonância satisfeita, inicia-se outro processo, que é o processo de aprendizado, onde acontece a adaptação dos pesos, de acordo com as equações (10) e (11) (KASUBA, 1993).

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

$$W_{kv}^b(novo) = \beta(I^b \wedge W_{kv}^b(antigo)) + (1 - \beta)W_{kv}^b(antigo) \quad (11)$$

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

A FAM será utilizada neste trabalho com o intuito de classificar padrões, auxiliando na identificação de falhas nos rolamentos.

2.7 TRABALHOS CORRELATOS

Além da análise do sinal de corrente elétrica dos motores para se identificar falhas nos rolamentos, também existem outras maneiras para realizar esse diagnóstico de rolamentos danificados, como a análise espectral de vibração e o estudo termográfico.

De acordo com ARAÚJO (2010) a análise de vibração, por questões relacionadas a custos de manutenção, é bastante utilizada nas empresas. O rolamento que é composto por quatro elementos, quando ele inicia sua atividade, cada elemento gera uma frequência própria, que no caso é a frequência do anel externo, frequência do anel interno, frequência da gaiola e frequência dos corpos rolantes. E com base nessas frequências já conhecidas, torna-se possível analisar o espectro de vibração e determinar a presença de defeitos.

Outra maneira de detecção de falhas que é o estudo termográfico se utiliza de câmaras termográficas para realizar esse diagnóstico. Como muitas falhas são ocasionadas pelo contato físico entre os metais que estão em movimento um em relação ao outro, no instante que ocorre esse contato, inicia-se uma geração de calor, que nesse momento é captado pelas tais câmaras termográficas e então é verificada a falha (CABRAL, 2017).

3 METODOLOGIA

Este trabalho propõe um método de detecção de falhas de rolamentos através da análise do sinal de corrente, levando-se em conta que o motor utilizado foi acionado por 3 inversores de frequência diferentes.

Por meio de ensaios laboratoriais que simulam um meio ambiente industrial é possível a realização de uma análise dos defeitos causados no motor por conta das condições de operação do mesmo em conjunto com as falhas mencionadas anteriormente.

Na próxima seção serão apresentadas as características do motor, assim como os métodos de análises que serão utilizadas para classificação.

3.1 Banco de Dados

Na Tabela 3 é possível verificar os parâmetros e as características básicas do motor utilizado para aquisição de dados deste trabalho.

Tabela 3 – Parâmetros e características do MIT.

Parâmetros	Motor
Motor	WEG
Potência (kW)	0,74
Frequência (Hz)	60
Tensão de Alimentação (V)	220/380
Corrente de Alimentação (A)	3,02/1,75
Números de pólos	4
Números de ranhuras	36
fases rebobinadas	-
Nível de curto circuito (%)	-
Velocidade (rpm)	1730
Torque nominal (N.m)	4,1
Números de barra de rotor	44

Na Tabela 4 é possível verificar as características dos inversores que foram utilizados no acionamento do motor.

Tabela 4 – 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

Na Tabela 5 é apresentada a quantidade total de dados e as características obtidas a partir do banco de dados.

Tabela 5 – Quantidade de aquisições por defeitos.

Motor	Condição	Sinamics G110	Micromaster MM440	ATV12H075M2
Motor (0,74 kW)	Rotor Saudável	70	73	62
	Desgaste 15 minutos	74	74	78
	Desgaste 30 minutos	74	74	78
	Desgaste 60 minutos	74	74	78
	Desgaste 90 minutos	74	74	78

Nos dados presentes na Tabela 5 a frequência síncrona com que os inversores estão operando varia na faixa de 12 a 60 Hz. Quanto ao torque aplicado no motor para cada experimento variou-se em 0,5 – 1, 0-1,5, 2,0-2,5, 3,0-3,5, 4,0-4,5 e 5 N.m (GODOY, 2016).

3.2 Aquisição de Falhas – Desgastes nos Rolamentos

Para obter-se uma falha causada por um desgaste gradual dos rolamentos ao longo do tempo, foram induzidas falhas de desgastes aos

mesmos, para então se desenvolver o banco de dados conforme o que foi verificado na Tabela 5.

Foi realizada a troca do lubrificante por pasta abrasiva, que por consequência contaminou os rolamentos após a retirada da proteção lateral e blindagens (GODOY, 2016).

No momento da aquisição de falhas o motor foi acionado diretamente a rede e operava a vazio. As falhas tiveram a classificação: inicial, média, avançado e severa. Respectivamente, essas falhas tiveram os seguintes tempos relacionados: 15, 30, 60 e 90 minutos.

As especificações dos rolamentos rígidos de esferas, modelo NSK 6204 pode ser vista na tabela a seguir (GODOY, 2016):

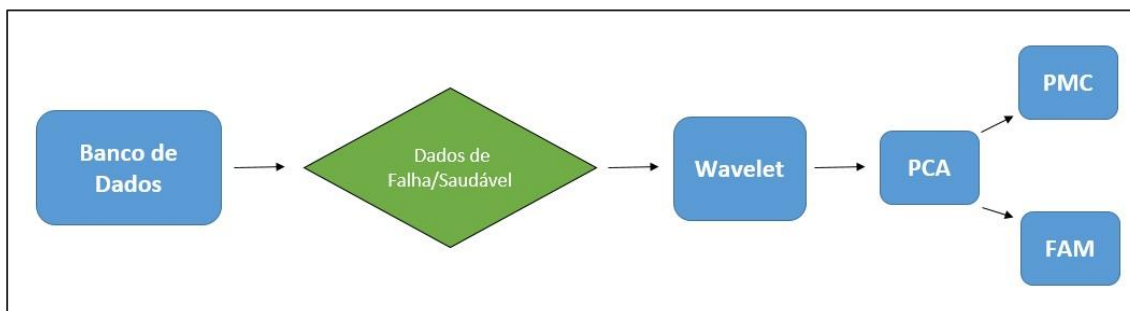
Tabela 6 – Especificações do Rolamento.

Parâmetros	Especificações
Diâmetro 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

3.3 Pré-processamento e classificação

O método utilizado para realizar o pré-processamento dos sinais de corrente, provenientes do banco de dados, assim como as redes neurais utilizadas para realizar a classificação das falhas estão apresentadas a seguir, de acordo com o fluxograma.

Figura 9 – Fluxograma de pré-processamento e classificação de falhas.



Fonte: Autoria própria.

3.3.1 Estrutura de pré-processamento

Para a realização da classificação das falhas nos MIT's são utilizados métodos de pré-processamentos de dados, e no caso deste trabalho o banco de dados possui sinais de corrente tanto de motor saudável como com falha. Trata-se de dados das correntes trifásicas dos motores, sendo que para o pré-processamento e para as classificações é utilizada somente uma das fases.

Nas condições em que existe uma grande quantidade de variáveis de entrada para as redes neurais utilizadas, mas que suas componentes são linearmente dependentes, é recomendado reduzir o número de variáveis de entrada. Nestas condições foi aplicada a PCA, que por consequência produz os seguintes resultados: 1) torna os vetores de entrada linearmente independente, devido a ortogonalização; 2) ordenação em ordem decrescente dos componentes de maior variação; 3) eliminação dos componentes que menos contribui para a variação do conjunto de dados (BEALE; HAGAN; DEMUTH, 2011).

A análise de componentes principais e a transformada wavelet serão os métodos utilizados para realizar o pré-processamento de sinais. Num primeiro momento é aplicado a transformada Wavelet até o terceiro nível, que é quando se obtém a aproximação de menor frequência. Em seguida é aplicada a PCA. O critério de uso do PCA será que a variação máxima entre o valor da variância

das componentes principais seja um valor de aproximadamente 100 vezes, para que com isso adote-se as componentes que representam a maior parte do sinal.

Após a realização do pré-processamento serão utilizados os métodos de classificação para que então se verifique a presença de falhas. Os métodos de classificação serão vistos na seção seguir.

3.3.2 Estrutura de Classificação de Dados

Para a realização da classificação dos dados serão utilizadas as redes *Perceptron* Multicamadas e a *Fuzzy ARTMap*. Os dados serão divididos aleatoriamente em 2 grupos: dados de treinamento e dados de teste, numa proporção de 80% e 20%, respectivamente.

Serão feitas duas análises com cada rede. A primeira será para ver como a rede vai se comportar na classificação de dois padrões: motor com falha e motor saudável. A segunda análise será realizada considerando o motor saudável e as falhas de desgaste 15 minutos, 30 minutos, 60 minutos e 90 minutos.

Para configurar a rede a rede *Perceptron* Multicamadas serão utilizados os parâmetros contidos na Tabela 7 abaixo:

Tabela 7 – Parâmetros da rede Perceptron.

Parâmetro	Tipo Utilizado
Função de ativação da camada de entrada e camada oculta	Tangente Hiperbólica
Função de ativação da camada de saída	Rampa Linear
Algoritmo de treinamento	<i>Backpropagation com Levenberg-Marquardt</i>

A função de ativação escolhida foi baseada em testes realizadas, e a que apresentou um melhor resultado foi a tangente hiperbólica. De acordo com Godoy (2016), a função *backpropagation* tem por finalidade encontrar as derivadas da função de erro com relação aos pesos e bias da RNA.

Foram necessários realizar alguns testes para se determinar a quantidade de neurônios de cada rede. De uma maneira geral, quanto mais neurônios a rede possuir, mais capacidade de mapear os conjuntos de entrada/saída, e esse número de neurônios está intimamente ligado a capacidade de aprendizagem, no entanto neurônios em excesso podem causar problemas de generalização de aprendizagem.

A Tabela 8 representou a topologia final que apresentou o melhor resultado no caso da classificação da primeira análise:

Tabela 8 – Topologia PMC – Classificação simples.

Característica	Quantidade
Neurônios na camada de entrada	8
Neurônios na camada oculta	4
Neurônios na camada de saída	2
Neurônios nas camadas escondidas	1
Iterações máximas	100

A topologia obtida por teste para a topologia de multiclassificação pode ser vista a seguir:

Tabela 9 – Topologia PMC – Multiclassificação.

Característica	Quantidade
Neurônios na camada de entrada	15
Neurônios na camada oculta	12
Neurônios na camada de saída	5
Neurônios nas camadas escondidas	1
Iterações máximas	100

Para se determinar a classificação simples de falha/saudável, foi utilizado uma sequência, como é mostrado na tabela 10:

Tabela 10 – Classificação Simples.

Característica	Saída Desejada
Falha	0 1
Saudável	1 0

Para multiplicação o resultado para a camada de saída pode ser verificado na tabela a seguir:

Tabela 11 – Multiclassificação.

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

Para a rede *Fuzzy ARTMap* utilizou-se os mesmos parâmetros tanto para a classificação simples como na multiclassificação, que foram mostrados na tabela abaixo:

Tabela 12 – Topologia FAM.

Variável	Valor Utilizado
Vigilância (ρ)	0,75
Taxa de aprendizado (β)	1
Escolha (α)	0,001

Para evitar uma formação maior de categorias na camada de saída, que acabam degradando os resultados de classificação, foi escolhido um número pequeno para a vigilância (ρ), no caso 0,75. Como a taxa de aprendizado (β) é diretamente proporcional a velocidade de aprendizado da rede, essa taxa foi definida como sendo 1. E por fim, o parâmetro de escolha foi definido como sendo um valor próximo a zero, no caso deste trabalho será 0,001 (GODOY, 2016).

4 RESULTADOS EXPERIMENTAIS

A partir da aplicação dos métodos mencionados no capítulo anterior serão apresentados nessa seção os resultados obtidos buscando verificar a presença e a severidade de falhas em MIT's.

Para descrever quais métodos tiveram o melhor desempenho os resultados serão evidenciados via matrizes de confusões. Tais resultados são provenientes dos melhores valores obtidos em sequência de 10 testes.

4.1 WAVELET – Classificação Simples

Diferenciando-se os dados de motor com falha e dados com motor saudável a Tabela 13 expõe os resultados verificados na classificação simples. O conjunto de dados utilizado é composto por 6480 amostras. Nesse primeiro caso o motor é acionado pelo inversor MM440, e do total de amostras 5064 foram utilizadas para treinamento e 1416 para teste.

Tabela 13 – Matriz confusão – MM440.

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	297	0	268	8
Falha	0	1119	13	1127

A partir da matriz confusão apresentada na Tabela 13 verifica-se que a rede *Perceptron* Multicamadas apresenta uma precisão global de 100% quando o motor é acionado pelo inversor MM440, apresentando 100% de precisão na classificação de falha e 100% de precisão na classificação de saudável.

A rede *Fuzzy ARTMAP* obteve uma precisão global de 98,52%, sendo que para a classificação de saudável obteve uma precisão de 95,37% e para a classificação de falha uma precisão de 99,30%.

Para a classificação simples utilizando o inversor G110 para o acionamento foram obtidos os resultados que podem ser verificados na tabela a seguir. Assim como na classificação anterior também foram utilizados no total 5064 amostras para treinamento e 1416 para teste.

Tabela 14 – Matriz confusão – G110.

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	285	2	266	3
Falha	4	1125	13	1134

De acordo com a matriz confusão pode-se observar que rede *Perceptron* Multicamadas obteve uma precisão global de 99,58%, sendo que para classificar como saudável a precisão da rede foi de 98,62% e para classificar como falha a precisão foi de 99,82%.

Para esse caso a rede *Fuzzy ARTMAP* obteve uma precisão global 98,87%, sendo que para realizar a classificação de saudável a precisão foi de 95,34% e para a classificação de falha a precisão foi de 99,74%.

O último caso da classificação simples foi com o motor sendo acionado pelo inversor ATV. O conjunto de dados utilizado nesse caso é composto por 6930 amostras, das quais 5544 foram utilizados para treinamento e 1386 para teste.

Tabela 15 – Matriz confusão – ATV.

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	272	4	253	11
Falha	3	1107	8	1114

A precisão global da rede *Perceptron* Multicamadas nesse caso foi de 99,49%, sendo que a precisão para a classificação de motor saudável foi de 98,91% e na análise de motor em falha a precisão foi de 99,64%.

No mesmo contexto a rede FAM obteve uma precisão global de 98,63%, sendo que para o diagnóstico de saudável a precisão foi de 96,93% e para o diagnóstico de falha a precisão foi de 99,02%.

4.2 WAVELET – Multiclassificação

Na Tabela 16 é possível observar os dados obtidos após a realização da multiclassificação de falhas, porém agora diferenciando as severidades encontradas no motor saudável e nas falhas. Nessa primeira tabela foram considerados os dados provenientes do motor acionado pelo inversor MM440, que são os mesmos dados utilizados na classificação simples.

Tabela 16 – Matriz confusão multiclassificador – MM440.

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	CC 10%	CC 1%	CC 3%	CC 5%	CC 10%	CC 10%
CC 1%	282	0	0	0	0	291	0	0	1	0
CC 3%	0	287	0	0	0	3	286	0	1	0
CC 5%	0	0	277	0	0	0	0	275	1	0
CC 10%	0	0	0	272	0	0	0	0	278	1
S.	0	0	0	0	298	0	0	0	5	274

De acordo com a matriz confusão da Tabela 16 verificou-se que a precisão global da rede *Perceptron* Multicamadas foi de 100%, enquanto que a rede *Fuzzy ARTMAP* apresentou uma precisão global de 99,15%.

Na rede PMC foi possível observar também uma precisão de 100% tanto para a classificação de motor saudável como para cada uma das falhas de desgaste de 15, 30, 60 e 90 minutos.

A rede FAM apresentou uma precisão global de 99,64% para a classificação de motor saudável, já com relação aos desgastes de 15, 30, 60 e 90 minutos, apresentou uma precisão de 98,98%, 100%, 100% e 97,20%, respectivamente.

A Tabela 17 representa a matriz confusão obtida por meio dos dados do motor que foi acionado pelo inversor G110.

Tabela 17 – Matriz confusão multiclassificador – G110.

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	CC 10%	CC 1%	CC 3%	CC 5%	CC 10%	CC 10%
CC 1%	280	2	0	5	0	295	0	0	0	0
CC 3%	1	286	2	0	0	4	287	0	0	0
CC 5%	0	0	275	0	0	12	3	259	0	1
CC 10%	0	0	0	271	0	7	1	0	261	0
S.	0	0	0	0	294	9	1	0	5	271

Nessa situação a rede PMC apresentou uma precisão global de 99,29%, enquanto que a rede FAM apresentou uma precisão global de 96,96%.

Baseado na Tabela 17 foi possível verificar também que a rede PMC obteve uma precisão de 100% para a classificação de motor saudável, enquanto que para as falhas de desgaste de 15, 30, 60 e 90 minutos a rede apresentou índices de 99,64%, 99,31%, 99,28% e 98,19%, respectivamente.

Na mesma condição a rede FAM apresentou uma precisão de 99,63% para classificação de motor saudável, e para as falhas de desgastes mencionadas anteriormente a rede apresentou índices de 90,21%, 98,29%, 100% e 98,12%, respectivamente.

Na Tabela 18 esta apresentada a matriz confusão obtida ao se utilizar os dados do motor acionado pelo inversor ATV. Nesta condição a rede PMC apresentou uma precisão global de 99,93%, enquanto que a rede FAM apresentou uma precisão global de 98,73%.

Tabela 18 – Matriz confusão multiclassificador – ATV.

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	CC 10%	CC 1%	CC 3%	CC 5%	CC 10%	CC 10%
CC 1%	295	0	0	0	0	295	0	1	0	0
CC 3%	0	289	0	1	0	0	287	3	1	0
CC 5%	0	0	284	0	0	5	0	259	0	1
CC 10%	0	0	0	278	0	0	0	5	261	0
S.	0	0	0	0	269	0	0	1	1	271

De acordo com a Tabela 18 pode-se verificar que a rede PMC apresentou uma precisão 100% quanto a classificação de motor saudável, enquanto que para a classificação de falhas com desgastes de 15, 30, 60 e 90 minutos, a rede apresentou índices de precisão que foram 100%, 100%, 100% e 99,64%, respectivamente.

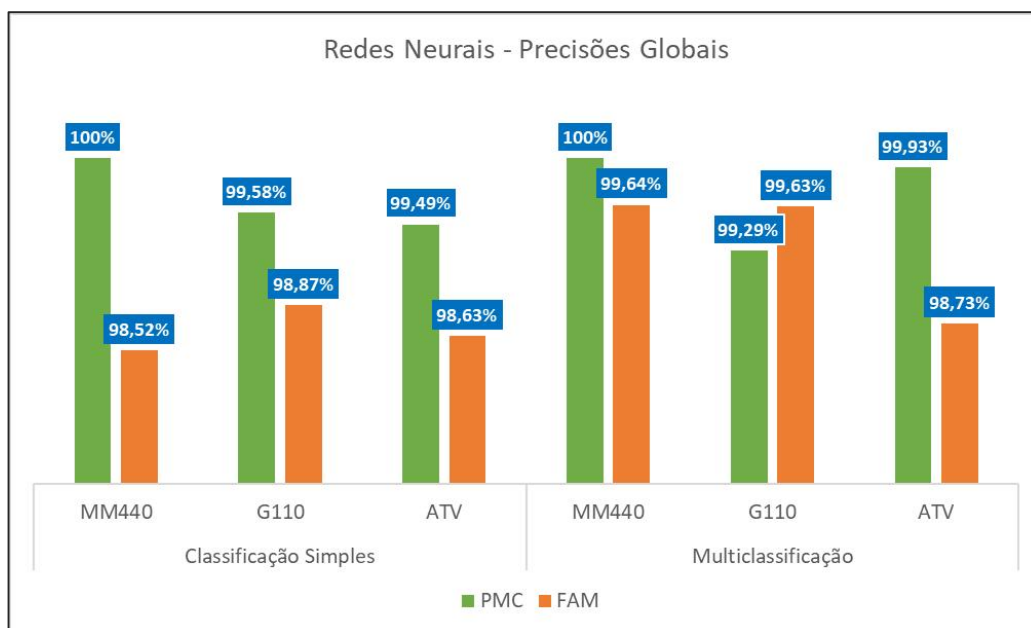
No mesmo contexto a rede FAM apresentou uma precisão de 99,63% para o diagnóstico de motor saudável, e precisões de 98,33%, 100%, 96,28% e 99,24% para diagnósticos de falhas com desgastes de 15, 30, 60 e 90 minutos, respectivamente.

5 ANÁLISE DOS RESULTADOS EXPERIMENTAIS

Nesta seção será realizada uma análise dos métodos e resultados obtidos na classificação falhas mencionadas no capítulo anterior. Os valores de precisão global serão utilizados para medir a eficiência das redes *Perceptron* Multicamadas e *Fuzzy ARTmap*.

Na Figura 8 pode-se verificar um compilado dos resultados de precisão global obtidos para o motor acionado pelos inversores MM440, G110 e ATV, respectivamente.

Figura 10 – Resultado das precisões globais das redes neurais.



Fonte: Autoria própria.

A escolha do método de processamento de dados adequado tem uma grande influência sobre o resultado de classificação de falhas em MIT acionados por inversores de frequência.

Dentre os resultados apresentados na Figura 10 foi possível constatar que os dados do motor acionado pelo inversor de frequência ATV foram os mais

difíceis de se classificar, pois de uma maneira geral foram os que apresentaram um menor valor de precisão.

De uma maneira geral, a aplicação da transformada Wavelet seguido pelo uso do PCA apresentou uma eficiência muito boa, levando-se em consideração que os valores de precisão global ficaram bem próximos do 100%. Isso está bastante ligado ao fato de ter sido aplicado três níveis de transformada, que por consequência gerou um ruído consideravelmente pequeno, facilitando de forma relevante a classificação das falhas pelas redes neurais.

No entanto, é necessário ressaltar que para se obter as eficiências apresentadas neste trabalho houve um esforço computacional e um tempo de processamento mais elevado, que dependendo do tipo de aplicação, pode vir a inviabilizar um projeto.

6 CONSIDERAÇÕES FINAIS

Este trabalho foi pautado em realizar a classificação de falhas nos rolamentos de um motor trifásico que foi acionado por três tipos de inversores de frequência distintos. Os dados utilizados para tais diagnósticos foram provenientes de experimentos realizados em um motor de indução trifásico, sendo este submetido a uma variação de carga no eixo.

Embora que os métodos de pré-processamento trouxeram um grande esforço computacional para a proposta do trabalho, eles tiveram papéis fundamentais para o resultado final, pois realizando uma redução eficiente na dimensionalidade dos dados e diminuindo o nível de ruído dos sinais de corrente, contribuíram de maneira relevante para a realização das classificações das falhas pelas redes neurais.

Por fim, vale destacar que os níveis de precisão obtidos tanto pela rede *Perceptron* Multicamadas como pela *Fuizzy ARTmap* foram excelentes, ficando sempre acima dos 96%, e que dependendo do contexto em que um determinado projeto for construído, onde se pondera as condições de tempo, precisão e esforço computacional, é sim u modelo que pode ser levado em consideração pois apresenta bons resultados.

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.
- 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.
- 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. **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.
- KASUBA T. (1993). **Simplified fuzzy ARTMAP**. *AI Expert*. 8:18–25.
- OLIVEIRA, H. M. **Análise de Fourier e Wavelets: Sinais Estacionários e não Estacionários**. Recife: Editora Universitária, UFPE, 2007. 342 p.
- REIS, A. J. S. **Reconhecimento de Padrões de Falhas em Motores Trifásicos Utilizando Redes Neurais**. UFRN, Natal, 2010.
- 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.

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.

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.