

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CAMPUS CORNÉLIO PROCÓPIO
CURSO DE ENGENHARIA ELÉTRICA**

MATEUS PERSIN JANDREICE

**ESTUDO COMPARATIVO DE FERRAMENTAS ESTATÍSTICAS EM FALHAS DE
MÁQUINAS ELÉTRICAS**

TRABALHO DE CONCLUSÃO DE CURSO

**CORNÉLIO PROCÓPIO
2019**

MATEUS PERSIN JANDREICE

**ESTUDO COMPARATIVO DE FERRAMENTAS ESTATÍSTICAS EM FALHAS DE
MÁQUINAS ELÉTRICAS**

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 obtenção do título de Bacharel.

Orientador: Prof. Dr. Wagner Fontes Godoy

CORNÉLIO PROCÓPIO

2019



Universidade Tecnológica Federal do Paraná

Campus Cornélio Procópio

Departamento de Engenharia Elétrica

Curso de Engenharia Elétrica



FOLHA DE APROVAÇÃO

Mateus Persin Jandreice

Estudo comparativo de ferramentas estatísticas em falhas de máquinas elétricas

Trabalho de conclusão de curso apresentado às 10:00hs do dia 26/06/2019 como requisito parcial para a obtenção do título de Engenheiro Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

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

Prof(a). Dr(a). Márcio Mendonça – (Membro)

Prof(a). Dr(a). Murilo da Silva – (Membro)

RESUMO

JANDREICE, Mateus P. **Estudo comparativo de ferramentas estatísticas em falhas de máquinas elétricas.** 2019. 93 f. Trabalho de conclusão de curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2019.

Este trabalho apresenta uma comparação entre metodologias usadas para detecção e classificação de falhas em motores de indução trifásicos acionados por inversores de frequência. O método aplicado foi a análise dos sinais de corrente com falhas nos rolamentos, estator e rotor, além de sinais de corrente de motor saudável. Tal análise foi realizada através do uso da Transformada Rápida de Fourier, da Transformada Wavelet e da Análise de Componentes Principais como técnicas de processamento dos sinais utilizados. Para se realizar a identificação da presença de falhas no motor e para classificar suas severidades, duas redes inteligentes serão utilizadas: *Perceptron* Multicamadas e *Fuzzy ARTmap*.

Palavras-chave: Falhas. Análise de Componentes Principais. Transformada Rápida de Fourier. *Perceptron*. Transformada *Wavelet*. Inversor de frequência. *Fuzzy Artmap*. Motor de indução trifásico.

ABSTRACT

JANDREICE, Mateus P. **Comparative study of statistical analysis in electrical machines faults.** 2019. 93 f. Trabalho de conclusão de curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2019.

This work presents a comparison between methodologies used to detect and classify faults in three-phase induction motors driven by frequency inverters. The applied method was the analysis of the current signals with stator, rotor and bearing faults, besides current signals of healthy motor. Such analysis was accomplished through the use of Fast Fourier Transform, Wavelet Transform and Principal Component Analysis as signals processing techniques. In order to identify the presence of motor faults and to classify their severity two intelligent networks were used: Multi-layer Perceptron and Fuzzy ARTmap.

Key words: Faults. Principal Component Analysis. Fast Fourier Transform. Perceptron. Wavelet Transform. Frequency inverter. Fuzzy Artmap. Three-phase induction Motor.

LISTA DE FIGURAS

Figura 1 – Principais partes de um MIT.....	16
Figura 2 – Falha do tipo distribuída.	17
Figura 3 – Falha do tipo degradação localizada.....	18
Figura 4 – Fluxograma de detecção de falhas.	21
Figura 5 – Representação da transformada Wavelet.	25
Figura 6 – Representação do neurônio artificial.....	27
Figura 7 – Representação da rede <i>Perceptron</i> Multicamadas.	29
Figura 8 – Rotor com barras quebradas.....	35
Figura 9 – Diagrama de pré-processamento e classificação de falhas	36
Figura 10 – Sinal de Corrente – falha no estator.....	37
Figura 11 – Sinal de Corrente - FFT – falha no estator.	38
Figura 12 – Sinal de Aproximação – Wavelet.....	39
Figura 13 – Sinal de Detalhe – Wavelet.	39
Figura 14 – Comparação de resultados para corrente no domínio do tempo	49
Figura 15 – Comparação de resultados para corrente - FFT	54
Figura 16 – Comparação de resultados para corrente - Wavelet.....	58
Figura 17 – Comparação de resultados para corrente no domínio do tempo	63
Figura 18 – Comparação de resultados para corrente - FFT	67
Figura 19 – Comparação de resultados para corrente - Wavelet.....	72
Figura 20 – Comparação de resultados para corrente no domínio do tempo	76
Figura 21 – Comparação de resultados para corrente - FFT	81
Figura 22 – Comparação de resultados para corrente - Wavelet.....	85
Figura 23 – Resultados obtidos – MM440.....	86
Figura 24 – Resultados obtidos – G110.....	86
Figura 25 – Resultados obtidos – ATV.....	87

LISTA DE TABELAS

Tabela 1 – Comparação entre as pesquisas do IEEE, EPRI e Allianz	13
Tabela 2 – Parâmetros e características dos MIT utilizados no trabalho	32
Tabela 3 – Parâmetros e características dos inversores utilizados no trabalho	33
Tabela 4 – Quantidade de aquisições utilizados por defeito	33
Tabela 5 – Parâmetros e características dos inversores utilizados no trabalho	35
Tabela 6 – Parâmetros da rede <i>Perceptron</i> Multicamadas	41
Tabela 7 – Topologia PMC – Classificação Simples.....	41
Tabela 8 – Topologia PMC – Multiclassificação	42
Tabela 9 – Classificação Simples	42
Tabela 10 – Multiclassificação	42
Tabela 11 – Topologia FAM.....	43
Tabela 12 – Matriz de confusão classificador simples MM440	44
Tabela 13 – Matriz de confusão classificador simples G110	45
Tabela 14 – Matriz de confusão classificador simples ATV	46
Tabela 15 – Matriz de confusão multiclassificador - MM440	46
Tabela 16 – Matriz de confusão multiclassificador - G110	47
Tabela 17 – Matriz de confusão multiclassificador - ATV.....	48
Tabela 18 – Matriz de confusão classificador simples MM440	50
Tabela 19 – Matriz de confusão classificador simples G110	50
Tabela 20 – Matriz de confusão classificador simples ATV	51
Tabela 21 – Matriz de confusão multiclassificador - MM440	51
Tabela 22 – Matriz de confusão multiclassificador - G110	52
Tabela 23 – Matriz de confusão multiclassificador - ATV.....	53
Tabela 24 – Matriz de confusão classificador simples MM440	54
Tabela 25 – Matriz de confusão classificador simples G110.....	55
Tabela 26 – Matriz de confusão classificador simples ATV	55
Tabela 27 – Matriz de confusão multiclassificador - MM440	56
Tabela 28 – Matriz de confusão multiclassificador - G110	57
Tabela 29 – Matriz de confusão multiclassificador - ATV.....	57
Tabela 30 – Matriz de confusão classificador simples MM440	59
Tabela 31 – Matriz de confusão classificador simples G110.....	60
Tabela 32 – Matriz de confusão classificador simples ATV	60

Tabela 33 – Matriz de confusão multiclassificador - MM440	61
Tabela 34 – Matriz de confusão multiclassificador - G110	61
Tabela 35 – Matriz de confusão multiclassificador - ATV	62
Tabela 36 – Matriz de confusão classificador simples MM440	63
Tabela 37 – Matriz de confusão classificador simples G110	64
Tabela 38 – Matriz de confusão classificador simples ATV	64
Tabela 39 – Matriz de confusão multiclassificador - MM440	65
Tabela 40 – Matriz de confusão multiclassificador - G110	66
Tabela 41 – Matriz de confusão multiclassificador - ATV	66
Tabela 42 – Matriz de confusão classificador simples MM440	68
Tabela 43 – Matriz de confusão classificador simples G110	68
Tabela 44 – Matriz de confusão classificador simples ATV	69
Tabela 45 – Matriz de confusão multiclassificador - MM440	69
Tabela 46 – Matriz de confusão multiclassificador - G110	70
Tabela 47 – Matriz de confusão multiclassificador - ATV	71
Tabela 48 – Matriz de confusão classificador simples MM440	72
Tabela 49 – Matriz de confusão classificador simples G110	73
Tabela 50 – Matriz de confusão classificador simples ATV	73
Tabela 51 – Matriz de confusão multiclassificador - MM440	74
Tabela 52 – Matriz de confusão multiclassificador - G110	75
Tabela 53 – Matriz de confusão multiclassificador - ATV	75
Tabela 54 – Matriz de confusão classificador simples MM440	77
Tabela 55 – Matriz de confusão classificador simples G110	77
Tabela 56 – Matriz de confusão classificador simples ATV	78
Tabela 57 – Matriz de confusão multiclassificador - MM440	78
Tabela 58 – Matriz de confusão multiclassificador - G110	79
Tabela 59 – Matriz de confusão multiclassificador - ATV	80
Tabela 60 – Matriz de confusão classificador simples MM440	81
Tabela 61 – Matriz de confusão classificador simples G110	82
Tabela 62 – Matriz de confusão classificador simples ATV	82
Tabela 63 – Matriz de confusão multiclassificador - MM440	83
Tabela 64 – Matriz de confusão multiclassificador - G110	84
Tabela 65 – Matriz de confusão multiclassificador - ATV	84

LISTA DE ABREVIATURAS

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

SUMÁRIO

1	INTRODUÇÃO	12
1.1	DELIMITAÇÃO DO TEMA.....	13
1.2	JUSTIFICATIVA.....	14
1.3	OBJETIVOS.....	14
1.4	ESTRUTURA DA DISSERTAÇÃO.....	15
2	FALHAS NO MOTOR DE INDUÇÃO TRIFÁSICO.....	16
2.1	MOTOR DE INDUÇÃO TRIFÁSICO.....	16
2.2	FALHA DE ROLAMENTO	17
2.3	FALHA NO ESTATOR	18
2.4	FALHA NO ROTOR	19
3	TÉCNICAS PARA ANÁLISE DE FALHAS EM MOTORES DE INDUÇÃO ...	21
3.1	FLUXOGRAMA DE DETECÇÃO DE FALHAS.....	21
3.2	PROCESSAMENTO DE SINAIS.....	22
3.2.1	Transformada de Fourier	22
3.2.1.1	Transformada Rápida de Fourier.....	23
3.2.2	Transformada Wavelet.....	24
3.2.3	Análise de Componentes Principais	26
3.3	DIAGNÓSTICO DE FALHAS	26
3.3.1	Redes Neurais Artificiais.....	27
3.3.2	Rede Perceptron Multicamadas.....	28
3.3.3	Fuzzy Artmap.....	30
4	METODOLOGIA.....	32
4.1	BANCO DE DADOS.....	32
4.2	INSERÇÃO DE FALHAS.....	34
4.2.1	Aquisição de Dados – Curto Circuito no Estator	34
4.2.2	Aquisição de Dados – Barras Quebradas no Rotor	34
4.2.3	Aquisição de Dados – Desgastes nos Rolamentos	35
4.3	PRÉ-PROCESSAMENTO E CLASSIFICAÇÃO	36
4.3.1	Estrutura de Pré-processamento dos dados.....	36
4.3.2	Estrutura de Classificação dos dados.....	40
5	RESULTADOS EXPERIMENTAIS.....	44
5.1	FALHA CURTO-CIRCUITO NO ESTATOR	44

5.1.1	Corrente domínio do tempo – Classificação Simples	44
5.1.2	Corrente domínio do tempo – Multiclassificação	46
5.1.3	Comparação da eficiência das redes.....	48
5.1.4	Corrente domínio da frequência – FFT – Classificação Simples	49
5.1.5	Corrente domínio da frequência – FFT – Multiclassificação	51
5.1.6	Comparação da eficiência das redes.....	53
5.1.7	Corrente domínio do tempo – Wavelet – Classificação Simples.....	54
5.1.8	Corrente domínio do tempo – Wavelet – Multiclassificação.....	56
5.1.9	Comparação da eficiência das redes.....	58
5.2	FALHA DE BARRAS QUEBRADAS NO ROTOR	59
5.2.1	Corrente domínio do tempo – Classificação Simples	59
5.2.2	Corrente domínio do tempo – Multiclassificação	60
5.2.3	Comparação da eficiência das redes.....	62
5.2.4	Corrente domínio da frequência – FFT – Classificação Simples	63
5.2.5	Corrente domínio da frequência – FFT – Multiclassificação	65
5.2.6	Comparação da eficiência das redes.....	67
5.2.7	Corrente domínio do tempo – Wavelet – Classificação Simples.....	67
5.2.8	Corrente domínio do tempo– Wavelet – Multiclassificação.....	69
5.2.9	Comparação da eficiência das redes.....	71
5.3	FALHA DE DESGASTES NOS ROLAMENTOS	72
5.3.1	Corrente domínio do tempo – Classificação Simples	72
5.3.2	Corrente domínio do tempo – Multiclassificação	74
5.3.3	Comparação da eficiência das redes.....	76
5.3.4	Corrente domínio da frequência – FFT – Classificação Simples	76
5.3.5	Corrente domínio da frequência – FFT – Multiclassificação	78
5.3.6	Comparação da eficiência das redes.....	80
5.3.7	Corrente domínio do tempo – Wavelet – Classificação Simples.....	81
5.3.8	Corrente domínio do tempo– Wavelet – Multiclassificação.....	83
5.3.9	Comparação da eficiência das redes.....	85
6	ANÁLISE DOS RESULTADOS EXPERIMENTAIS	86
7	CONSIDERAÇÕES FINAIS	89
	REFERÊNCIAS	90

1 INTRODUÇÃO

Dentre os tipos de motores elétricos mais utilizados, os motores de indução possuem um destaque especial, principalmente por apresentarem um simples princípio de funcionamento, uma construção robusta, elevada confiabilidade e um preço pouco elevado devido à automação do seu processo de fabricação (GUEDES, 1994). Esses motores podem chegar a consumir mais de 50% da capacidade produtiva de uma nação industrializada (CUSIDO et al, 2005). No caso do Brasil, estudos realizados em 2005 pela Empresa de Pesquisa Energética (EPE) estimam que 47% da energia produzida no Brasil são destinadas à classe industrial, o que equivale a aproximadamente 346 bilhões de MWh anuais, sendo que deste montante estima-se que 50% da energia consumida seja atribuída a motores elétricos (SUETAKE, 2012).

A manutenção preventiva de motores elétricos exerce um papel fundamental no setor industrial, o que requer um monitoramento constante de suas operações para a detecção condições anormais, sejam elétricas ou mecânicas, as quais podem acarretar em paradas não programadas ou até mesmo a falha do sistema de produção (MARTINS et al., 2006). Como resultado houve um aumento significativo em pesquisas que fornecessem novas condições de monitoramento para motores de indução. Dessa forma, caso seja realizado um diagnóstico correto de falhas e sua detecção na fase inicial, resultando em manutenções não programadas mais rápidas e diminuição do tempo de inatividade para o processo em questão, o que auxilia na redução de perdas financeiras (BELLINI et al., 2008).

Uma das tecnologias que vem sendo utilizada para amenizar os efeitos dos acionamentos dos motores nas indústrias é o inversor de frequência, uma vez que os mesmos podem apresentar proteção contra sobretensão/subtensão, sobrecorrente, sobrecarga no motor, falhas de curto-circuito nas saídas além de proteção contra sobretemperatura (FAIZ; GHORBANIAN; EBRAHIMI, 2012b).

Dentro do setor industrial é necessário que os motores de indução operem em diferentes ambientes que podem conter características que podem ser danosas aos motores, como elevado nível de poeira, ambientes altamente corrosivos, ambientes com altas temperaturas e alta umidade, etc. Essas condições de operação podem levar a diversas condições de falhas nos motores, entre elas as falhas de rolamentos,

falhas nos enrolamentos do estator, falha no rotor, entre outras. Pesquisas realizadas pela IEEE-IAS (IEEE - Industry Application Society), pela EPRI (Electric Power Research Institute) e pela Allianz (Auto Instituto Ayrton Senna) mostram a taxa de ocorrência das falhas nos motores de indução, conforme pode ser observado na Tabela 1.

Tabela 1 – Comparação entre as pesquisas do IEEE, EPRI e Allianz

Major Components	IEEE-IAS % de falhas	EPRI % de falhas	Allianz % de falhas
Rolamentos	44	41	13
Estator	26	36	66
Rotor	8	9	13
Outros	22	14	8

Fonte: Zhang, Du, Habetler, Lu (2011).

Assim, a proposta deste trabalho consiste em apresentar uma comparação entre alguns métodos utilizados para se realizar a classificação e detecção de falhas nos motores de indução, acionados por modelos distintos de inversores de frequência, através da análise dos sinais de corrente no domínio do tempo.

1.1 DELIMITAÇÃO DO TEMA

Neste trabalho será realizado uma comparação entre métodos de classificação de falhas em motores de indução trifásico, visando identificar quais conjuntos de técnicas que possuem maior precisão e menor esforço computacional.

As técnicas de processamento que serão utilizadas são a Transformada Rápida de Fourier (FFT) e a Transformada *Wavelet* (WT). As técnicas de classificação serão as redes inteligentes *Perceptron* Multicamadas e a *Fuzzy Artmap*. Também será utilizado em todos os conjuntos a Análise de Componentes Principais (PCA) para reduzir a quantidade de amostras a serem utilizadas.

Considerando-se as técnicas apresentadas, serão analisados 6 conjuntos, sendo eles:

- 1) Sinal de corrente no domínio do tempo sem o processamento de sinal, utilizando-se o *Perceptron* Multicamadas como classificador;
- 2) Sinal de corrente no domínio do tempo sem o processamento de sinal, utilizando-se o *Fuzzy Artmap* como classificador;

- 3) Sinal de corrente processado pela Transformada Rápida de Fourier utilizando-se o *Perceptron* Multicamadas como classificador;
- 4) Sinal de corrente processado pela Transformada Rápida de Fourier utilizando-se o *Fuzzy Artmap* como classificador;
- 5) Sinal de corrente processado pela Transformada *Wavelet* utilizando-se o *Perceptron* Multicamadas como classificador;
- 6) Sinal de corrente processado pela Transformada *Wavelet* utilizando-se o *Fuzzy Artmap* como classificador;

1.2 JUSTIFICATIVA

Um sistema de detecção e diagnóstico de falhas pode auxiliar o setor de manutenção de uma indústria de diversas maneiras. Uma das principais vantagens desse sistema está na possibilidade de detectar a falha em seu estágio inicial, o que auxilia a manutenção preditiva e pode também evitar uma parada não programada da máquina, o que pode causar prejuízos à empresa. Para isso é necessário que a detecção e a correta classificação precoce de falhas sejam o mais preciso possíveis.

A realização deste trabalho possibilitará a comparação entre alguns métodos utilizados para se realizar a classificação e identificação de falhas, indicando qual deles é o mais adequado de acordo com sua complexidade e precisão.

1.3 OBJETIVOS

Nesta seção serão descritos os objetivos gerais e específicos deste trabalho.

Objetivo Geral:

Classificar falhas em motores de indução trifásico utilizando redes neurais artificiais e o sistema *Fuzzy ARTmap*, com padrões obtidos através dos sinais de corrente no domínio do tempo, sendo estes padrões obtidos através de processamentos utilizando a Transformada Rápida de Fourier (FFT), modelos wavelet, análise de componentes principais e os próprios sinais de corrente no domínio do tempo.

Objetivos Específicos:

Analisar características de sinais de corrente de motores de indução com falhas;

- Aplicar o pré-processamento do sinal utilizando a Transformada Rápida de Fourier, Transformada Wavelet e análise de componentes principais;
- Implementar redes neurais classificadoras para classificar sinais com falhas e sem falhas através do uso do Perceptron Multicamadas e *Fuzzy ARTmap*;
- Comparar os resultados de classificação obtidos para os sinais de corrente no domínio do tempo, os sinais pré-processados pela transformada wavelet e pela Transformada Rápida de Fourier, com e sem o processamento das análises de componentes principais.

1.4 ESTRUTURA DA DISSERTAÇÃO

Este trabalho será dividido em 5 capítulos, que serão descritos a seguir:

No Capítulo 1 foi apresentada a introdução sobre os motores de indução trifásicos, sua importância no setor industrial e o por que existe a necessidade de se analisar as faltas que ocorrem no rolamento, estator e rotor do motor de indução. Adicionalmente, o tema deste trabalho, a justificativa e os objetivos que este trabalho visa discutir.

No Capítulo 2, descrevem-se os conceitos de motores de indução trifásico e são descritas as teorias relacionadas as principais falhas que ocorrem nestes motores, sendo elas falhas de rolamentos, estator e rotor.

No Capítulo 3, são definidas as técnicas de diagnóstico utilizadas no trabalho, o fluxograma que será utilizado para se aplicar as técnicas descritas, as teorias relacionadas aos processamentos de sinais utilizados, sendo eles Transformada de Fourier, Transformada *Wavelet* e Análise de Componentes Principais, além das teorias relacionadas as técnicas de classificação por sistemas inteligentes que serão utilizadas, sendo elas *Perceptron Multicamadas* e *Fuzzy Artmap*.

No Capítulo 4, discutem-se os resultados esperados para este trabalho.

No Capítulo 5, é apresentado o cronograma de desenvolvimento da proposta deste trabalho e sua aplicação.

2 FALHAS NO MOTOR DE INDUÇÃO TRIFÁSICO


Nesta seção serão apresentados os conceitos relacionados aos motores de indução trifásico e as teorias referentes as falhas que apresentam maior ocorrência nestes motores, sendo elas: falhas de rolamento, estator e rotor.

2.1 MOTOR DE INDUÇÃO TRIFÁSICO

No motor de indução, a corrente alternada é fornecida diretamente ao estator, e o rotor recebe a corrente por indução. Quando excitado por uma fonte polifásica equilibrada, um campo magnético é produzido no entreferro girando na velocidade síncrona. Essa velocidade é determinada pelo número de polos e a frequência aplicada ao estator (FITZGERALD; KINGSLEY; UMANS, 2003).

O rotor de uma máquina de indução trifásica pode ser do tipo rotor bobinado ou rotor de gaiola de esquilo. As máquinas de rotor bobinado são mais incomuns, sendo recomendados nos casos em que a carga possui alto conjugado resistente ou alta inércia na partida (WEG, 2013). No caso do rotor de gaiola de esquilo, este apresenta extrema simplicidade e robustez, sendo o mais empregado em qualquer aplicação industrial (FITZGERALD; KINGSLEY; UMANS, 2003).

Figura 1 – Principais partes de um MIT.



Fonte: (WEG, 2013).

Assim como apresentado na Tabela 1, a maior parte das falhas que podem ocorrer em um motor de indução trifásico estão concentradas nos rolamentos, estator e rotor. Essas falhas podem ser causadas por diversos fatores, sendo eles: estresses mecânicos, térmicos, ambientais, elétricos, etc. (KATHIR et al., 2011). As seções a seguir apresentam maiores detalhes dos tipos de falhas em MIT's.

2.2 FALHA DE ROLAMENTO

O rolamento em motores de indução trifásico é constituído por quatro elementos, sendo estes o anel externo, o anel interno, a gaiola e corpos rolantes. Cada elemento gera uma frequência de resposta própria. Estas quatro frequências naturais (f_n) são definidas como: frequência do anel externo, frequência do anel interno, frequência da gaiola, frequência dos corpos rolantes (SILVA; CARDOSO).

De acordo com a Tabela 1, os estudos realizados na IEEE-IAS e na EPRI mostram que as falhas nos rolamentos são as mais comuns nos motores de indução trifásico.

Existem vários fatores que podem levar a falha nos rolamentos de motores de indução, dentre eles: vibração, desgaste interno, desalinhamento do eixo, excentricidade, corrente no rolamento, poeira, corrosão, lubrificação inadequada, além de sua montagem incorreta (GODOY, 2016).

As falhas nos rolamentos podem ser consideradas dos tipos distribuídas ou localizadas. A primeira determina uma falha que afeta toda uma região do rolamento. Esta falha apresenta uma certa dificuldade de identificação por não possuir uma frequência distinta que a caracterize. (GONGORA, 2013). Um exemplo desta falha é apresentado na Figura 2.

Figura 2 – Falha do tipo distribuída.



Fonte: Adaptado de NSK DO BRASIL (2012).

O segundo tipo de classificação, as falhas localizadas, afetam um único ponto do rolamento. Estas falhas são pontos incipientes como rachaduras, ranhuras ou deterioração pontual (BLODT et al., 2008). Um exemplo desta falha é apresentado na Figura 3.

Figura 3 – Falha do tipo degradação localizada.



Fonte: Adaptado de NSK DO BRASIL (2012).

O diagnóstico das falhas de rolamento é realizado de forma não-invasiva por meio do monitoramento de variáveis como vibração, temperatura, e especialmente mediante os sinais de corrente (GODOY, 2016). Neste trabalho serão analisados os sinais de corrente para a detecção e classificação das falhas nos motores de indução.

2.3 FALHA NO ESTATOR

No motor de indução trifásico, o estator é composto por três enrolamentos dispostos a 120° mecânicos. O fluxo produzido nos enrolamentos do estator, e que atravessa o entreferro e o rotor, é girante e com a velocidade da frequência da tensão de alimentação.

De acordo com a Tabela 1, os estudos realizados na IEEE-IAS e na EPRI mostram que a frequência de falhas nos estatores é apenas superada pela frequência de falha nos rolamentos. Já na pesquisa realizada pela Allianz mostra que as falhas nos estatores são as mais comuns.

Entre os fatores que podem levar a falha nos estatores de motores de indução, as mais comuns são: Sobreaquecimento; Erros de projeto; Folga de conexão dos rolamentos; Contaminação do óleo por umidade e poeira; Curto-circuito e exigências de partida; Defeitos nos componentes da máquina e Descargas elétricas (REIS, 2010).

Existem duas classes principais de falhas nos enrolamentos do estator, sendo elas: Assimetria nos enrolamentos do estator como uma falha de fase-aberta; curto-circuito de em algumas voltas nos enrolamentos de fase. A primeira permite a máquina operar com um torque reduzido enquanto a segunda pode levar a uma falha catastrófica em um curto período de tempo (BELLINI et al., 2008).

A falha assimétrica pode ser detectada de maneira simples através da corrente de sequência negativa. Como o funcionamento da máquina não é muito afetado neste caso, não é necessário se tomar medidas drásticas. As falhas envolvendo corrente de curto-circuito são as mais difíceis de se detectarem. Um dos métodos mais simples e efetivo é o contínuo monitoramento da sequência negativa das correntes do estator (BELLINI et al., 2008).

No caso de falhas de estator, o diagnóstico é efetuado a partir do monitoramento das assinaturas de corrente de estator, mediante métodos não-invasivos. (GODOY, 2016). As correntes analisadas neste trabalho estarão sob o efeito de falha de curto-circuito, devido a maior importância e dificuldade em se detectar falhas deste tipo.

2.4 FALHA NO ROTOR

No motor de indução trifásico, o rotor pode ser composto por três enrolamentos similares ao do estator (rotor bobinado), ou pode ser composto por um conjunto de barras condutoras conectadas em seus extremos por dois anéis (rotor tipo gaiola de esquilo).

De acordo com a Tabela 1, os estudos realizados na IEEE-IAS e na EPRI mostram que as falhas nos rotores são as possuem menor chance de ocorrência quando comparadas com falhas de rolamentos e falhas nos estatores. Isto se deve devido a robustez desta peça.

Quando uma falha de estator ocorre em um motor de indução, a operação da máquina é limitada a alguns segundos, já no caso de falhas no rotor a operação da máquina não é restrita. No entanto, a corrente que apresenta falha causa um aumento de até 50% na corrente adjacente nas barras do rotor, enquanto que no caso de falha no estator, a corrente adjacente só sofreria um aumento de poucas porcentagens em relação a corrente original.

A maioria das falhas nos rotores são causadas principalmente pela quebra nas articulações das barras e anéis. Essas falhas normalmente causam: Variações de torque; oscilações de velocidade; vibrações; mudanças de componentes da frequência; ruídos; sobreaquecimentos; laminações e centelhamento no rotor. (REIS, 2010).

Nas próximas seções serão apresentadas as técnicas de processamento de sinais e as estratégias de classificação utilizadas para realizar a detecção e classificação das falhas de rolamento, estator e rotor.

3 TÉCNICAS PARA ANÁLISE DE FALHAS EM MOTORES DE INDUÇÃO

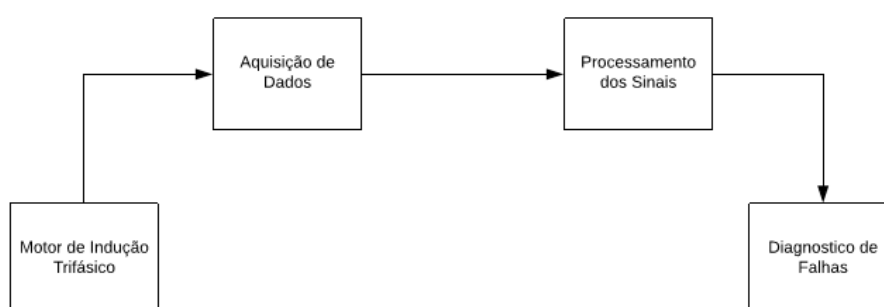
Atualmente existem diversos métodos de detecção e diagnóstico de falhas em motores. A detecção da falha determina se o funcionamento do sistema está incorreto ou inaceitável em algum aspecto. O diagnóstico de falhas pode ser usado para determinar o tipo, localização e o tempo de detecção da falha, de acordo com os sintomas observados, incluindo o isolamento e a identificação da falha (REIS, 2010).

3.1 FLUXOGRAMA DE DETECÇÃO DE FALHAS

O processo de detecção de falhas pode ser dividido em três etapas: Aquisição de dados. Processamento dos dados e identificação da falha.

A primeira etapa consiste na aquisição de dados relevantes do motor através, por exemplo, de sensores de tensão e corrente que utilizam filtros, conversores analógico-digital, etc. Na segunda etapa ocorre o processamento dos sinais, obtidos na primeira etapa, afim de conhecer a condição do motor. Existem várias técnicas que podem ser usadas para se realizar estes processamentos, entre elas: Transformada Rápida de Fourier (FFT), Transformada Wavelet (WT), Métodos de Elementos Finitos (FEM), abordagem da transformada de Park, entre outras. Na terceira etapa ocorre o processo de identificação da falha. Os procedimentos de identificação são realizados através do uso de técnicas de inteligência artificial como, por exemplo, redes neurais, lógica fuzzy, algoritmos genéticos, entre outras.

Figura 4 – Fluxograma de detecção de falhas.



Fonte: Autoria própria.

Nas próximas seções serão apresentadas as técnicas escolhidas neste trabalho para se realizar o processamento dos sinais de corrente, o diagnóstico e a classificação das falhas de rolamento, estator e rotor.

3.2 PROCESSAMENTO DE SINAIS

Nesta seção serão apresentadas as técnicas utilizadas para se realizar o processamento dos sinais coletados do motor de indução.

Os sinais escolhidos para análise serão os sinais de corrente, já que para a coleta dos mesmos podem ser usados métodos não invasivos, não sendo necessário interromper o funcionamento do motor. Através dos sinais de corrente coletados serão aplicadas técnicas de processamento através da Transformada Rápida de Fourier e da Transformada Wavelet. A aplicação destes métodos tem como objetivo a extração de características relevantes dos sinais de corrente. Estas transformadas têm como objetivo representar o sinal de corrente no domínio da frequência, permitindo assim uma análise mais detalhada e precisa das componentes principais da frequência quando sob efeito de falhas.

Após o processamento dos dados pela Transformada Rápida de Fourier e pela Transformada Wavelet, será aplicada a análise de componentes principais, visando reduzir a quantidade de dados obtidos, enquanto preserva as principais informações contidas neles.

3.2.1 Transformada de Fourier

A Transformada de Fourier (FT) é utilizada para realizar a transição entre variáveis do domínio do tempo para o domínio da frequência. Essa transformada tem a limitação de só se aplicar a sinais não periódicos e contínuos.

Para uma função $x = x(t)$, a FT é definida como:

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

onde:

- $X(w)$ é o sinal $x(t)$ representado no domínio da frequência (w)

- e é a função exponencial.

3.2.1.1 Transformada Rápida de Fourier

A Transformada Rápida de Fourier (FFT) foi desenvolvida para suprir a necessidade de acelerar o processo de interpolação de grande quantidade de dados por polinômios trigonométricos. Essa transformada se aplica para sinais não periódicos em tempo discreto, e consiste de um conjunto de passos que se utiliza das propriedades do cálculo da Transformada Discreta de Fourier (DFT), representada pela seguinte forma (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 $[0 \dots N_a]$, que representa o índice do vetor discreto do sinal $x(n)$, no domínio do tempo;
- m é um número inteiro entre $[0 \dots N_a]$, que representa o índice do vetor discreto do sinal $X(m)$, no domínio da frequência;
- N_a é a quantidade total de amostra.

O cálculo de uma DFT é equivalente ao cálculo da FT em N_a amostragens de frequência, com espaçamento de:

$$w_m = \frac{2\pi m}{N_a} \quad (3)$$

Um dos requisitos da FFT consiste no fato de que a quantidade de amostras N_a da janela de dados deve ser em função da potência de 2, conforme segue:

$$N_a = 2^v \quad (4)$$

Onde v é um número inteiro positivo.

3.2.2 Transformada Wavelet

A Transformada de Fourier analisada acima possui uma determinada desvantagem, sendo que parte da informação no tempo é perdida quando o sinal é passado para o domínio da frequência. Não é possível analisar quando ocorreu algum evento específico no sinal (MISITI et al., 1997).

A Transformada *Wavelet* foi introduzida com a ideia de superar as dificuldades da Transformada de Fourier. Uma técnica de janelamento com região variável é usada para realizar a análise do sinal. Análise de Wavelet permite o uso de intervalos de tempo mais longos quando é necessária uma informação a baixa frequência, e intervalos de tempo mais curto quando é necessária uma informação a alta frequência (BENBOUZID et al., 2003).

A análise wavelet é baseada na decomposição de um sinal em versões deslocadas e escalonadas de uma mesma função (wavelet-mãe), permitindo diferentes resoluções de tempo e frequência (MALLAT, 1999).

A transformada wavelet de tempo contínuo (Continuous Wavelet Transform - CWT) é calculada pela integral do sinal multiplicado por versões deslocadas e escalonadas de uma função wavelet, Equação

(5).

$$CWT(a, d) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \Psi\left(\frac{t-d}{a}\right) dt \quad (5)$$

em que $CWT(a, d)$ são os coeficientes wavelet, Ψ é a wavelet, a é o fator de compressão e d é o fator de translação.

A transformada wavelet discreta (Discrete Wavelet Transform - DWT), desenvolvida por Mallat (1989), usa banco de filtros na análise multiresolução. Bancos de filtros de reconstrução perfeita são sistemas que decompõem sinais em bandas de frequência usando filtros seletivos e são capazes de reconstruí-los perfeitamente. Essa técnica possibilita a análise de sinais em diferentes resoluções no tempo e na frequência, através de um janelamento de tamanho variável.

As funções escala e *wavelet* podem ser definidas usando versões transladadas e escalonadas delas mesmas e também por um par de filtros de decomposição passa-baixa (h_n) e passa-alta (g_n), conforme as Equações (6) e (7),

em que j é o índice do somatório, o qual depende do comprimento do filtro, e n é o índice do sinal.

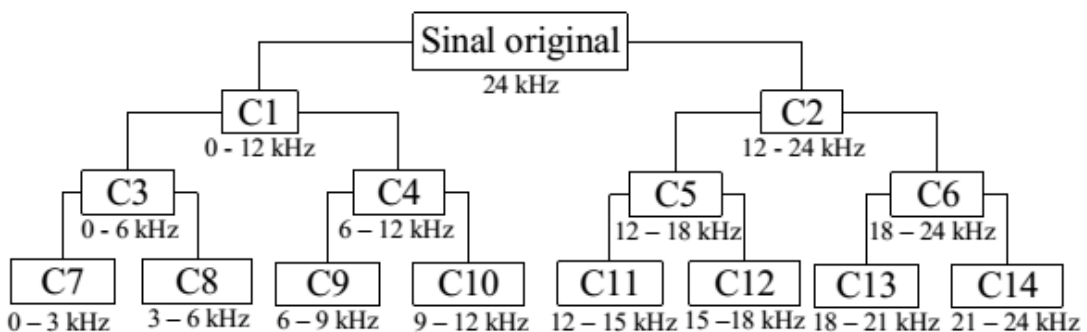
$$\Phi[n] = \sum_j h_n \Phi[2n - j] \quad (6)$$

$$\Psi[n] = \sum_j g_n \Phi[2n - j] \quad (7)$$

A decomposição é obtida pela convolução do sinal com o par de filtros, o que decompõe o sinal em duas partes: componentes de baixa e alta frequência, chamados de aproximação e detalhe respectivamente.

Na Decomposição Wavelet-Packet (DWP), ambos os componentes de baixa e alta frequência são decompostos novamente em cada um dos próximos níveis (MALLAT, 1999), conforme pode ser observado na Figura 5. Os blocos C1 e C2 representam os coeficientes de aproximação e detalhe do primeiro nível de decomposição. Os blocos C3, C4, C5 e C6 representam os componentes do segundo nível de decomposição. Os demais blocos representam os componentes do terceiro nível de decomposição. Observa-se a frequência do sinal original, igual a 24 kHz e a faixa de frequências relacionada a cada componente, abaixo de cada bloco.

Figura 5 – Representação da transformada Wavelet.



Fonte: Adaptado Silva (2014).

3.2.3 Análise de Componentes Principais

A Análise de Componentes Principais é uma técnica estatística utilizada para reduzir a dimensionalidade de um conjunto de dados onde há um grande número de variáveis inter-relacionadas. Isto é feito de forma que o máximo de variância presente nos dados seja mantido. Essa redução se dá pela obtenção de um novo e reduzido conjunto de variáveis não correlacionadas, chamadas componentes principais. Tais componentes estão ordenadas de forma que os primeiros guardam a maior parte da variância presente nas variáveis originais (SILVA, 2008).

Quando um motor de indução trifásico está sujeito a uma falha, as correntes no motor podem estar sujeitas a diversas características, algumas delas como consequência das falhas e outras como causas. Nesse contexto, o PCA será utilizado para tentar reduzir as características que compõe estes sinais, tendo como resultado somente as características que mais contribuem para o sinal analisado.

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

$$a'_1x = \sum_{j=1}^p a_1x_j \quad (8)$$

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 $a'_1x, a'_2x, \dots, a'_{k-1}x$ (SILVA, 2008).

3.3 DIAGNÓSTICO DE FALHAS


Nesta seção serão apresentadas as técnicas utilizadas para se realizar o diagnóstico dos sinais após o processamento dos mesmos. Para tanto, serão utilizadas as redes inteligentes *Perceptron Multicamadas* e *Fuzzy Artmap*.

3.3.1 Redes Neurais Artificiais

Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos para o processamento de informações paralelas. Essas redes podem ser definidas como um conjunto de unidades de processamento, caracterizados por neurônios artificiais, que são interligados por um grande número de interconexões conhecidas como sinapses artificiais. Essas redes podem ser usadas em aplicações como aproximador universal de funções, controle de processos, classificação de padrões, agrupamento de dados, sistemas de previsão, otimização de sistemas e memórias associativas (SILVA, SPATTI, FLAUZINO, 2010).

O elemento principal de uma rede neural é o neurônio artificial, que tem funções simples como coletar os sinais existentes em suas entradas, agrega-los de acordo com sua função operacional e produzir uma resposta. O neurônio artificial pode ser representado pelo modelo ilustrado na Figura 4.

Figura 6 – Representação do neurônio artificial.



Fonte: Adaptado de Goedtel, Silva e Sernil (2006).

Através da Figura verifica-se que o neurônio artificial é constituído de sete elementos básicos. A combinação destes elementos de acordo com a Figura 4 resulta em duas expressões, sendo elas:

$$v_j(k) = \sum_{i=1}^n X_i \cdot w_i + b \quad (9)$$

$$y_j(k) = \varphi_j(v_j(k)) \quad (10)$$

onde:

- n é o número de sinais de entrada do neurônio;
- X_i é o i -ésimo sinal de entrada do neurônio;
- w_i é o peso associado com o i -ésimo sinal de entrada;
- b é o limiar de cada neurônio;
- $v_j(k)$ é a resposta ponderada do j -ésimo neurônio em relação ao instante k ;
- $\varphi_j(\cdot)$ é a função de ativação do j -ésimo neurônio;
- $y_j(k)$ é o sinal de saída do j -ésimo neurônio em relação ao instante k .

As redes neurais podem apresentar vantagens no diagnóstico de sinais de motores de indução quando comparadas com técnicas convencionais. Isto se deve pois tais técnicas podem apresentar um custo computacional intenso e uma lentidão de processamento, o modelo matemático pode não ser facilmente obtido, falta de informações disponíveis do problema e as condições operacionais provavelmente são ruidosas. Já as redes neurais oferecem algumas vantagens que podem lidar com as essas dificuldades. Isto se deve através de sua capacidade de aprender e construir um complexo mapeamento não linear devido a sua capacidade de apreender a partir de exemplos, além de possuírem a capacidade de rejeição de ruídos, que podem auxiliar nas incertezas do problema (REIS, 2010).

Dentre as diferentes redes que podem ser utilizadas pelas redes neurais, neste trabalho será abordada a rede *Perceptron* Multicamadas (PMC) para a classificação das falhas.


3.3.2 Rede Perceptron Multicamadas

As redes PMC são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a respectiva camada de saída. Esta arquitetura é uma das mais versáteis quanto a sua aplicabilidade. (SILVA, SPATTI, FLAUZINO, 2010).

A vantagem desta rede frente a outras, como exemplo a rede *Perceptron* simples e a rede *Adalaine*, é que na PMC a camada de saída pode ser composta por diversos neurônios, sendo que cada um destes representa uma saída do processo a ser mapeado (SILVA, SPATTI, FLAUZINO, 2010). Devido a este fator, esta rede se

torna ideal para o diagnóstico de falhas para este trabalho, visto que serão realizadas multiclassificações envolvendo diferentes falhas, ou falhas de um mesmo tipo, mas com distintas características. Uma ilustração desta rede é apresentada na Figura 6.

Figura 7 – Representação da rede *Perceptron Multicamadas*.



Fonte: Adaptado de Godoy, (2006).

A rede PMC utilizada neste trabalho é treinada pelo algoritmo *backpropagation*. Este algoritmo apresenta uma diferença com relação ao algoritmo *feedforward*, visto que o no *backpropagation* um erro é obtido a partir do sinal da saída e é enviado a camada de entrada. Esse erro é utilizado no processo de ajuste dos parâmetros internos (GODOY, 2016). Este processo de *backpropagation* se repete até que a rede alcance um valor de erro que seja aceitável.

De acordo com Goedtel, Silva e Sernil (2006), o processo de ajuste dos pesos da rede w_j associados ao j -ésimo neurônio de saída é feito pelo cálculo do sinal de erro em relação à k -ésima iteração ou ao k -ésimo vetor de entrada. Este sinal de erro é calculado pela seguinte equação:

$$e_j(k) = d_j(k) - y_j(k) \quad (11)$$

onde $d_j(k)$ é a resposta desejada do j -ésimo neurônio de saída. Somando todos os erros quadráticos produzidos pelos neurônios de saída da rede em relação à k -ésima iteração, tem-se:

$$E(k) = \frac{1}{2} \sum_{j=1}^p e_j^2(k) \quad (12)$$

onde p é o número de neurônios da saída. Para uma configuração de pesos ótima, $E(k)$ é minimizado pelo ajuste dos pesos sinápticos w_{ji} . Os pesos associados à camada de saída da rede são recalculados usando a seguinte expressão:

$$w_{ji}(k) \leftarrow w_{ji}(k) - \eta \frac{\partial E(k)}{\partial w_{ji}(k)} \quad (13)$$

onde w_{ji} é o peso conectando o j -ésimo neurônio da camada de saída ao i -ésimo neurônio da camada anterior e η é a constante que determina a taxa de aprendizado do algoritmo de *backpropagation*. O ajuste dos pesos pertencentes às camadas escondidas é feito de forma análoga.

3.3.3 Fuzzy Artmap

A rede *Fuzzy Artmap* é uma arquitetura baseada na teoria de ressonância adaptativa (ART) desenvolvida por Carpenter e Grossberg (1987). Essa rede apresenta um sistema de aprendizagem supervisionada de reconhecimento de padrões e mapas multidimensionais em resposta a vetores de entrada em ordem arbitrária (CARPENTER et al., 1992).

A estrutura original de uma rede FAM engloba o treinamento simultâneo de dois módulos *Fuzzy ART*, para a associação de um padrão análogo no modo supervisionado: o *Fuzzy* e o ART. Cada um destes módulos é responsável por associar dois espaços vetoriais distintos, porém relacionados. Em problemas de classificação de padrões, um dos espaços é o denominado espaço dos rótulos, enquanto o outro é o espaço de entrada (GODOY, 2016).

A rede neural *Fuzzy Artmap* possui uma entrada referente ao módulo *Fuzzy ART*_a, representada por um vetor a , $a = [a_1 \dots a_{M_B}]$, M_a -dimensional. Esse vetor de entrada é normalizado e complementado, sendo representado por um vetor $I^a = [\bar{a} \bar{a}^c]$, de tamanho $2 M_a$ (CARPENTER et al. 1992).

De acordo com Carpenter et al. (1992), o treinamento da rede se inicia na apresentação de cada padrão de entrada para a camada F_1^a , onde são obtidos os vetores complementares, sendo representado por $\bar{a}^c = (1 - \bar{a})$. O vetor de ganhos sinápticos é inicializado em 1 ($w_{jk} = 1$), onde $j = 1, \dots, N^a$ representa as N^a categorias

da rede ART_a e $k = 1, \dots, 2M_a$ representa cada elemento que compõe os ganhos sinápticos de cada categoria. Além disso, os ganhos sinápticos do *Mapfield* são colocados também em 1 ($w_{jk}^{ab} = 1$). Após o processo de inicialização, o vetor a é enviado à camada F_1^a para que seja calculada a categoria ativa, por meio da função de escolha $T_j(I)$, dada por:

$$T_j(I) = \frac{|A \wedge w_j^a|}{\alpha + |w_j^a|} \quad (14)$$

Onde \wedge representa o operador mínimo e $\alpha > 0$ é o parâmetro de escolha, sendo este um pequeno valor positivo.

O processo de escolha é iniciado fazendo com que o maior valor para a função de escolha da categoria seja escolhido mediante do processo de competição (*winner takes all*) em que o vencedor leva tudo (GODOY, 2016). Após a escolha da categoria o processo de ressonância é verificado através da equação:

$$\frac{|I^a \wedge W_{jv}^a|}{|I^a|} \geq p_a \quad (15)$$

Se a condição de ressonância falhar com a primeira categoria, o mecanismo de reset é acionado e a próxima categoria é selecionada e o processo é refeito. Caso nenhuma categoria passe no teste de similaridade, uma nova categoria é criada e que inicialmente representa exclusivamente o padrão apresentado. No entanto, se a categoria acarretar em uma ressonância, o padrão de aprendizagem é acionado e as matrizes de pesa são atualizadas conforme a equação a seguir (GODOY, 2016).

$$w_j^a(n+1) = (1 - \beta)w_j^a(n) + \beta(A \wedge w_j^a(n)) \quad (16)$$

Onde β representa a taxa de aprendizagem, sendo que este valor se encontra de 0 a 1.

Visto a praticidade e rapidez com que a *Fuzzy Artmap* opera, esta rede e a rede *Perceptron* serão utilizadas para se realizar os processos de identificação e classificação dos dados processados.

4 METODOLOGIA

Como mencionado anteriormente, os MITs são muito utilizados na indústria devido a suas características simplificadas e produtivas. Isto faz com que estes se apresentem suscetíveis as deteriorações naturais presentes no ambiente industrial. A maior parte destas falhas ocorre nos rolamentos, no estator e no rotor, sendo que a que estas 3 juntas representam de 78% a 92% das falhas, de acordo com os estudos mencionados no capítulo 1.

Para que se possa analisar os defeitos causados nos motores devido as condições de operação dos mesmos e as falhas mencionadas anteriormente, são realizados ensaios em laboratório que simulam o ambiente industrial.

Assim, este trabalho propõe um método de detecção de falhas de estator, rotor e de rolamentos por meio da análise dos sinais de corrente, considerando que cada um dos motores utilizados foi acionado por 3 inversores de frequência distintos.

A seguir serão apresentadas características dos motores e inversores utilizados, o método de inserção de cada uma das falhas e os métodos de análises que serão utilizados para classificação.

4.1 BANCO DE DADOS

Os parâmetros e características básicas dos motores, os quais foram usados para a aquisição dos dados utilizados neste trabalho, são apresentados na Tabela 2. O Motor 1 foi utilizado para se realizar os ensaios de curto-circuito no estator, o Motor 2 foi utilizado para os ensaios de barras quebradas de rotor e rolamentos.

Tabela 2 – Parâmetros e características dos MIT utilizados no trabalho

Parâmetros	Motor 1	Motor 2
Fabricante	WEG	WEG
Potência (kW)	0,74	0,74
Frequência (Hz)	60	60
Tensão de alimentação (V)	220/380	220/380
Corrente de alimentação (A)	3,02/1,75	3,02/1,75
Número de pólos	4	4
Número de ranhuras	36	36
Fases rebobinadas	3	-
Nível de curto-circuito (%)	1, 3, 5, 10, 15 e 20	-
Velocidade (rpm)	1730	1730
Torque nominal (N.m)	4,1	4,1
Número de barras de rotor	44	44

A Tabela 3 contém os parâmetros e características dos inversores utilizados neste trabalho.

Tabela 3 – Parâmetros e características dos inversores utilizados no trabalho

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 4 apresenta as características gerais e quantidade totais de dados obtidos através do banco de dados utilizado no contexto deste trabalho. Tal banco de dados também foi usado em Lopes (2016), Bazan (2016), Broniera (2014), Godoy (2016) e Palácios (2016), entre outros.

Tabela 4 – Quantidade de aquisições utilizados por defeito

Motor	Condição	Sinamics G110	Micromaster MM440	ATV12H075M2
Motor 1 (0,74 kW)	Saudável	74	73	84
	1% curto-circuito no estator	76	76	83
	3% curto-circuito no estator	76	70	84
	5% curto-circuito no estator	76	70	84
	10% curto-circuito no estator	75	76	84
Motor 2 (0,74 kW)	Saudável	70	73	62
	1 barra quebrada de rotor	70	73	62
	2 barra quebrada de rotor	70	73	62
	4 barra quebrada de rotor	70	73	62
	2/2 barra quebrada de rotor	70	73	62
Motor 2 (0,74 kW)	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

No banco de dados apresentado na Tabela 4 os inversores estão operando com uma frequência síncrona que varia na faixa de 12 a 60 Hz, com intervalos de 6 Hz entre cada amostra. O torque de carga aplicado nos motores 1 e 2 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 5,0 N.m (Godoy, 2016).

4.2 INSERÇÃO DE FALHAS

Ao se desenvolver o banco de dados utilizado, foram induzidas as falhas de curto-circuito no estator, barras quebradas no rotor e desgastes nos rolamentos, sendo estas falhas nos motores 1 e 3 de acordo a Tabela 4.

A seguir serão apresentados os métodos de inserção de falhas.

4.2.1 Aquisição de Dados – Curto Circuito no Estator

Os dados de curto-circuito no estator foram obtidos através de ensaios em motor com as mesmas características do motor 1 da Tabela 2. De acordo com Godoy (2016), o MIT utilizado possui 6 bobinas, isoladas com verniz, respeitando as medidas originais e a classe de isolamento do motor. O que possibilitou a geração artificial de falhas de isolamento entre as espiras foi a forma com que as três fases do enrolamento do motor foram montadas.

Essa montagem permitiu a realização de ensaios com 1%, 3%, 5%, 10%, 15% e 20% de curto circuito no estator. Destas foram utilizadas para o banco de dados os curto circuitos de 1%, 3%, 5% e 10%.


Os motores utilizados foram ensaiados em ambiente de laboratório, operando em regime permanente e sob cargas constantes.

4.2.2 Aquisição de Dados – Barras Quebradas no Rotor

Para se desenvolver esta parte do banco de dados foi utilizado o motor 2 presentes na Tabela 2. Foram utilizados cinco diferentes rotores para emular as falhas de barras quebradas de rotor em laboratório.

De acordo com Godoy (2016), foi-se utilizado um procedimento de cisalhamento das barras. Essa quebra é realizada com a perfuração usando uma furadeira de bancada, sendo que a broca deve ter diâmetro suficientemente maior que a barra. As quebras foram feitas para 1 até 4 barras, como mostrado na Figura 8.

Figura 8 – Rotor com barras quebradas



Fonte: Adaptado de Godoy (2016)

4.2.3 Aquisição de Dados – Desgastes nos Rolamentos

No caso dos desgastes de rolamentos, buscou-se aprofundar a investigação de uma falha causada pelo desgaste gradual de um rolamento ao longo do tempo de operação da máquina.

De acordo com Godoy (2016), foi efetuada a substituição do lubrificante por pasta abrasiva, a qual contaminou os rolamentos após a remoção das blindagens de proteção lateral,

As situações de falha analisada foram de desgastes: inicial, médio, avançado e severo. Estes desgastes tiveram os seguintes tempos definidos, respectivamente: 15, 30, 60 e 90 minutos. Neste período o motor foi acionado diretamente na rede e operava a vazio.

A Tabela 5 apresenta as especificações do rolamento rígido de esferas, modelo NSK 6204 (GODOY, 2016)

Tabela 5 – Parâmetros e características dos inversores utilizados no trabalho

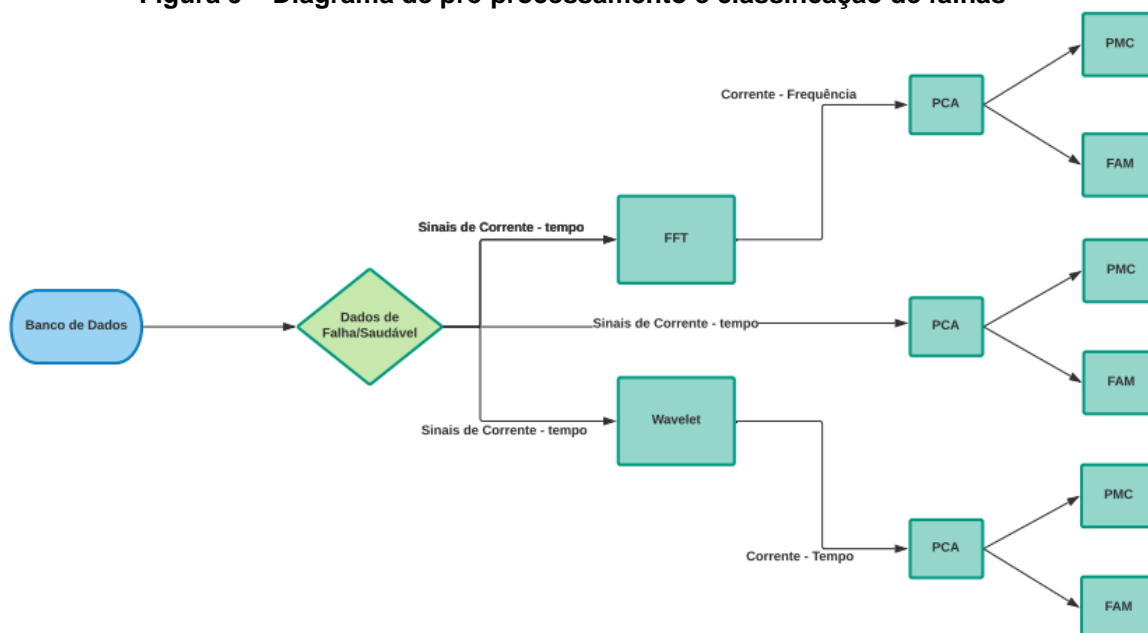
Parâmetros	Especificações
Diâmetro do furo (mm)	20
Diâmetro externo (mm)	47
Largura (mm)	14
Carga dinâmica (kN)	13,5
Carga estática (kN)	6,55
Velocidade (rpm)	32000
Velocidade limite (rpm)	17000

4.3 PRÉ-PROCESSAMENTO E CLASSIFICAÇÃO

A seguir serão apresentados os métodos utilizados para se realizar o pré-processamento dos sinais de corrente, provenientes do banco de dados, bem como as redes inteligentes utilizadas para se realizar a classificação dos dados processados.

A ordem de pré-processamento e classificação dos dados será de acordo com o fluxograma a seguir.

Figura 9 – Diagrama de pré-processamento e classificação de falhas



Fonte: Autoria Própria.

4.3.1 Estrutura de Pré-processamento dos dados


Neste trabalho serão utilizados sinais de corrente provenientes do banco de dados. Para que seja realizada a classificação das falhas em MIT's, mencionadas anteriormente, são aplicados métodos para realizar um pré-processamento dos dados de corrente.

Os dados de motor com falha e motor saudável retirados do banco de dados, como mostrado na Figura 9, são dados das correntes trifásicas dos motores, sendo que para o pré-processamento e para as classificações é utilizada somente uma das fases, mais especificamente a fase "a".

Uma representação do sinal de corrente utilizado nas análises é apresentada na Figura 10.

Nos casos em que o número de variáveis de entrada para as redes utilizadas, *Perceptron* Multicamadas e *Fuzzy ARTmap*, é muito grande, mas que os seus componentes sejam altamente correlacionados, ou seja, são linearmente dependentes, é recomendado reduzir a dimensão dos vetores de entrada. Nestes casos foi aplicada a análise dos componentes principais, que resulta em três efeitos: 1) ortogonaliza os componentes do vetor de entrada para que os mesmos tornem linearmente independentes entre si; 2) ordena os resultados dos componentes ortogonais em ordem decrescente dos componentes de maior variação; 3) elimina os componentes que menos contribuem para a variação do conjunto de dados (BEALE; HAGAN; DEMUTH, 2011).

Figura 10 – Sinal de Corrente – falha no estator.




Fonte: Autoria Própria.

O exemplo de sinal de corrente utilizado na Figura 10 é para uma das fases de falha no estator, com motor acionado por inversor MM440.

Serão utilizados três métodos de pré-processamento. O primeiro consiste em se utilizar os sinais de corrente no domínio do tempo, como o sinal representado na Figura 10 sendo que neste caso o pré-processamento será dado pelo uso de análise dos componentes principais (PCA).

O segundo método será utilizar a transformada rápida de Fourier nos sinais de corrente, resultando em sinais no domínio da frequência. Tal resultado é exemplificado na Figura 11.

Figura 11 – Sinal de Corrente - FFT – falha no estator.




Fonte: Autoria Própria.

O sinal apresentado na Figura 11 apresenta frequência fundamental variada devido ao acionamento do motor pelo inversor de frequência. O sinal da figura 10 é uma aquisição do conjunto de dados de falha de estator acionado por MM440, enquanto a Figura 11 representa


O terceiro método consiste no uso da transformada Wavelet. Uma representação do resultado da aplicação da transformada Wavelet, aplicada no sinal da figura 10, no primeiro nível é mostrado nas Figuras 12 e 13.

Figura 12 – Sinal de Aproximação – Wavelet.



Fonte: Autoria Própria.

Figura 13 – Sinal de Detalhe – Wavelet.



Fonte: Autoria Própria.

Os sinais apresentados nas Figuras e 12 e 13 são a aproximação e detalhe da transformada, respectivamente. Tais sinais representam o primeiro nível da transformada. Os dados utilizados para se apresentar as redes são referentes a aproximação de menor frequência obtida após aplicação de três níveis da transformada Wavelet.

Após a aplicação dos métodos de FFT e Wavelet foi aplicado o 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. Com isso é possível se adotar as componentes que representam a maior parte do sinal.

Em cada um dos métodos também será aplicada a normalização dos 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).

Realizado o pré-processamento serão aplicados os métodos de classificação para determinar a presença de falhas e suas severidades. Tais métodos são apresentados na seção a seguir.

4.3.2 Estrutura de Classificação dos dados

As estruturas utilizadas para se realizar a classificação dos dados serão as redes inteligentes *Perceptron* Multicamadas e a rede *Fuzzy ARTmap*.

Após a etapa de pré-processamento os dados se encontram reduzidos e normalizados em seus respectivos métodos, sendo no domínio do tempo ou da frequência, representando o domínio de operação do motor.

Os dados a serem utilizados são divididos aleatoriamente em 2 grupos: dados de treinamento e dados de teste. A proporção com que os dados são separados nestes grupos será de 80% e 20%, respectivamente. Essa proporção será mantida para as duas redes e para os 3 tipos diferentes de falhas a serem analisadas.

Serão duas análises com cada rede. Na primeira análise será verificado o desempenho na classificação de dois padrões: motor com falha e motor saudável. A segunda análise será realizada considerando o motor saudável e todas as falhas em

cada um dos casos. No caso da falha de rolamentos serão analisadas falhas de Desgaste 15 minutos, 30 minutos, 60 minutos, 90 minutos. Para falha de estator serão curtos-circuitos nos valores 1%, 3%, 5% e 10%. Para falha no rotor serão: 1 barra quebrada, 2 barras quebradas, 4 barras quebradas e 2/2 barras quebradas.

Os parâmetros utilizados para se configurar a rede *Perceptron* Multicamadas estão presentes na Tabela 6. Tais parâmetros foram usados nas duas análises mencionadas anteriormente.

Tabela 6 – Parâmetros da rede *Perceptron* Multicamadas

Parâmetros	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</i> com Levenberg-Marquardt

Foi utilizada uma camada oculta durante o processo de classificação. A função de ativação escolhida foi baseada em testes realizadas, sendo que a tangente hiperbólica aquela que apresentou melhor resultado.

A função *backpropagation*, de acordo com Godoy (2016), tem a finalidade de encontrar as derivadas da função de erro com relação aos pesos e bias da RNA.

Foram realizados testes para se determinar qual a quantidade de neurônios em cada camada que apresentaria o melhor resultado. Partindo-se de um valor mínimo de neurônios em cada camada, os mesmos foram incrementados e foi analisado o desempenho da rede em cada caso. A Tabela 7 representa a topologia final que apresentou os melhores resultados no caso da classificação da primeira análise, sendo motor saudável e com falha.

Tabela 7 – Topologia PMC – Classificação Simples

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

O número de neurônios está relacionado com a capacidade de aprendizagem da rede. Quanto maior o número de neurônios, mais a rede terá condições de mapear

o conjunto de entrada/saída. Entretanto, se este número for excessivo, esta ode apresentar problemas de generalização de aprendizagem. Os números de neurônios presentes nas tabelas 7 e 8 foram escolhidos de forma a evitar os problemas de generalização, além de apresentarem bons resultados para classificação.

A topologia obtida por testes para o caso da multiclassificação, analisando todas as falhas, é apresentada na Tabela 8.

Tabela 8 – Topologia PMC – Multiclassificação

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

A função de ativação da camada de saída foi utilizada como rampa linear devido a escolha dos valores na camada de saída para se realizar a classificação. Para a classificação simples de situação falha/saudável, foi utilizado uma sequência, como mostrada na Tabela 9.

Tabela 9 – Classificação Simples

Característica	Saída Desejada
Saudável	0 1
Falha	1 0

No caso de classificação de múltiplas falhas, a característica da camada de saída utilizada é representada na Tabela 10, sendo do tipo *one of C-class*.

Tabela 10 – Multiclassificação

Característica	Saída Desejada
Saudável	0 0 0 0 1
Falha inicia	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, a topologia utilizada envolveu os parâmetros apresentados na Tabela 11, tanto para análise simples quanto para a multiclassificação para todas as falhas analisadas.

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

De acordo com Godoy (2016), caso os valores do parâmetro de vigilância (ρ) sejam elevados, isto implica na formação de um número maior de categorias na camada de saída, os quais degradam os resultados de classificação. A taxa de aprendizado (β) é diretamente proporcional a velocidade de aprendizado da rede. Tal valor foi definido como 1 para uma rápida aprendizagem.

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

5 RESULTADOS EXPERIMENTAIS

Nesta seção serão apresentados os resultados obtidos a partir da implementação dos métodos descritos no capítulo 4, visando detectar a presença e severidade de falhas em MITs.

Os dados de entrada utilizados do banco de dados foram sinais de corrente do estator, estando este no domínio do tempo e no domínio da frequência pelas transformadas rápidas de Fourier e transformada Wavelet. Os resultados obtidos serão expostos a seguir através das matrizes de confusão construídas.

Os resultados apresentados nas Tabelas são provenientes dos melhores valores obtidos em sequência de 10 testes.

5.1 FALHA CURTO-CIRCUITO NO ESTATOR

Nesta seção serão apresentados os resultados de classificação dos dados de falha de curto-circuito no estator. Os resultados são divididos de acordo com os métodos de pré-processamento aplicados.

5.1.1 Corrente domínio do tempo – Classificação Simples

A Tabela 12 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 6480 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 5184 dados para treinamento e 1296 dados para teste. Após a rede ser testada foi gerada a matriz de confusão, na qual é possível verificar a precisão com que o classificador distingue uma classe de outra.

Tabela 12 – Matriz de confusão classificador simples MM440

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	226	2	250	2
Falha	28	1040	4	1040

A partir da matriz de confusão apresentada na Tabela 12 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 97,7%, sendo que atingiu 99,8% de precisão para classificação de falha e 88,97% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 98,7%, sendo que atingiu 99,8% de precisão para classificação de falha e 99,2% de precisão para análise de motor saudável. Nesta situação a rede FAM apresentou melhores resultados do que a rede PMC.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 6480 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 5184 amostras para treinamento e 1296 para teste. A matriz confusão obtida é apresentada na Tabela 13.

Tabela 13 – Matriz de confusão classificador simples G110

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	187	4	223	37
Falha	79	1026	70	966

A partir da matriz de confusão apresentada na Tabela 13 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 93,6%, sendo que atingiu 99,6% de precisão para classificação de falha e 70,3% de precisão para análise de motor saudável. Neste caso a rede apresentou uma dificuldade ainda maior para se identificar quais dados eram saudáveis.

A rede *Fuzzy* ARTmap obteve precisão global de 91,75%, atingindo 96,31% de precisão para classificação de falha e 76,11% de precisão para análise de motor saudável. Neste caso a rede PMC apresentou melhores e mais consistentes do que a rede FAM. A rede conseguiu discernir melhor os dados saudáveis do que a rede PMC, mas teve menor desempenho em classificar os dados com falhas.

A Tabela 14 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 6930 amostras, sendo 5544 utilizadas para treinamento e 1386 para teste.

Tabela 14 – Matriz de confusão classificador simples ATV

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	215	16	210	70
Falha	61	1094	66	1040

A partir da matriz de confusão apresentada da Tabela 14 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 94,4%, sendo que atingiu 98,56% de precisão para classificação de falha e 77,89% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 90,19%, sendo que atingiu 93,7% de precisão para classificação de falha e 76,09% de precisão para análise de motor saudável. Novamente a rede PMC demonstrou maior facilidade em se realizar a classificação simples entre motor com falha e motor saudável.

Através desses dados observa-se que para dados no domínio do tempo, as redes apresentam dificuldade em classificar os dados de motor saudável.

5.1.2 Corrente domínio do tempo – Multiclassificação

A Tabela 15 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 15 – Matriz de confusão multiclassificador - MM440

PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	250	178	50	159	68	250	5	2	4	0
CC 3%	0	86	1	0	0	5	231	4	2	0
CC 5%	1	4	214	2	2	8	1	246	1	3
CC 10%	0	0	0	86	1	4	5	2	245	10
S.	2	4	1	0	187	0	0	0	0	263

A partir da matriz de confusão apresentada na Tabela 15 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 63,5%, enquanto a rede FAM apresentou uma precisão de 95,3%.

Ainda de acordo com a Tabela 15, observa-se que a rede PMC obteve 72,5% de precisão para classificação de motor saudável, além de apresentar índices de 98,8%, 31,6%, 80,5% e 34,8% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente. Através da matriz confusão é possível observar que a rede PMC não conseguiu teve graves problemas identificando os dados de falha e saudáveis como falha de 1%, apesar de ter classificado corretamente os mesmos.

No mesmo contexto a FAM apresentou precisão de 93,63%, 95,45%, 97,62% e 97,22% para as falhas, respectivamente, além de uma precisão de 93,6% para diagnóstico de motor saudável. A rede apresentou ótimo desempenho em separar os dados de falha do motor saudável, diferente do que foi observado na seção 5.1.1.

A Tabela 16 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 60,7%, enquanto a rede FAM obteve uma precisão de 88,27%.

Tabela 16 – Matriz de confusão multiclassificador - G110

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	261	165	49	157	132	235	1	1	2	3
CC 3%	0	101	0	0	0	10	236	5	4	6
CC 5%	0	1	196	5	0	7	3	207	15	1
CC 10%	0	0	0	100	0	10	3	14	259	3
S.	0	0	0	0	129	25	3	0	5	238

Ainda de acordo com a Tabela 16, observa-se que a rede PMC obteve 49,4% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 37,8%, 80% e 38,2% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente. Novamente nota-se a dificuldade da rede de se diferenciar as falhas do curto-circuito de 1%.

No mesmo contexto a FAM apresentou precisão de 81,88%, 95,93%, 91,19% e 90,88% para as falhas, respectivamente, além de uma precisão de 94,82% para diagnóstico de motor saudável.

Com relação a rede FAM, neste caso a matriz confusão apresenta um resultado menos preciso daquele com o motor acionado pelo inversor MM440, sendo esta diferença dada na análise das falhas

A Tabela 17 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 50,4%, enquanto a rede FAM obteve uma precisão de 86,07%.

Tabela 17 – Matriz de confusão multiclassificador - ATV

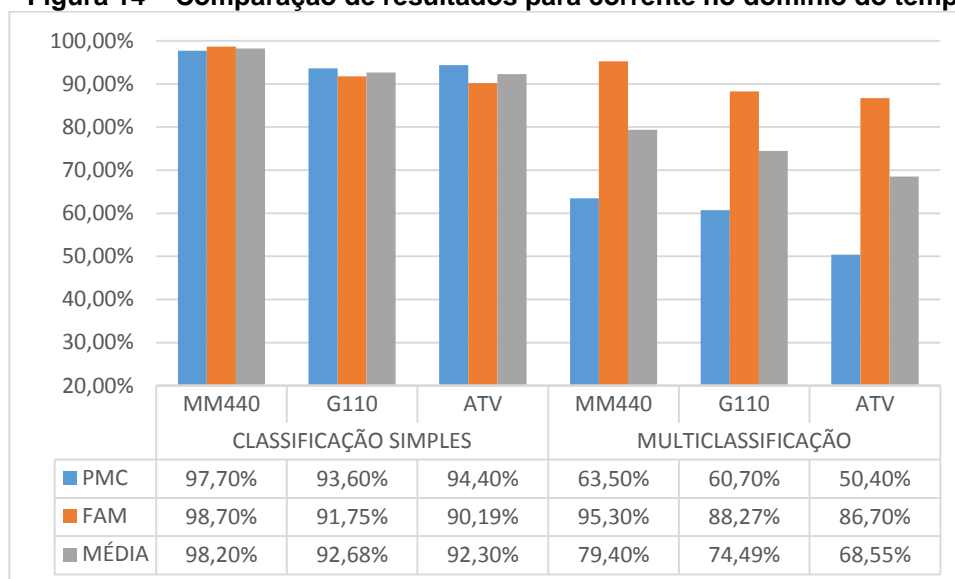
PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	298	255	121	180	122	245	18	1	4	8
CC 3%	0	36	0	0	0	8	240	5	7	4
CC 5%	0	0	139	0	2	17	28	230	13	4
CC 10%	1	0	0	76	0	9	12	12	223	11
S.	2	0	3	2	149	5	3	8	2	255

Ainda de acordo com a Tabela 17, observa-se que a rede PMC obteve 54,6% de precisão para classificação de motor saudável, além de apresentar índices de 99%, 12,4%, 52,9% e 29,5% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente. No mesmo contexto a FAM apresentou precisão de 86,27%, 79,73%, 85,19% e 89,56% para as falhas, respectivamente, além de uma precisão de 90,43% para diagnóstico de motor saudável.

5.1.3 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy* ARTmap, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:

Figura 14 – Comparação de resultados para corrente no domínio do tempo

Fonte: Autoria Própria.

Na Figura 14 são resumidas as precisões de acerto globais para classificação simples e multiclassificação, com o motor ativado pelos 3 inversores e dados classificados pelas 2 redes.

Através da Figura é possível observar que para uma situação em que são atribuídas duas classes, falha e saudável, um pré-processamento utilizando apenas o PCA e o sinal no domínio do tempo implicam em resultados aceitáveis, dependendo do contexto de precisão desejado. Quando são atribuídas múltiplas classes, nestes dados observa-se um bom decaimento de precisão. Tal decaimento é mais visível na rede PMC do que na rede FMA, que apresenta uma certa consistência nos resultados.

Para falhas de curto-circuito no estator com a corrente no domínio do tempo, a rede FAM apresentou

Apenas esta comparação não é um indicativo final de qual topologia de classificação é a mais precisa, pois como mostrado nas matrizes de confusão anteriores, a rede pode ter alta precisão para identificar um tipo de falha mas confunde dados de falha com dados saudáveis, o que a torna menos viável.

5.1.4 Corrente domínio da frequência – FFT – Classificação Simples

A Tabela 18 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 6480 amostras do motor sendo acionado pelo inversor

MM440. No total foram usados 5184 dados para treinamento e 1296 dados para teste. Após a rede ser testada foi gerada a matriz de confusão, na qual é possível verificar a precisão com que o classificador distingue uma classe de outra.

Tabela 18 – Matriz de confusão classificador simples MM440

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	850	0	267	5
Falha	0	3528	2	1022

A partir da matriz de confusão apresentada na Tabela 18 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 99,46%, sendo que atingiu 99,51% de precisão para classificação de falha e 99,26% de precisão para análise de motor saudável. Neste caso a rede PMC apresentou melhores resultados do que a rede FAM.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 6480 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 5184 amostras para treinamento e 1296 para teste. A matriz confusão obtida é apresentada na Tabela 19.

Tabela 19 – Matriz de confusão classificador simples G110

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	846	0	238	14
Falha	0	3532	13	1031

A partir da matriz de confusão apresentada na Tabela 19 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 97,92%, atingindo 98,66% de precisão para classificação de falha e 94,82% de precisão para análise de motor saudável.

A Tabela 20 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 6930 amostras, sendo 5544 utilizadas para treinamento e 1386 para teste.

Tabela 20 – Matriz de confusão classificador simples ATV

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	958	0	266	8
Falha	0	3870	13	1099

A partir da matriz de confusão apresentada na Tabela 20 é possível observar que a rede *Perceptron* Multicamadas novamente obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 98,49%, sendo que atingiu 99,28% de precisão para classificação de falha e 95,34% de precisão para análise de motor saudável. Novamente a rede PMC demonstrou maior facilidade em se realizar a classificação simples entre motor com falha e motor saudável.

5.1.5 Corrente domínio da frequência – FFT – Multiclassificação

A Tabela 21 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 21 – Matriz de confusão multiclassificador - MM440

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	227	10	4	0	0	259	0	0	0	0
CC 3%	0	250	1	0	0	0	243	22	0	0
CC 5%	0	0	244	0	0	0	10	226	0	0
CC 10%	0	0	0	275	0	0	0	0	268	0
S.	0	0	0	0	285	0	0	0	0	268

A partir da matriz de confusão apresentada na Tabela 21 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 98,8%, enquanto a rede FAM apresentou uma precisão de 97,53%. Nesta situação a rede PMC apresentou maior precisão que a rede FAM.

Ainda de acordo com a Tabela 21, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 96,15%, 98% e 100% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente. A rede apresentou mais dificuldade em distinguir a primeira falha das demais, mas classificou com precisão o restante dos dados.

No mesmo contexto a FAM apresentou precisão de 100%, 96,05%, 91,13% e 100% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável. Neste caso a rede conseguiu diferenciar com precisão um motor com falha de um saudável, mas apresentou erros ao diferenciar uma falha de outra.

A Tabela 22 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 99,7%, enquanto a rede FAM obteve uma precisão de 94,6%.

Tabela 22 – Matriz de confusão multiclassificador - G110

PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	249	0	2	2	0	251	0	0	0	0
CC 3%	0	275	0	0	0	0	274	0	0	0
CC 5%	0	0	263	0	0	0	0	212	36	0
CC 10%	0	0	0	257	0	0	0	34	226	0
S.	0	0	0	0	248	0	0	0	0	263

Ainda de acordo com a Tabela 22, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 100%, 99,25% e 99,23% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente, mantendo o comportamento de análise observado para o motor acionado pelo inversor MM440.

No mesmo contexto a FAM apresentou precisão de 100%, 100%, 86,18% e 26,26% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

Observa-se que para este inversor a rede PMC apresentou resultados gerais bem mais satisfatórios que a FAM.

A Tabela 23 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 99,8%, enquanto a rede FAM obteve uma precisão de 98,99%.

Tabela 23 – Matriz de confusão multiclassificador - ATV

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	274	1	0	0	0	262	0	0	0	2
CC 3%	2	257	0	0	0	6	272	0	0	0
CC 5%	0	0	294	0	0	0	0	286	3	0
CC 10%	0	0	0	265	0	0	0	0	262	1
S.	0	0	0	0	293	0	0	0	2	290


Ainda de acordo com a Tabela 23, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 99,3%, 99,6%, 100% e 100% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente. No mesmo contexto a FAM apresentou precisão de 97,76%, 100%, 100% e 98,132% para as falhas, respectivamente, além de uma precisão de 98,97% para diagnóstico de motor saudável.

Observa-se pela matriz confusão que a FAM foi capaz de classificar as falhas e diferencia-las do motor saudável com alta precisão para o acionamento pelo inversor ATV.

5.1.6 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy* ARTmap, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:

Figura 15 – Comparação de resultados para corrente - FFT

Fonte: Autoria Própria.

Através da Figura 15 é possível observar que as redes tiveram alto nível de precisão ao se realizar tanto a classificação simples quanto a multiclassificação. No caso da rede FAM, apesar de ter apresentado um menor desempenho geral novamente se mostrou mais consistente do que a rede PMC.

Também é possível observar a influência de cada inversor no contexto da falha analisada, sendo que neste caso o inversor G110 foi o que aparentou ser mais difícil de se classificar.

5.1.7 Corrente domínio do tempo – Wavelet – Classificação Simples

A Tabela 24 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 6480 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 5184 dados para treinamento e 1296 dados para teste.

Tabela 24 – Matriz de confusão classificador simples MM440

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	257	0	248	4
Falha	1	1038	5	1039

A partir da matriz de confusão apresentada na Tabela 24 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,9%, sendo que atingiu 100% de precisão para classificação de falha e 99,6% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 99,3%, sendo que atingiu 99,62% de precisão para classificação de falha e 98,02% de precisão para análise de motor saudável.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 6480 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 5184 amostras para treinamento e 1296 para teste. A matriz confusão obtida é apresentada na Tabela 25.

Tabela 25 – Matriz de confusão classificador simples G110

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	241	0	240	4
Falha	5	1050	9	1043

A partir da matriz de confusão apresentada na Tabela 25 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,6%, sendo que atingiu 100% de precisão para classificação de falha e 98% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 98,99%, atingindo 99,62% de precisão para classificação de falha e 96,39% de precisão para análise de motor saudável.

A Tabela 26 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 6930 amostras, sendo 5544 utilizadas para treinamento e 1386 para teste.

Tabela 26 – Matriz de confusão classificador simples ATV

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	280	0	263	5
Falha	0	1106	0	1118

A partir da matriz de confusão apresentada da Tabela 26 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 99,64%, sendo que atingiu 99,55% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. Novamente a rede PMC demonstrou maior facilidade em se realizar a classificação simples entre motor com falha e motor saudável.

5.1.8 Corrente domínio do tempo – Wavelet – Multiclassificação

A Tabela 27 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 27 – Matriz de confusão multiclassificador - MM440

PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	275	2	2	2	0	264	0	0	0	0
CC 3%	0	228	0	0	0	4	269	0	0	0
CC 5%	0	0	250	0	0	9	0	235	0	0
CC 10%	0	0	0	279	0	7	0	0	244	0
S.	0	0	0	0	258	7	0	0	0	257

A partir da matriz de confusão apresentada na Tabela 27 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,5%, enquanto a rede FAM apresentou uma precisão de 97,92%.

Ainda de acordo com a Tabela 27, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 99,1%, 99,2% e 99,3% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente.

No mesmo contexto a FAM apresentou precisão de 90,72%, 100%, 100% e 100% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

A Tabela 28 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 99,1%, enquanto a rede FAM obteve uma precisão de 97,99%.

Tabela 28 – Matriz de confusão multiclassificador - G110

PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	244	1	4	5	2	249	0	0	0	0
CC 3%	0	282	0	0	0	7	248	1	0	0
CC 5%	0	0	239	0	0	7	0	234	0	0
CC 10%	0	0	0	263	0	3	0	4	273	0
S.	0	0	0	0	256	1	0	3	0	266

Ainda de acordo com a Tabela 28, observa-se que a rede PMC obteve 99,2% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 99,6%, 98,4% e 98,1% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente. Novamente nota-se a dificuldade da rede de se diferenciar as falhas do curto-circuito de 1%.

No mesmo contexto a FAM apresentou precisão de 93,26%, 100%, 96,69% e 100% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

A Tabela 29 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 99,5%, enquanto a rede FAM obteve uma precisão de 99,43%.

Tabela 29 – Matriz de confusão multiclassificador - ATV


PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	281	2	2	2	1	243	0	1	1	0
CC 3%	0	274	0	0	0	0	278	4	0	0
CC 5%	0	0	242	0	0	0	0	269	0	0
CC 10%	0	0	0	299	0	0	0	1	303	0
S.	0	0	0	0	283	0	0	1	0	285

Ainda de acordo com a Tabela 29, observa-se que a rede PMC obteve 99,6% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 99,3%, 99,2% e 99,3% para as falhas de curto-circuito de 1%, 3%, 5% e 10%, respectivamente. No mesmo contexto a FAM apresentou precisão de 100%, 100%, 97,46% e 99,67% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

5.1.9 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy ARTmap*, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:



Fonte: Autoria Própria.

Através da Figura 16 é possível observar que as redes tiveram alto nível de precisão ao se realizar tanto a classificação simples quanto a multiclassificação. Neste caso observou-se uma elevada consistência na classificação realizada por ambas as redes, além de um alto nível de desempenho.

5.2 FALHA DE BARRAS QUEBRADAS NO ROTOR

Nesta seção serão apresentados os resultados de classificação dos dados de falha de barras quebradas no rotor. Os resultados são divididos de acordo com os métodos de pré-processamento aplicados.

5.2.1 Corrente domínio do tempo – Classificação Simples

A Tabela 30 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 12780 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 10224 dados para treinamento e 2556 dados para teste.

Tabela 30 – Matriz de confusão classificador simples MM440

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	492	0	459	67
Falha	0	2064	90	1940

A partir da matriz de confusão apresentada na Tabela 30 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 93,86%, sendo que atingiu 96,66% de precisão para classificação de falha e 83,61% de precisão para análise de motor saudável.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 12240 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 9792 amostras para treinamento e 2448 para teste. A matriz confusão obtida é apresentada na Tabela 31.

Tabela 31 – Matriz de confusão classificador simples G110

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	381	1942	430	60
Falha	124	1	78	1880

A partir da matriz de confusão apresentada na Tabela 31 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 94,9%, sendo que atingiu 99,9% de precisão para classificação de falha e 75,4% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 94,36%, atingindo 96,91% de precisão para classificação de falha e 84,65% de precisão para análise de motor saudável.

A Tabela 32 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 10800 amostras, sendo 8640 utilizadas para treinamento e 2160 para teste.

Tabela 32 – Matriz de confusão classificador simples ATV

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	426	1729	270	144
Falha	5	0	241	1505

A partir da matriz de confusão apresentada da Tabela 32 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,8%, sendo que atingiu 100% de precisão para classificação de falha e 98,8% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 82,18%, sendo que atingiu 91,27% de precisão para classificação de falha e 52,85% de precisão para análise de motor saudável.

5.2.2 Corrente domínio do tempo – Multiclassificação

A Tabela 33 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e

do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 33 – Matriz de confusão multiclassificador - MM440

PMC						FAM				
Classes	1 B.	2 B.	4 B.	2/2 B.	S.	1 B.	2 B.	4 B.	2/2 B.	S.
1 B.	509	274	229	232	256	462	10	9	3	18
2 B.	0	212	0	0	0	7	495	8	0	17
4 B.	0	0	288	0	0	11	0	471	2	14
2/2 B.	0	0	0	290	0	12	1	16	461	15
S.	0	0	1	0	265	6	6	25	10	477

A partir da matriz de confusão apresentada na Tabela 33 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 61,2%, enquanto a rede FAM apresentou uma precisão de 92,57%.

Ainda de acordo com a Tabela 33, observa-se que a rede PMC obteve 50,9% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 43,6%, 55,6% e 55,6% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente.

No mesmo contexto a FAM apresentou precisão de 92,77%, 96,68%, 89,04% e 96,85% para as falhas, respectivamente, além de uma precisão de 88,17% para diagnóstico de motor saudável.

A Tabela 34 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 60,7%, enquanto a rede FAM obteve uma precisão de 88,44%.

Tabela 34 – Matriz de confusão multiclassificador - G110

PMC						FAM				
Classes	1 B.	2 B.	4 B.	2/2 B.	S.	1 B.	2 B.	4 B.	2/2 B.	S.
1 B.	500	270	166	124	379	402	12	27	16	10
2 B.	0	203	1	0	0	7	398	34	32	4
4 B.	1	5	340	8	2	0	1	505	6	1
2/2 B.	2	0	2	349	0	2	8	50	430	1
S.	1	0	0	0	95	8	6	46	12	430

Ainda de acordo com a Tabela 34, observa-se que a rede PMC obteve 20% de precisão para classificação de motor saudável, além de apresentar índices de 99,2%, 42,5%, 66,8%, 72,6% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente.

No mesmo contexto a FAM apresentou precisão de 95,94%, 93,65%, 76,28% e 86,69% para as falhas, respectivamente, além de uma precisão de 96,41% para diagnóstico de motor saudável.

A Tabela 35 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 32,8%, enquanto a rede FAM obteve uma precisão de 79,49%.

Tabela 35 – Matriz de confusão multiclassificador - ATV

Classes	PMC					FAM				
	1 B.	2 B.	4 B.	2/2 B.	S.	1 B.	2 B.	4 B.	2/2 B.	S.
1 B.	432	417	370	260	391	362	12	26	10	15
2 B.	0	16	0	0	0	45	320	25	6	23
4 B.	0	0	31	0	0	38	28	343	11	23
2/2 B.	3	5	1	160	0	30	19	31	364	1
S.	1	2	1	1	69	45	12	26	3	328

Ainda de acordo com a Tabela 35, observa-se que a rede PMC obteve 15% de precisão para classificação de motor saudável, além de apresentar índices de 99,1%, 3,6%, 7,7%, 38% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente.


No mesmo contexto a FAM apresentou precisão de 69,62%, 81,84%, 76,05% e 92,39% para as falhas, respectivamente, além de uma precisão de 81,19% para diagnóstico de motor saudável. Neste caso a rede FAM apresentou uma dificuldade geral para realizar a classificação dos dados.

5.2.3 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy* ARTmap, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:

Figura 17 – Comparação de resultados para corrente no domínio do tempo



Fonte: Autoria Própria.

Através da Figura 17 é possível observar que as redes tiveram alto nível de precisão ao se realizar tanta a classificação simples quanto a multiclassificação. Isso demonstra a eficácia da FFT como pré-processamento para se utilizar em redes classificadoras de dados.

5.2.4 Corrente domínio da frequência – FFT – Classificação Simples

A Tabela 36 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 12780 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 10224 dados para treinamento e 2556 dados para teste.

Tabela 36 – Matriz de confusão classificador simples MM440

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	467	0	517	5
Falha	0	2089	7	2027

A partir da matriz de confusão apresentada na Tabela 36 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. A rede *Fuzzy ARTmap* obteve precisão global de 99,3%, sendo que atingiu 99,75% de precisão para classificação de falha e 98,66% de precisão para análise de motor saudável.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 12240 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 9792 amostras para treinamento e 2448 para teste. A matriz de confusão obtida é apresentada na Tabela 37.

Tabela 37 – Matriz de confusão classificador simples G110

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	496	0	479	11
Falha	0	1952	11	1947

A partir da matriz de confusão apresentada na Tabela 37 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. A rede *Fuzzy ARTmap* obteve precisão global de 99,1%, atingindo 99,44% de precisão para classificação de falha e 97,76% de precisão para análise de motor saudável.

A Tabela 38 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 10800 amostras, sendo 8640 utilizadas para treinamento e 2160 para teste.

Tabela 38 – Matriz de confusão classificador simples ATV

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	440	0	313	133
Falha	0	1720	168	1546

A partir da matriz de confusão apresentada na Tabela 38 é possível observar que a rede *Perceptron* Multicamadas novamente obteve precisão global de 100%,

sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 86,06%, sendo que atingiu 92,08% de precisão para classificação de falha e 65,07% de precisão para análise de motor saudável. Neste caso a rede apresentou baixa precisão para classificar os dados de motor saudável.

5.2.5 Corrente domínio da frequência – FFT – Multiclassificação

A Tabela 39 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 39 – Matriz de confusão multiclassificador - MM440

PMC						FAM				
Classes	1 B.	2 B.	4 B.	2/2 B.	S.	1 B.	2 B.	4 B.	2/2 B.	S.
1 B.	529	0	0	0	0	500	4	0	0	0
2 B.	0	485	0	0	0	0	508	0	0	0
4 B.	0	0	518	0	0	0	0	512	0	0
2/2 B.	0	0	0	505	0	0	0	0	516	0
S.	0	0	0	0	519	0	0	0	0	516

A partir da matriz de confusão apresentada na Tabela 39 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, enquanto a rede FAM apresentou uma precisão de 99,84%.

Ainda de acordo com a Tabela 39, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, e 100% de precisão para classificação de todas as falhas.

No mesmo contexto a FAM apresentou precisão de 100%, 99,22%, 100% e 100% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável. Neste caso a rede conseguiu diferenciar com precisão quase perfeita todas as falhas e dados de motor saudável.

A Tabela 40 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 98,3%, enquanto a rede FAM obteve uma precisão de 98,41%.

Tabela 40 – Matriz de confusão multiclassificador - G110

Classes	PMC					FAM				
	1 B.	2 B.	4 B.	2/2 B.	S.	1 B.	2 B.	4 B.	2/2 B.	S.
1 B.	484	0	22	20	0	462	0	4	13	0
2 B.	0	479	0	0	0	6	512	0	2	0
4 B.	0	0	475	0	0	0	0	512	0	0
2/2 B.	0	0	0	458	0	3	0	9	468	0
S.	0	0	0	0	510	0	0	2	0	455

Ainda de acordo com a Tabela 40, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 100%, 95,6% e 95,8% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente.

No mesmo contexto a FAM apresentou precisão de 98,09%, 100%, 97,15% e 96,89% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

A Tabela 41 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 58,4%, enquanto a rede FAM obteve uma precisão de 79,81%.

Tabela 41 – Matriz de confusão multiclassificador - ATV

Classes	PMC					FAM				
	1 B.	1 B.	1 B.	1 B.	1 B.	1 B.	1 B.	1 B.	1 B.	1 B.
1 B.	417	297	130	150	318	362	73	4	1	25
2 B.	2	137	0	0	0	34	302	6	1	87
4 B.	0	0	285	0	0	0	1	373	33	0
2/2 B.	0	0	0	289	0	0	3	33	386	0
S.	0	1	0	0	134	24	107	4	0	301


Ainda de acordo com a Tabela 41, observa-se que a rede PMC obteve 99,5% de precisão para classificação de motor saudável, além de apresentar índices de

31,5%, 68,7%, 65,8% e 29,6% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente. No mesmo contexto a FAM apresentou precisão de 86,19%, 62,14%, 88,81% e 91,69% para as falhas, respectivamente, além de uma precisão de 72,88% para diagnóstico de motor saudável.

5.2.6 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy* ARTmap, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:



Fonte: Autoria Própria.

Através da Figura 18 é possível observar que as redes tiveram alto nível de precisão ao se realizar tanto a classificação simples quanto a multiclassificação, com exceção do motor acionado por inversor ATV.

5.2.7 Corrente domínio do tempo – Wavelet – Classificação Simples

A Tabela 42 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de

dados utilizado é composto por 12780 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 10224 dados para treinamento e 2556 dados para teste.

Tabela 42 – Matriz de confusão classificador simples MM440

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	508	0	502	8
Falha	0	2048	5	2041

A partir da matriz de confusão apresentada na Tabela 42 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 99,49%, sendo que atingiu 99,61% de precisão para classificação de falha e 99,01% de precisão para análise de motor saudável.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 12240 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 9792 amostras para treinamento e 2448 para teste. A matriz confusão obtida é apresentada na Tabela 43.

Tabela 43 – Matriz de confusão classificador simples G110

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	492	0	475	1
Falha	0	1956	3	1969

A partir da matriz de confusão apresentada na Tabela 43 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 99,84%, atingindo 99,95% de precisão para classificação de falha e 99,37% de precisão para análise de motor saudável.

A Tabela 44 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 10800 amostras, sendo 8640 utilizadas para treinamento e 2160 para teste.

Tabela 44 – Matriz de confusão classificador simples ATV

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	415	5	431	6
Falha	2	1738	9	1714

A partir da matriz de confusão apresentada da Tabela 44 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,7%, sendo que atingiu 99,7% de precisão para classificação de falha e 99,5% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 99,31%, sendo que atingiu 99,65% de precisão para classificação de falha e 97,9% de precisão para análise de motor saudável.

5.2.8 Corrente domínio do tempo– Wavelet – Multiclassificação

A Tabela 45 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 45 – Matriz de confusão multiclassificador - MM440

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	503	0	1	0	1	517	2	0	0	0
CC 3%	0	527	0	0	0	0	506	0	1	0
CC 5%	0	0	538	0	0	0	0	548	1	0
CC 10%	0	0	0	501	0	1	0	0	471	0
S.	0	0	0	0	485	1	0	0	0	508

A partir da matriz de confusão apresentada na Tabela 45 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,9%, enquanto a rede FAM apresentou uma precisão de 99,77%.

Ainda de acordo com a Tabela 45, observa-se que a rede PMC obteve 99,8% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 100%, 99,8% e 100% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente.

No mesmo contexto a FAM apresentou precisão de 99,61%, 99,61%, 100% e 98,58% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

A Tabela 46 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 98%, enquanto a rede FAM obteve uma precisão de 98,9%.

Tabela 46 – Matriz de confusão multiclassificador - G110

Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	454	28	6	6	8	475	2	4	0	0
CC 3%	0	477	0	0	0	0	473	0	1	0
CC 5%	0	0	475	0	0	0	6	487	0	0
CC 10%	0	0	0	493	0	0	6	2	463	0
S.	0	0	0	0	501	0	4	1	1	523

Ainda de acordo com a Tabela 46, observa-se que a rede PMC obteve 98,4% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 94,5%, 98,8% e 98,4% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente.

No mesmo contexto a FAM apresentou precisão de 100%, 96,33%, 98,58% e 99,57% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

Com relação a rede FAM, neste caso a matriz confusão apresenta um resultado menos preciso daquele com o motor acionado pelo inversor MM440, sendo esta diferença dada na análise das falhas

A Tabela 47 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da

classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 99,6%, enquanto a rede FAM obteve uma precisão de 98,88%.

Tabela 47 – Matriz de confusão multiclassificador - ATV


Classes	PMC					FAM				
	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	434	8	0	1	0	417	2	2	0	0
CC 3%	0	414	0	0	0	0	427	1	1	3
CC 5%	0	0	438	0	0	1	0	445	2	5
CC 10%	0	0	0	427	0	0	1	0	434	0
S.	0	0	0	0	438	1	0	3	2	413

Ainda de acordo com a Tabela 47, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 98,1%, 100% e 99,8% para as falhas de 1, 2, 4 e 2/2 barras quebradas, respectivamente. No mesmo contexto a FAM apresentou precisão de 99,52%, 99,3%, 98,67% e 98,86% para as falhas, respectivamente, além de uma precisão de 98,1% para diagnóstico de motor saudável.

5.2.9 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy* ARTmap, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:

Figura 19 – Comparação de resultados para corrente - Wavelet

Fonte: Autoria Própria.

Através da Figura 19 é possível observar que as redes tiveram alto nível de precisão ao se realizar tanto a classificação simples quanto a multiclassificação. Neste caso ambas as redes apresentaram desempenho e consistência elevados.

5.3 FALHA DE DESGASTES NOS ROLAMENTOS

Nesta seção serão apresentados os resultados de classificação dos dados de falha de desgastes nos rolamentos.

5.3.1 Corrente domínio do tempo – Classificação Simples

A Tabela 48 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 6480 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 5184 dados para treinamento e 1296 dados para teste.

Tabela 48 – Matriz de confusão classificador simples MM440

	PMC		FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	255	0	200	52
Falha	0	1041	79	965

A partir da matriz de confusão apresentada na Tabela 48 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 89,89%, sendo que atingiu 94,89% de precisão para classificação de falha e 71,68% de precisão para análise de motor saudável.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 6480 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 5184 amostras para treinamento e 1296 para teste. A matriz confusão obtida é apresentada na Tabela 49.

Tabela 49 – Matriz de confusão classificador simples G110

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	243	0	216	44
Falha	3	1050	47	989

A partir da matriz de confusão apresentada na Tabela 49 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,8%, sendo que atingiu 100% de precisão para classificação de falha e 98,8% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 92,98%, atingindo 95,74% de precisão para classificação de falha e 82,13% de precisão para análise de motor saudável.

A Tabela 50 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 6930 amostras, sendo 5544 utilizadas para treinamento e 1386 para teste.

Tabela 50 – Matriz de confusão classificador simples ATV

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	260	5	238	71
Falha	13	1108	80	997

A partir da matriz de confusão apresentada da Tabela 50 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 98,7%, sendo que atingiu 99,6% de precisão para classificação de falha e 95,2% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 89,10%, sendo que atingiu 93,35% de precisão para classificação de falha e 74,84% de precisão para análise de motor saudável.

5.3.2 Corrente domínio do tempo – Multiclassificação

A Tabela 51 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 51 – Matriz de confusão multiclassificador - MM440

Classes	PMC					FAM				
	D. 15	D. 30	D. 60	D. 90	S.	D. 15	D. 30	D. 60	D. 90	S.
D. 15	257	197	165	189	149	241	3	6	10	13
D. 30	0	70	0	0	0	1	223	5	7	10
D. 60	0	0	94	0	0	4	5	209	8	14
D. 90	0	0	0	79	0	3	7	2	239	11
S.	0	0	0	0	96	0	3	2	5	265

A partir da matriz de confusão apresentada na Tabela 51 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 46%, enquanto a rede FAM apresentou uma precisão de 90,82%.

Ainda de acordo com a Tabela 39, observa-se que a rede PMC obteve 39,2% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 26,2%, 36,3% e 29,5% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.

No mesmo contexto a FAM apresentou precisão de 96,79%, 92,53%, 93,33% e 88,85% para as falhas, respectivamente, além de uma precisão de 84,66% para diagnóstico de motor saudável.

A Tabela 52 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 46,5%, enquanto a rede FAM obteve uma precisão de 92,52%.

Tabela 52 – Matriz de confusão multiclassificador - G110

Classes	PMC					FAM				
	D. 15	D. 30	D. 60	D. 90	S.	D. 15	D. 30	D. 60	D. 90	S.
D. 15	261	212	129	183	168	277	2	5	6	3
D. 30	0	61	0	0	0	2	242	7	11	8
D. 60	0	0	121	1	0	6	0	246	5	2
D. 90	0	0	0	66	0	1	18	3	227	6
S.	0	0	0	0	94	10	1	0	1	257

Ainda de acordo com a Tabela 52, observa-se que a rede PMC obteve 35,9% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 22,3%, 48,3%, 26,4% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.

No mesmo contexto a FAM apresentou precisão de 92,28%, 92,02%, 94,25% e 90,8% para as falhas, respectivamente, além de uma precisão de 93,12% para diagnóstico de motor saudável.

A Tabela 53 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 45,8%, enquanto a rede FAM obteve uma precisão de 88,89%.

Tabela 53 – Matriz de confusão multiclassificador - ATV

Classes	PMC					FAM				
	D. 15	D. 30	D. 60	D. 90	S.	D. 15	D. 30	D. 60	D. 90	S.
D. 15	286	244	198	78	224	237	4	14	9	0
D. 30	0	46	0	0	0	8	242	21	10	3
D. 60	0	0	71	0	1	5	8	260	17	1
D. 90	0	3	1	184	2	0	10	19	232	4
S.	0	0	0	0	48	4	6	5	6	261

Ainda de acordo com a Tabela 53, observa-se que a rede PMC obteve 17,5% de precisão para classificação de motor saudável, além de apresentar índices de

100%, 15,7%, 26,3%, 70,2% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.

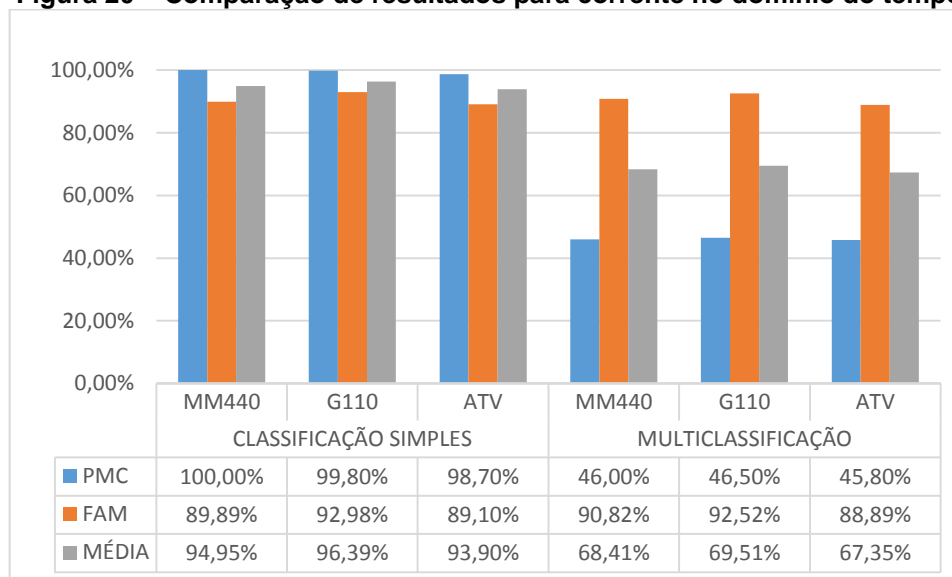
No mesmo contexto a FAM apresentou precisão de 93,31%, 89,63%, 81,5% e 84,67% para as falhas, respectivamente, além de uma precisão de 97,03% para diagnóstico de motor saudável.

5.3.3 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy* ARTmap, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:

Figura 20 – Comparação de resultados para corrente no domínio do tempo



Fonte: Autoria Própria.

Através da Figura 20 é possível observar que as redes tiveram alto nível de precisão ao se realizar a classificação simples dos dados, mas como observado nos casos anteriores, a rede PMC apresentou baixa precisão ao se realizar a multiclassificação dos dados.

5.3.4 Corrente domínio da frequência – FFT – Classificação Simples

A Tabela 54 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 6480 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 5184 dados para treinamento e 1296 dados para teste.

Tabela 54 – Matriz de confusão classificador simples MM440

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	255	0	233	11
Falha	0	1041	5	1047

A partir da matriz de confusão apresentada na Tabela 30 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 98,77%, sendo que atingiu 98,96% de precisão para classificação de falha e 97,9% de precisão para análise de motor saudável.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 6480 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 5184 amostras para treinamento e 1296 para teste. A matriz de confusão obtida é apresentada na Tabela 55.

Tabela 55 – Matriz de confusão classificador simples G110

PMC			FAM	
Classes	Saudável	Falha	Saudável	Falha
Saudável	266	0	281	9
Falha	0	1030	6	1000

A partir da matriz de confusão apresentada na Tabela 55 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 98,85%, atingindo 99,11% de precisão para classificação de falha e 97,91% de precisão para análise de motor saudável.

A Tabela 56 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 6930 amostras, sendo 5544 utilizadas para treinamento e 1386 para teste.

Tabela 56 – Matriz de confusão classificador simples ATV

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	295	0	268	6
Falha	0	1091	3	1109

A partir da matriz de confusão apresentada na Tabela 56 é possível observar que a rede *Perceptron* Multicamadas novamente obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 99,35%, sendo que atingiu 99,46% de precisão para classificação de falha e 98,89% de precisão para análise de motor saudável.

5.3.5 Corrente domínio da frequência – FFT – Multiclassificação

A Tabela 57 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 57 – Matriz de confusão multiclassificador - MM440

Classes	PMC					FAM				
	D. 15	D. 30	D. 60	D. 90	S.	D. 15	D. 30	D. 60	D. 90	S.
D. 15	258	1	12	34	8	201	0	6	45	0
D. 30	0	268	0	0	0	0	257	0	0	2
D. 60	0	0	241	0	0	1	0	246	9	0
D. 90	0	0	0	214	0	33	0	8	218	267
S.	0	0	0	0	260	0	3	0	0	267

A partir da matriz de confusão apresentada na Tabela 57 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 95,8%, enquanto a rede FAM apresentou uma precisão de 91,75%.

Ainda de acordo com a Tabela 57, observa-se que a rede PMC obteve 97% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 99,6%, 95,3% e 86,3% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.

No mesmo contexto a FAM apresentou precisão de 85,53%, 98,85%, 94,62% e 80,15% para as falhas, respectivamente, além de uma precisão de 99,26% para diagnóstico de motor saudável. Neste caso a rede apresentou dificuldade em diferenciar algumas das falhas, mas manteve uma boa precisão geral.

A Tabela 58 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 95,4%, enquanto a rede FAM obteve uma precisão de 95,76%.

Tabela 58 – Matriz de confusão multiclassificador - G110

Classes	PMC					FAM				
	D. 15	D. 30	D. 60	D. 90	S.	D. 15	D. 30	D. 60	D. 90	S.
D. 15	281	29	0	31	0	246	0	0	0	0
D. 30	0	227	0	0	0	3	220	0	24	0
D. 60	0	0	260	0	0	0	0	273	0	0
D. 90	0	0	0	240	0	4	22	0	233	0
S.	0	0	0	0	228	2	0	0	0	269

Ainda de acordo com a Tabela 58, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 88,7%, 100% e 88,6% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.

No mesmo contexto a FAM apresentou precisão de 96,47%, 90,91%, 100% e 90,66% para as falhas, respectivamente, além de uma precisão de 100% para diagnóstico de motor saudável.

A Tabela 59 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 84,5%, enquanto a rede FAM obteve uma precisão de 68,83%.

Tabela 59 – Matriz de confusão multiclassificador - ATV

PMC						FAM				
Classes	D. 15	D. 30	D. 60	D. 90	S.	D. 15	D. 30	D. 60	D. 90	S.
D. 15	287	46	86	82	1	152	28	15	64	8
D. 30	0	238	0	0	0	1	165	6	80	4
D. 60	0	0	180	0	0	12	24	146	93	3
D. 90	0	0	0	199	0	12	24	42	205	8
S.	0	0	0	0	267	0	0	0	8	286

Ainda de acordo com a Tabela 59, observa-se que a rede PMC obteve 99,6% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 83,8%, 67,7% e 70,8% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.


No mesmo contexto a FAM apresentou precisão de 85,88%, 68,46%, 69,86% e 45,56% para as falhas, respectivamente, além de uma precisão de 92,56% para diagnóstico de motor saudável. Neste caso a rede conseguiu apresentar bom desempenho em classificar os dados saudáveis, mas apresentou baixo desempenho em diferenciar as falhas.

5.3.6 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy ARTmap*, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:

Figura 21 – Comparação de resultados para corrente - FFT



Fonte: Autoria Própria.

Através da Figura 21 é possível observar que mesmo com os dados no domínio da frequência, as redes apresentaram uma certa dificuldade em realizar a classificação dos dados do motor acionado pelo inversor ATV.

5.3.7 Corrente domínio do tempo – Wavelet – Classificação Simples

A Tabela 60 representa os resultados obtidos para classificação simples, diferenciando dados de motor com falha de dados de motor saudável. O conjunto de dados utilizado é composto por 6480 amostras do motor sendo acionado pelo inversor MM440. No total foram usados 5184 dados para treinamento e 1296 dados para teste.

Tabela 60 – Matriz de confusão classificador simples MM440

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	248	0	224	5
Falha	0	1048	9	1058

A partir da matriz de confusão apresentada na Tabela 60 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, sendo que atingiu 100% de precisão para classificação de falha e 100% de precisão para análise de motor saudável.

A rede *Fuzzy* ARTmap obteve precisão global de 98,92%, sendo que atingiu 99,52% de precisão para classificação de falha e 96,14% de precisão para análise de motor saudável.

A seguir são apresentados os resultados obtidos utilizando-se um conjunto de dados de 6480 amostras, sendo o motor acionado pelo inversor G110. Neste caso tem-se um total de 5184 amostras para treinamento e 1296 para teste. A matriz de confusão obtida é apresentada na Tabela 61.

Tabela 61 – Matriz de confusão classificador simples G110

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	239	1	223	2
Falha	3	1053	7	1064

A partir da matriz de confusão apresentada na Tabela 43 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,69%, sendo que atingiu 99,9% de precisão para classificação de falha e 98,76% de precisão para análise de motor saudável. Neste caso a rede apresentou uma dificuldade ainda maior para se identificar quais dados eram saudáveis.

A rede *Fuzzy* ARTmap obteve precisão global de 99,31%, atingindo 99,81% de precisão para classificação de falha e 96,95% de precisão para análise de motor saudável.

A Tabela 62 representa a matriz de confusão obtida com os dados do motor sendo acionado pelo inversor ATV. Neste caso tem-se um total de 6930 amostras, sendo 5544 utilizadas para treinamento e 1386 para teste.

Tabela 62 – Matriz de confusão classificador simples ATV

Classes	PMC		FAM	
	Saudável	Falha	Saudável	Falha
Saudável	264	1	242	9
Falha	3	1028	4	1041

A partir da matriz de confusão apresentada da Tabela 62 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 99,7%, sendo que atingiu 99,9% de precisão para classificação de falha e 98,87% de precisão para

análise de motor saudável. A rede *Fuzzy* ARTmap obteve precisão global de 98,9%, sendo que atingiu 99,14% de precisão para classificação de falha e 98,37% de precisão para análise de motor saudável.

5.3.8 Corrente domínio do tempo– Wavelet – Multiclassificação

A Tabela 63 representa os resultados obtidos ao se realizar a multiclassificação de falhas, diferenciando as severidades encontradas nas falhas e do motor saudável. Os dados utilizados são referentes ao motor acionado por inversor MM440, sendo as mesmas amostras utilizadas na classificação simples.

Tabela 63 – Matriz de confusão multiclassificador - MM440

PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	257	0	0	0	0	262	0	0	1	0
CC 3%	0	265	0	0	0	1	264	0	1	0
CC 5%	0	0	259	0	0	0	0	257	1	0
CC 10%	0	0	0	244	0	0	0	0	248	1
S.	0	0	0	0	271	0	0	0	3	251

A partir da matriz de confusão apresentada na Tabela 63 é possível observar que a rede *Perceptron* Multicamadas obteve precisão global de 100%, enquanto a rede FAM apresentou uma precisão de 98,92%.

Ainda de acordo com a Tabela 63, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável e para cada uma das falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.

No mesmo contexto a FAM apresentou precisão de 99,62%, 100%, 100% e 97,64% para as falhas, respectivamente, além de uma precisão de 97,29% para diagnóstico de motor saudável.

A Tabela 64 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor G110. Nesta situação, a rede PMC apresentou uma precisão global de 99,1%, enquanto a rede FAM obteve uma precisão de 96,61%.

Tabela 64 – Matriz de confusão multiclassificador - G110

PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	265	3	0	4	0	282	0	0	0	0
CC 3%	1	244	1	0	0	9	261	0	0	0
CC 5%	0	0	284	0	0	16	1	236	0	0
CC 10%	0	0	0	236	0	6	2	0	241	1
S.	0	0	0	0	255	8	1	0	0	232

Ainda de acordo com a Tabela 64, observa-se que a rede PMC obteve 98,5% de precisão para classificação de motor saudável, além de apresentar índices de 98,9%, 98,4%, 99,6% e 100% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente.

No mesmo contexto a FAM apresentou precisão de 87,85%, 98,49%, 100% e 100% para as falhas, respectivamente, além de uma precisão de 99,57% para diagnóstico de motor saudável.

A Tabela 65 representa a matriz confusão obtida ao se utilizar os dados de motor acionado pelo inversor ATV, utilizando a mesma quantidade de dados da classificação simples. Nesta situação, a rede PMC apresentou uma precisão global de 99,9%, enquanto a rede FAM obteve uma precisão de 98,78%.

Tabela 65 – Matriz de confusão multiclassificador - ATV


PMC						FAM				
Classes	CC 1%	CC 3%	CC 5%	CC 10%	S.	CC 1%	CC 3%	CC 5%	CC 10%	S.
CC 1%	295	0	0	1	0	299	0	1	1	0
CC 3%	0	289	0	0	0	0	245	1	0	0
CC 5%	0	0	283	0	0	0	0	295	1	0
CC 10%	0	0	0	266	0	4	0	3	262	1
S.	0	0	0	0	252	0	0	5	0	268

Ainda de acordo com a Tabela 65, observa-se que a rede PMC obteve 100% de precisão para classificação de motor saudável, além de apresentar índices de 100%, 100%, 100% e 99,6% para as falhas de desgastes de 15, 30, 60 e 90 minutos, respectivamente. No mesmo contexto a FAM apresentou precisão de 98,68%, 100%, 96,72% e 99,24% para as falhas, respectivamente, além de uma precisão de 99,63% para diagnóstico de motor saudável.

5.3.9 Comparação da eficiência das redes

Nesta seção serão comparadas as eficiências das redes *Perceptron* Multicamadas e *Fuzzy ARTmap*, através das precisões globais mencionadas nas seções anteriores.

O resumo dos destes dados e suas comparações podem ser observadas na Figura a seguir:



Fonte: Autoria Própria.


Através da Figura 22 é possível observar que as redes tiveram alto nível de precisão ao se realizar tanto a classificação simples quanto a multiclassificação. Novamente pode ser observado que o método de pré-processamento por transformada Wavelet infere em bons resultados de classificação de dados.

6 ANÁLISE DOS RESULTADOS EXPERIMENTAIS

Nesta seção será realizada a análise dos resultados apresentados na seção 5. Tal análise será realizada utilizando o valor de precisão média, mostrado nas Figuras 14 a 22, obtido pela média das precisões globais das redes *Perceptron* Multicamadas e *Fuzzy ARTmap*. Através destes valores foi comparada a eficiência de cada método de pré-processamento apresentado na seção 4.

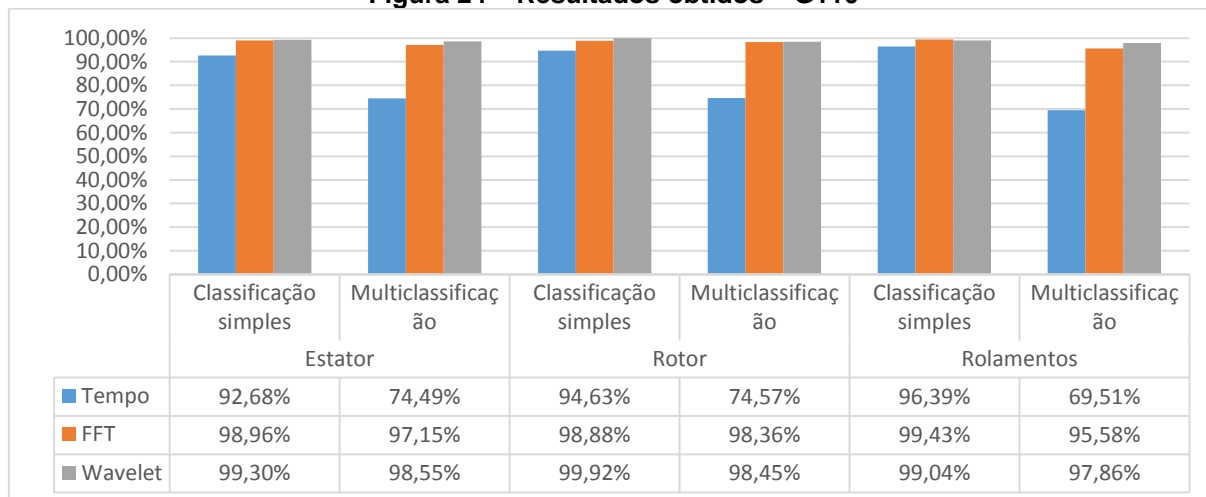
Na Figura 23, 24 e 25 são apresentados a compilação dos resultados médios obtidos para o motor acionado pelos inversores MM440, G110 e ATV, respectivamente.

Figura 23 – Resultados obtidos – MM440




Fonte: Autoria Própria.

Figura 24 – Resultados obtidos – G110



Fonte: Autoria Própria.

Figura 25 – Resultados obtidos – ATV



Fonte: Autoria Própria.

Através destas Figuras é possível observar que a escolha de um método de processamento adequado pode gerar grande influência quando são realizadas classificações de falhas em MIT acionados por inversores de frequência.

Em geral, os dados de motor acionado por inversor de frequência ATV se mostraram mais difíceis de serem classificados com relação a multiclassificação de falhas, com exceção dos dados processados por transformada Wavelet.

Nas três Figuras acima o método por análise de corrente no domínio do tempo com pré-processamento por PCA se mostrou adequada e relevante no contexto de classificação simples, além de alta viabilidade devido ao baixo esforço computacional necessário para se aplicar este método de pré-processamento. Para um caso de multiclassificação tal método se mostrou ineficaz para a rede PMC, apesar de apresentar certa consistência para a rede FMA.

No caso do pré-processamento por FFT, este desempenhou uma eficiência e precisão geral mais elevada que o método por corrente no domínio do tempo, apesar de ter apresentado resultados não aceitáveis para algumas classificações, como mostrado na Figura 25. Esses resultados demonstram que este método se mostra mais confiável e viável do que o método anterior, considerando que o esforço computacional para aplicar a FFT não é elevado.

O método que se mostrou mais eficiência, precisão e consistência foi a aplicação de transformada Wavelet seguida pelo uso do PCA. Como foram utilizados três níveis da transformada, os dados usados pela componente de aproximação tinham um ruído consideravelmente reduzido. Isto implicou em uma precisão elevada

quando foram realizadas as classificações pelas redes inteligentes. Tal método se mostrou o mais preciso, porém perde viabilidade pois o esforço computacional para aplica-lo é muito mais elevado que os outros dois métodos apresentados.

Sendo assim os métodos FFT e transformada Wavelet se mostraram os mais eficientes. Dependendo do contexto utilizado, se for necessário um uso de baixo esforço computacional e for aceita uma menor precisão, a transformada rápida de Fourier é recomendada. Caso seja necessária uma precisão elevada e o tempo de processamento e esforço computacionais não forem relevantes, a transformada Wavelet é recomendada.

7 CONSIDERAÇÕES FINAIS

Este trabalho consistiu em se avaliar a eficiência de métodos para se diagnosticar falhas de estator, rotor e rolamento. Os dados utilizados para se realizar tal avaliação foram provenientes de experimentos realizados em Motores de Indução Trifásicos, acionados em casos distintos por três inversores de frequência, sendo que estes foram usados com uma faixa de frequência determinada e variação de carga mecânica no eixo do motor.

Uma análise feita nas Figuras 14 a 25 demonstra que, para um contexto de classificação simples a rede *Perceptron* Multicamadas apresenta uma precisão geral melhor do que a rede *Fuzzy ARTmap*. Isto é observado em todos os três métodos de pré-processamento aplicados.

Para os métodos de pré-processamento aplicados neste trabalho, foi constatado que somente o uso de dados no domínio do tempo processados por PCA não apresentam resultados aceitáveis para multiclassificação de dados, mas pode ser utilizado para uma classificação simples.

O método por FFT apresentou uma eficiência geral aceitável, mostrando resultados mais baixos dependendo do inversor utilizado para se acionar o MIT. Já a transformada Wavelet demonstrou eficiência geral excelente, mas apresenta esforço computacional muito elevado comparado aos outros métodos, o que não impede tais métodos de serem utilizados para análise de classificação e detecção de severidade de falhas em MIT.

Portanto, os resultados obtidos neste trabalho demonstram o nível de precisão de duas redes inteligentes, *Perceptron* Multicamadas e *Fuzzy ARTmap*, como classificadores de falhas de estator, rolamentos e rotor em MIT. Também foi apresentada a viabilidade e precisão de três métodos de pré-processamento, sendo que cada um destes pode ser utilizado dependendo do contexto analisado, com relação a tempo, esforço computacional e precisão.

REFERÊNCIAS

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Neural Network Toolbox: user's guide**. Natick, MA: The MathWorks, Inc., 2011.

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

BENBOUZID, M. E. H. A Review of Induction Motors Signature Analysis as a Medium for Faults Detection. **IEEE Transactions on Industrial Eletronics**. 2000. v. 47, n. 5, p. 984-993.

BENBOUZID, M. E. H.; KLIMAN, G. B. What Stator Current Processing-Based Technique to Use for Induction Motor Rotor Faults Diagnosis? **IEEE Transactions on Energy Conversion**, 2003. v. 18, n. 2, p. 238-244.

BRITO, J. N. **Desenvolvimento de um Sistema Inteligente Híbrido para Diagnóstico de Falhas em Motores de Indução Trifásicos**. 214 p. Tese (Doutorado em Engenharia Mecânica) — Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas, 2002.

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.

CUSIDÓ, J.; ROSERO, J.; ALDABAS, E.; ORTEGA, J. A.; ROMERAL, L. Fault Detection Techniques for Induction Motors. **IEEE**. 2005. p. 1-6.

CUSIDÓ, Jordi; ROMERAL, Luis; ORTEGA, Juan A.; ROSERO, Javier A.; ESPINOSA, Antonio G. Fault Detection in Induction Machines Using Power Spectral Density in Wavelet Decomposition. **IEEE Transactions on Industrial Eletronics**. 2008. v. 55, n. 2, p. 633-643.

DU, Y.; HABETLER, T.; LU, B.; ZHANG, P. A survey of condition monitoring and protection methods for medium voltage induction motors. In: **IEEE Transaction on Industry Applications**, 2011. v. 47, n.1, p. 34-46.

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: McGrawHill Companies, Incorporated, 2003. (Electrical Engineering Series).

GUEDES, Manuel V. **O Motor de Indução Trifásico**. Faculdade de Engenharia do Porto. 73 p. 1994.

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.

GOEDEL, Alessandro; SILVA, Ivan N. da; SERNIL, Paulo J. A. Uma abordagem neural para estimação de conjugado em motores de indução. **SciELO Sba Controle & Automação**. v. 17. n. 3, jan. 2005.

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.

Haykin, S. (1999). **Neural Networks - A Comprehensive Foundation**. Prentice-Hall.

KATHIR, I.; BALAKRISHNAN, S.; BEVILA, R. J. Fault Analysis of Induction Motor. **IEEE International Conference on Eco-Technologies Environmental Chemistry**, 2011.

MALLAT, S. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 11, n. 7, p. 674–693, Jul. 1989.

MALLAT, S. **A wavelet tour of signal processing**. 2. ed. Cambridge: Academic Press, 1999.

MARTINS, J. F.; PIRES, A. J.; PIRES, V. F. PCA-Based On-Line Diagnosis of Induction Motor Stator Fault Feed by PWM Inverter. **IEEE International Symposium on Industrial Electronics**, Jul. 2006.

MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J.-M. **Wavelet toolbox for use with MATLAB**. [S.l.]: mathworks, 1997.

PREGO, Thiago de M.; MARTINS, Dionísio H. C. de Sá Só; LIMA, Amaro A. de. Classificação de Severidade de Falhas em Máquinas Rotativas usando Random Forest e Redes Neurais Artificiais. **XIII Encontro Nacional de Inteligência Artificial e Computacional**. 2016. p. 13-24.

REIS, A. J. S. **Reconhecimento de Padrões de Falhas em Motores Trifásicos Utilizando Redes Neurais**. 73 p. Tese (Mestrado em Engenharia Elétrica) — Universidade Federal do Rio Grande do Norte, Natal, 2010.

SANTOS, F. M. da C.; SILVA, I. N. da; SUETAKE, M. **Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - Uma visão geral**. Revista Controle & Automação, v. 23, n. 5, p. 553–569, set./out. 2012.

SCHOEN, Randy. R.; HABELTER, Thomas G. Effects of Time-Varying Loads on Rotor Fault Detection in Induction Machines. **IEEE Transaction on Industry Applications**, 1995. v. 31, n. 4, p. 900-906.

SCHOEN, Randy. R.; LIN, Brian K.; HABELTER, Thomas G.; Farag, Samir; Schlag, Jay H. An Unsupervised, On-Line System for Induction Motor Fault Detection Using Stator Current Monitoring. **IEEE Transaction on Industry Applications**, 1995. v. 31, n. 6, p. 1280-1286.

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, Lyvia R. B. **Classificação de Falhas em Máquinas Elétricas Usando Redes Neurais, Modelos Wavelet e Medidas de Informação**. 2014. 84 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2014.

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 Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos**. 128 p. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, São Carlos, 2012.

THOMSON, W. T.; FENGER, M. Current Signature Analysis to Detect Induction Motor Fault. **IEEE Industry Applications Magazine**. p. 26-34. 2001.

WAGECK, Marcelo dos M. **Deteção de defeitos em motores de indução pela análise da assinatura da corrente elétrica**. Trabalho de Conclusão de Curso – Engenharia Industrial Elétrica, enf. Eletrotécnica, Universidade Tecnológica Federal do Paraná. Curitiba, 2015.

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-dasescovas-folheto-50042391-catalogo-portugues-br.pdf>>. Acesso em: 10 de abr. de 2018.

YAN, R.; GAO, R. X.; CHEN, X. Wavelets for faults diagnosis of rotary machines: A review with applications. **Elsevier B.V.** v. 96, p. 1-15. 2014.