

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
ENGENHARIA ELÉTRICA

GABRIEL AOKI GONÇALVES

**COMPARAÇÃO DE DIFERENTES MÉTODOS DE FILTRAGEM APLICADO AO
DIAGNÓSTICO DE FALHAS DE ESTATOR EM MOTORES DE INDUÇÃO
TRIFÁSICOS ACIONADOS POR INVERSORES DE FREQUÊNCIA.**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO
2020

GABRIEL AOKI GONÇALVES

**COMPARAÇÃO DE DIFERENTES MÉTODOS DE FILTRAGEM APLICADO AO
DIAGNÓSTICO DE FALHAS DE ESTATOR EM MOTORES DE INDUÇÃO
TRIFÁSICOS ACIONADOS POR INVERSORES DE FREQUÊNCIA.**

Trabalho de Conclusão de Curso de graduação apresentado à disciplina TCC2, do Curso de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para a obtenção do título de Bacharel.
Orientador: Prof. Dr. Wagner Fontes Godoy.

CORNÉLIO PROCÓPIO
2020



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



FOLHA DE APROVAÇÃO

Gabriel Aoki Gonçalves

Comparação de métodos de filtragem para classificação de falhas de estator em motores de indução alimentados por inversores de frequência

Trabalho de conclusão de curso apresentado às 15:00hs do dia 21/10/2020 como requisito parcial para a obtenção do título de Engenheiro Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

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

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

Prof(a). Dr(a). Edson Luis Bassetto - (Membro)

RESUMO

GONÇALVES, Gabriel Aoki. **Classificação de diferentes métodos de filtragem aplicados ao diagnóstico de falhas de estator em motores de indução trifásicos acionados por inversores de frequência**. 2020. 57f. Trabalho de Conclusão de Curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Campus Cornélio Procópio, 2020.

Este trabalho de conclusão de curso propõe um estudo relacionado à comparação de desempenho de diferentes métodos de filtragem aplicados ao diagnóstico de falhas de estator em motores de indução trifásicos acionados por inversores de frequência. O trabalho propõe ainda o emprego dos seguintes métodos de filtragem (i) *Kernel*, (ii) Análise de Componentes Principais, (iii) Wavelet. Na etapa de classificação serão utilizados os seguintes classificadores: *Random Forest*, Função de Base Radial (*RBF Network*) e k-Vizinhos mais próximos (k-NN). Foram realizadas as análises de cada um dos filtros dentro de cada um dos classificadores, para fim de uma melhor comparação de resultados e, conseqüentemente uma avaliação mais eficaz.

Palavras-chave: Motores de Indução Trifásicos, Falhas de estator, Métodos de filtragem, Classificadores, Redes Neurais Artificiais.

ABSTRACT

GONÇALVES, Gabriel Aoki. **Classification of different filtering methods applied to the diagnosis of stator faults in three-phase induction motors driven by frequency inverters.** 2020. 57f. Trabalho de conclusão de curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Campus Cornélio Procopio, 2020.

This course conclusion work proposes a study related to performance comparison of different filtering methods applied to the diagnosis of stator faults in three-phase induction motors driven by frequency inverters. The paper also proposes the use of the following filtering methods (i) *Kernel*, (ii) *Principal Components Analysis*, (iii) *Wavelet*. In the classification stage the following classifiers will be used: *Random Forest*, *Radial Basis Function (RBF Network)* and *k-Nearest Neighbors (k-NN)*. Analysis of each of the filters were carried out within each of the classifiers, in order to better compare results and, consequently, make a more effective assessment.

Keywords: Three-phase induction motors, Stator faults, Filtering methods, Classifiers, Artificial neural networks.

LISTA DE FIGURAS

Figura 1 - Vista em corte longitudinal de um motor de indução de 460V e 7,5HP, com rotor gaiola de esquilo.	6
Figura 2 - Motor de Indução Trifásico, modelo w22 premium, WEG.	12
Figura 3 - Classificação dos tipos de falhas em motores de indução.	14
Figura 4 - Distribuição dos tipos de falhas.	14
Figura 5 - Enrolamentos de estator de um motor de indução típico.	15
Figura 6 - Representação das falhas de estator.	16
Figura 7 - Falha de estator localizada.	17
Figura 8 - Comparação de classificações de mapas.	20
Figura 9 - Decomposição Wavelet aplicada a sinais filtrados	23
Figura 10 - Estrutura da Função de Base Radial	27
Figura 11 - Exemplo de aplicação do k-NN.	30
Figura 12 - Diagrama de acionamento do MIT.	33
Figura 13 - Estator do MIT rebobinado com <i>taps</i>	34
Figura 14 - Diagrama de pré-processamento e classificação de falhas	35
Figura 15 - Comparação de resultados globais.	44
Figura 16 - Comparação dos resultados para motor saudável e em falha.	44

LISTA DE TABELAS

Tabela 1 - Parâmetros e características do MIT utilizado no trabalho.....	31
Tabela 2 - Parâmetros e características dos inversores utilizados no trabalho.....	32
Tabela 3 - Quantidade de aquisições utilizados por defeito	32
Tabela 4 - Comparação das matrizes de confusão geradas pelo método Kernel	38
Tabela 5 - Comparação dos desempenhos dos classificadores para o método Kernel	38
Tabela 6 - Comparação das matrizes de confusão geradas pelo método PCA	40
Tabela 7 - Comparação dos desempenhos dos classificadores para o método PCA	40
Tabela 8 - Comparação das matrizes de confusão geradas pelo método Wavelet...	42
Tabela 9 - Comparação dos desempenhos dos classificadores para o método Wavelet	42

LISTA DE ABREVIATURAS

CA	Corrente Alternada
ELM	<i>Extreme Learning Machine</i>
IBL	<i>Instance-based Learning</i>
IEEE	<i>Institute of Electric and Electronic Engineers</i>
k-NN	<i>k-Nearest Neighbors</i>
MCSA	<i>Motor Current Signature Analysis</i>
MIT	Motor de Indução Trifásico
OBB	<i>Out of Bag</i>
PCA	<i>Principal Component Analysis</i>
PWM	<i>Pulse Width Modulation</i>
RBF	Função de Base Radial
RF	<i>Random Forest</i>
RNA	Redes Neurais Artificiais
TCS	Transformadores de Corrente
TW	Transformada <i>Wavelet</i>
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

Sumário

1 INTRODUÇÃO	6
1.1 Delimitação do tema	8
1.2 Problemas e premissas.....	9
1.3 Objetivos	9
1.3.1 Objetivo geral	9
1.3.2 Objetivos específicos	10
1.4 Estrutura da Dissertação.....	10
2 REFERENCIAL TEÓRICO.....	11
2.1 Motor de Indução Trifásico.....	11
2.1.1 Acionamento por Inversor de Frequência	12
2.2 Falhas em Motores de Indução Trifásicos	13
2.3 Falha de estator	15
3 Métodos de filtragem e classificações.....	18
3.1 Detecção de falhas	18
3.2 Métodos de Filtragem	19
3.2.1 <i>Kernel</i>	19
3.2.2 Análise de Componentes Principais (PCA).....	21
3.2.3 Wavelet	22
3.3 Classificação inteligente de falhas	24
3.3.1 Redes Neurais Artificiais	24
3.3.2 Random Forest	25
3.3.3 Rede Função de Base Radial	27
3.3.4 <i>k</i> Vizinhos mais Próximos	29
4 Metodologia	31
4.1 Banco de dados	31
4.2 Inserção de falhas.....	33
4.2.1 Aplicação de curto circuito no estator	33
4.3 CLASSIFICAÇÃO	35
4.3.1 Estruturas de classificação	36
5. Resultados Experimentais	37
5.1 <i>Kernel</i>	38


5.2 PCA.....	40
5.3 Wavelet.....	42
5.4 RESULTADOS GERAIS	44
6. CONSIDERAÇÕES FINAIS	47
REFERÊNCIAS.....	49

1 INTRODUÇÃO

Os motores de indução trifásicos possuem uma influência considerável na continuidade de muitos processos industriais. O setor industrial brasileiro consome aproximadamente 40% da energia produzida no país, e mais de 60% dessa energia é usada em sistemas de acionamentos (EPE, 2014). Assim, é evidente a importância dessas máquinas no setor industrial brasileiro e a necessidade de conversão de energia elétrica em energia mecânica.

Neste contexto, destaca-se o motor elétrico de indução trifásico, principalmente com o rotor gaiola de esquilo, ou seja, com os enrolamentos do rotor sendo barras sólidas de alumínio que são fundidas nas ranhuras do rotor e colocados em curto circuito por anéis de alumínio fundido localizados em cada extremidade do rotor. Esse tipo de construção de rotor resulta em motores de indução que são relativamente baratos e altamente confiáveis, fatores que contribuem à sua imensa popularidade e ampla aplicação (FITZGERALD; KINGSLEY; UMANS, 2014).

Figura 1 - Vista em corte longitudinal de um motor de indução de 460V e 7,5HP, com rotor gaiola de esquilo.



Fonte: FITZGERALD; KINGSLEY; UMANS (2014, p.199).

O acionamento por inversores de frequência é o método preferido para controlar a velocidade dos motores atualmente. O acionamento é muito flexível, e em sua saída é obtido um conjunto trifásico de tensões cuja frequência e tensão podem ser variadas. O controle da tensão e da frequência de saída é obtido usando técnicas de modulação de largura de pulso (PWM – *Pulse Width Modulation*) (CHAPMAN, 2013). Assim, além do controle de velocidade, os inversores evitam picos de correntes, sobretensões/subtensões e reduzem as falhas, obtendo um sistema totalmente eficaz e prolongando o tempo de vida útil das máquinas.

Os motores elétricos estão sujeitos a vários tipos de falhas, as quais podem ser divididas em duas classes distintas: i) falhas elétricas e ii) falhas mecânicas. As falhas elétricas são relacionadas com problemas associados ao enrolamento de armadura, ao enrolamento do rotor, à quebra de barras no rotor e conexões, entre outros. Já as falhas mecânicas, são principalmente derivadas de problemas nos rolamentos, na excentricidade, no desgaste de acoplamentos, e nos desalinhamentos (BELLINI et al, 2008, p.4109-4126).

Apesar de possuírem características construtivas robustas, os motores elétricos de indução são expostos a uma variedade de condições ambientais, operando sob diversos tipos de cargas. Tais fatores, juntamente com o envelhecimento natural, contribuem para que os motores possam vir a desenvolver falhas (SUETAKE, 2012). Logo, a detecção de defeitos, ainda na fase inicial, é imprescindível para a adequada manutenção. A partir dela, se evitam potenciais danos severos que o motor poderia desenvolver caso a falha não fosse detectada e corretamente corrigida, além de evitar paradas não programadas para a realização de manutenção corretiva. Esse fator se traduz em um aumento da disponibilidade das máquinas e no aumento de produtividade consequentemente.

Dentre as falhas que podem vir a ocorrer nos motores elétricos, cerca de 36% correspondem a erros nos enrolamentos de estator, segundo pesquisas realizadas pelo IEEE. Portanto, realizar o monitoramento da máquina é essencial, visto que a vida útil confiável do núcleo do estator depende de muitos fatores, incluindo o projeto original e as condições de operação, e então cada núcleo poderá exigir algum tipo de manutenção respectivamente (IEEE, 2013).

Assim, a proposta deste trabalho consiste em apresentar, inicialmente, as falhas de estatores e em seguida, com aplicação de diferentes métodos de filtragens. Além disso, ele visa realizar uma classificação inteligente dessas falhas, através de

dados de corrente no domínio do tempo em motores elétricos de indução trifásicos, acionados por inversores de frequência.

1.1 Delimitação do tema

Este trabalho pretende analisar o desempenho dos classificadores *Random Forest*, Função de Base Radial e *k-Nearest Neighbors*, a partir da aplicação de diferentes estratégias de filtragem, utilizando um sinal de corrente no domínio do tempo adquirido de um motor de indução trifásico, acionado por inversor de frequência. Inicialmente, será aplicado na máquina operando em condições normais, e posteriormente, com a máquina operando sob condições de curto-circuito de estator.

Portanto, serão apresentadas nove análises, sendo:

- 1- MIT em condições normais e em falha, utilizando filtragem Kernel e RF como classificador;
- 2- MIT em condições normais e em falha, utilizando filtragem Kernel e RBF *network* como classificador;
- 3- MIT em condições normais e em falha, utilizando filtragem Kernel e k-NN como classificador;
- 4- MIT em condições normais e em falha, utilizando filtragem PCA e RF como classificador;
- 5- MIT em condições normais e em falha, utilizando filtragem PCA e RBF *network* como classificador;
- 6- MIT em condições normais e em falha, utilizando filtragem PCA e k-NN como classificador;
- 7- MIT em condições normais e em falha, utilizando filtragem *Wavelet* e RF como classificador;
- 8- MIT em condições normais e em falha, utilizando filtragem *Wavelet* e RBF *network* como classificador;
- 9- MIT em condições normais e em falha, utilizando filtragem *Wavelet* e k-NN como classificador.

1.2 Problemas e premissas

Como o motor de indução trifásico é uma máquina muito demandada em diversos setores da indústria brasileira, é necessário um acompanhamento rígido em relação ao seu desempenho, neutralizando assim, possíveis riscos de falhas. Caso isso não ocorra, essa falha pode gerar problemas maiores, a citar a parada de um processo de produção para manutenção, ou até causar dano à própria máquina, refletindo em prejuízo financeiro indesejado.

Portanto, o monitoramento contínuo destes motores permite identificar falhas precoces, possibilitando dessa forma, a programação de planos de manutenções a serem realizados. Com isso, são evitados danos futuros e paradas não programadas, além de promover maior rendimento da máquina e disponibilidade dela ao usuário. Ademais, se tratando de abordagens financeiras, ocasiona economia aos favorecidos.

1.3 Objetivos

Nesta seção, são descritos os objetivos gerais e específicos desta proposta de trabalho de conclusão de curso, com a intenção de atingir os resultados esperados ao final deste estudo.

1.3.1 Objetivo geral

O objetivo geral deste trabalho é realizar a comparação de diferentes métodos de filtragem aplicados ao diagnóstico de falhas de estator em motores elétricos de indução trifásicos, acionados por inversores de frequência. Isso se dará por meio de dados aferidos e tratados. Inicialmente será feita a análise sem nenhum método de filtragem; posteriormente serão aplicados três métodos diferentes de filtragem e analisados em três classificadores.

1.3.2 Objetivos específicos

Dentre os objetivos específicos, elencam-se os seguintes:

- Verificar o estado da arte dos trabalhos de classificação de falhas em máquinas, bem como as estratégias de filtragem aplicadas;
- Analisar o desempenho de 3 diferentes estratégias de filtragem para classificação de falhas de curto-circuito de estator;
- Diagnosticar falhas de estator empregando os classificadores *Random Forest*, Função de Base Radial e *k-Nearest Neighbors*;
- Simular os três métodos de filtragem aplicados aos três classificadores, ou seja, cada filtro será aplicado em cada classificador citado;
- Comparar os resultados obtidos a fim de gerar conclusões coerentes e significantes para possíveis estudos e/ou aplicações futuras.

1.4 Estrutura do Trabalho

Este trabalho será dividido em 6 capítulos, da seguinte maneira:

- 1- Foi feita a introdução, focando explicar a importância das máquinas de indução para o ambiente industrial e o impacto gerado por elas caso venham a falhar. Além disso, foram descritos todos os objetivos para esse estudo;
- 2- Na parte dois, foi explicado o funcionamento dessas máquinas e como elas são acionadas via inversores de frequência. Para finalizar, foi introduzida a parte teórica, referente às incorreções e seus impactos nessas máquinas, com foco em falhas no estator;
- 3- No terceiro momento, foram descritos os funcionamentos dos três métodos de filtragem aplicados, além dos três classificadores usados para classificação dos resultados;
- 4- Nesta etapa, foi apresentada a base de dados e a metodologia utilizada para a parcela prática do trabalho;
- 5- No Capítulo 5, foram discutidos os resultados, junto aos objetivos iniciais e suas possíveis aplicações.
- 6- Por fim, foram descritas as considerações finais.

2 REFERENCIAL TEÓRICO

Nesse Capítulo, serão apresentados os conceitos relacionados aos motores de indução trifásicos, abordando o método de acionamento mais utilizado atualmente, via inversores de frequência. Por fim, são ressaltadas as teorias referentes aos principais tipos de falhas que ocorrem nesses motores, dando grande ênfase à falha de estator.

Para a realização de uma classificação inteligente de falhas, serão empregados sinais de corrente discretizados no domínio do tempo. Estes sinais serão inicialmente analisados sem nenhum tipo de aplicação. Em sequência, há acomodação deles à diferentes estratégias de filtragem, e por fim, inserção nos classificadores *Random Forest*, Função de Base Radial e *k-Nearest Neighbors*, para a classificação da falha. Cada uma destas metodologias será descrita mais detalhadamente nas seções seguintes. Para a obtenção e comparação dos resultados, os dados serão simulados no *software Weka – Waikato Environment for Knowledge Analysis*.

2.1 Motor de Indução Trifásico

Motor elétrico é a máquina destinada a transformar energia elétrica em energia mecânica. O motor de indução é o mais usado dentre todos os tipos de motores, pois combina as vantagens da utilização de energia elétrica – baixo custo, facilidade de transporte, limpeza, simplicidade de comando – com sua construção simples e grande versatilidade de adaptação às cargas dos mais diversos tipos e melhores rendimentos (WEG, 2017).

Um motor de indução tem fisicamente o mesmo estator que uma máquina síncrona, com uma construção de rotor diferente. No estator encontra-se o enrolamento de armadura, e este é alimentado por corrente alternada, e então, por indução, correntes são induzidas no rotor. Os fluxos no rotor e no estator giram em sincronismo, porém, o rotor não gira em sincronismo com o fluxo da armadura, o que resulta em um escorregamento (FITZGERALD; KINGSLEY; UMANS, 2014; CHAPMAN, 2013).

A Figura 2, representa um motor de indução trifásico.

Figura 2 - Motor de Indução Trifásico, modelo w22 premium, WEG.



Fonte: (WEG, 2013b).

O rotor de uma máquina de indução polifásica pode ser de dois tipos: bobinado ou gaiola de esquilo. As máquinas com rotor bobinado são relativamente incomuns, encontradas apenas em um número limitado de aplicações especializadas. Já o rotor gaiola de esquilo é o tipo de motor mais usado, devido a extrema simplicidade e robustez em sua construção, além de apresentar vantagens notáveis para esse tipo de máquina (FITZGERALD; KINGSLEY; UMANS, 2014).

2.1.1 Acionamento por Inversor de Frequência

O acionamento de motores elétricos de indução por meio de inversores de frequência (denominados também conversores estáticos de frequência) é uma solução amplamente utilizada na indústria, e que se constitui atualmente no método mais eficiente para o controle de velocidade dos motores de indução. Os inversores transformam a tensão da rede, de amplitude e frequência constantes, em uma tensão de amplitude e frequência variáveis, atuando como uma fonte de frequência variável para o motor (WEG, 2017).

O acionamento por inversor de frequência vem sendo muito utilizado nas empresas, embora precisem de um dimensionamento adequado para a obtenção da melhor eficiência possível. Conseqüentemente, ocorrerão reduções em picos de

corrente, redução em consumo de energia, proteção contra sobretensão/ subtensão, aumentando assim, o tempo de vida útil do sistema.

2.2 Falhas em Motores de Indução Trifásicos

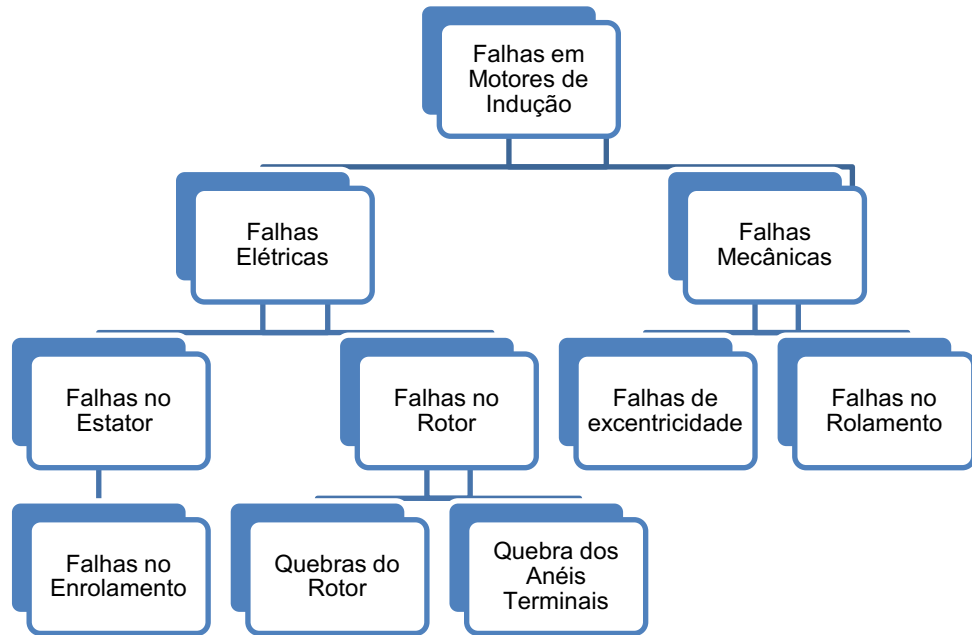
O tempo de evolução de falhas é difícil de ser estimado, e depende das condições de funcionamento do motor, sendo este exposto a uma variedade de condições ambientais e operando sob diversos tipos de cargas. No entanto, a evolução pode ocorrer rapidamente, e então o monitoramento constante e a detecção do tipo de falha são essenciais (SUETAKE, 2012; BACCARINI et al, 2013).

Portanto, com o monitoramento de operação desses motores afim de detectar falhas ainda no estado inicial, é possível evitar paradas não programadas para a manutenção, o que se traduz em uma redução do custo de manutenção. Além de não comprometer o processo industrial no qual as máquinas estão inseridas, evitando assim prejuízos ainda maiores com a produção (DRIF; CARDOSO, 2007).

As falhas ocorrentes em motores de indução, em geral, podem ser classificadas conforme o esquema (YEH et al, 2007) ilustrado na Figura 03. Ademais, as principais falhas que ocorrem nos motores de indução, dividem-se em internas e externas. As internas podem ser divididas em falhas internas elétricas e falhas internas mecânicas; já as externas, em elétricas, mecânicas e ambientais. As falhas elétricas internas, podem ser: falhas no estator e/ou no rotor, anéis quebrados, e conexões. Já as internas mecânicas classificam-se em falhas de rolamentos, excentricidade e desgaste do acoplamento. (GODOY, 2016).

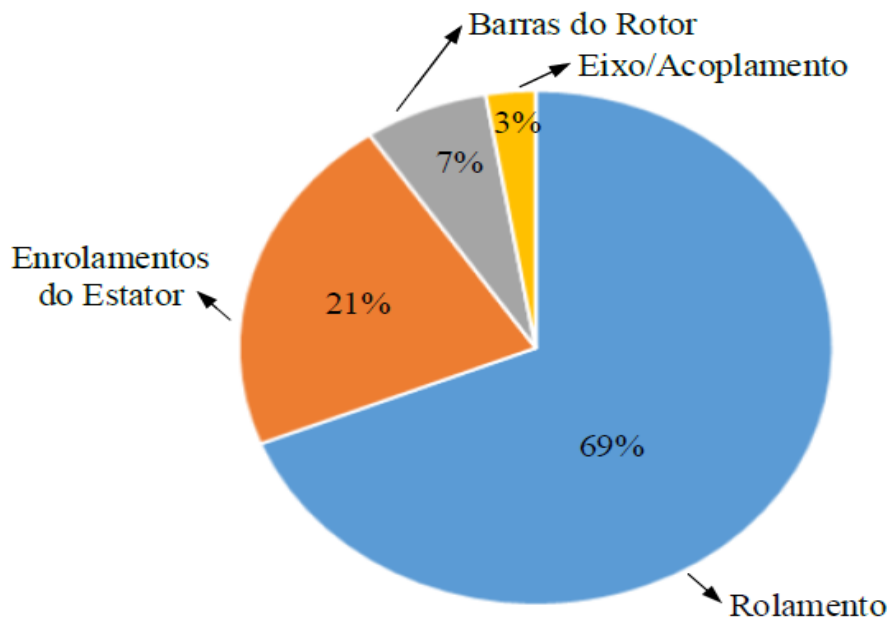
Dentre estas falhas, de acordo com (BONNETT; YUNG, 2008), a Figura 04, representa a distribuição estatística de cada uma. Seguem abaixo as ilustrações citadas.

Figura 3 - Classificação dos tipos de falhas em motores de indução.



Fonte: Adaptado (YEH et al, 2007).

Figura 4 - Distribuição dos tipos de falhas.




Fonte: Adaptado (Bonnett; Yung, 2008).

Assim, é possível notar que a maior parte das falhas elétricas acontecem no rotor. Entretanto, o número de falhas no estator também é altamente significativo para o melhor desempenho dessas máquinas. Portanto, é de extrema necessidade o acompanhamento e a detecção prévia de falhas, principalmente no rotor e no estator.

2.3 Falha de estator

Em máquinas CA, tais como as síncronas ou as de indução, os enrolamentos de armadura alojam-se geralmente na parte estacionária do motor, conhecida como estator. Nas máquinas de indução, as correntes são induzidas nos enrolamentos do rotor por meio da combinação da variação, no tempo, das correntes de estator e do movimento do rotor em relação ao estator (FITZGERALD; KINGSLEY; UMANS, 2014). Os enrolamentos de estator são alinhados como ilustrado na Figura 05.

Figura 5 - Enrolamentos de estator de um motor de indução típico.




Fonte: Chapman (2013, p.308).

Basicamente, falhas relacionadas com os enrolamentos do estator são curto-circuito entre fase-terra, fase-fase, curto-circuito entre as voltas de enrolamento de fases iguais ou diferentes (TRAN et al, 2013). Falhas no estator podem se manifestar de várias maneiras, incluindo aquecimento excessivo do motor, bem como sobrecarga elétrica e isolamento de falhas nas bobinas (GODOY et al, 2016).

Como já citado acima, as falhas do estator são relacionadas com vários tipos de curto-circuito, mais detalhado na Figura 06.

Figura 6 - Representação das falhas de estator.



Fonte: Adaptado de Siddiqui, Sahay e Giri (2014).

A falha derivada de um curto-circuito entre as espiras é fundamental para o desenvolvimento das demais falhas, visto que ela causará aumento de temperatura considerável, devido a corrente de falta ser bem maior do que a corrente de rotor bloqueado. Com as sobrecargas, a isolação irá se deteriorar até chegar em níveis mais avançados, podendo assim, culminar nos outros tipos de curto circuito citados na Figura 05, afetando assim as outras seções do enrolamento. Portanto, é possível concluir que os sobreaquecimentos são os principais causadores de falhas, pois atingem diretamente o sistema de isolação (BONNETT; SOUKUP, 1992).

A Figura 07 ilustra de maneira detalhada danificações causadas no estator da máquina por sobreaquecimentos.

Figura 7 - Falha de estator localizada.



Fonte: ABB group (2015).

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

3 Métodos de filtragem e classificações

Neste Capítulo, serão apresentados detalhes sobre detecções de falhas em motores, possibilitando a identificação de *outliers*. Além disso, serão detalhados todos os métodos de filtragens que foram utilizados no trabalho e, também, os classificadores inteligentes utilizados.

3.1 Detecção de falhas

Os métodos baseados na análise da corrente elétrica (MCSA) não são invasivos e não requerem a interrupção da operação dos sistemas de acionamentos (BENBOUZID, 2000). A medição é feita por sensores comuns (TCS – transformadores de corrente) e muitas vezes já estão presentes na aplicação a ser monitorada (BACCARINI; MENEZES; CAMINHAS, 2010). Neste trabalho, serão utilizados sinais de corrente como forma de diagnosticar falhas.

A principal etapa no processo de detecção de falhas constitui na análise de sinais e na extração de características relevantes, o que pode ser realizado através de uma transformação ou decomposição do correspondente sinal. (OLIVEIRA H. M., 2007). Quando um motor de indução trifásico apresenta algum tipo de falha, o seu espectro de corrente torna-se distinto do espectro de corrente de um motor saudável, tornando possível a realização de um diagnóstico e aplicações de métodos de filtragens, com o intuito de reduzir falhas futuras e conseguir um melhor desempenho da máquina.

3.2 Métodos de Filtragem

Nesta seção serão detalhados todos os métodos de filtragem citados e aplicado no trabalho.

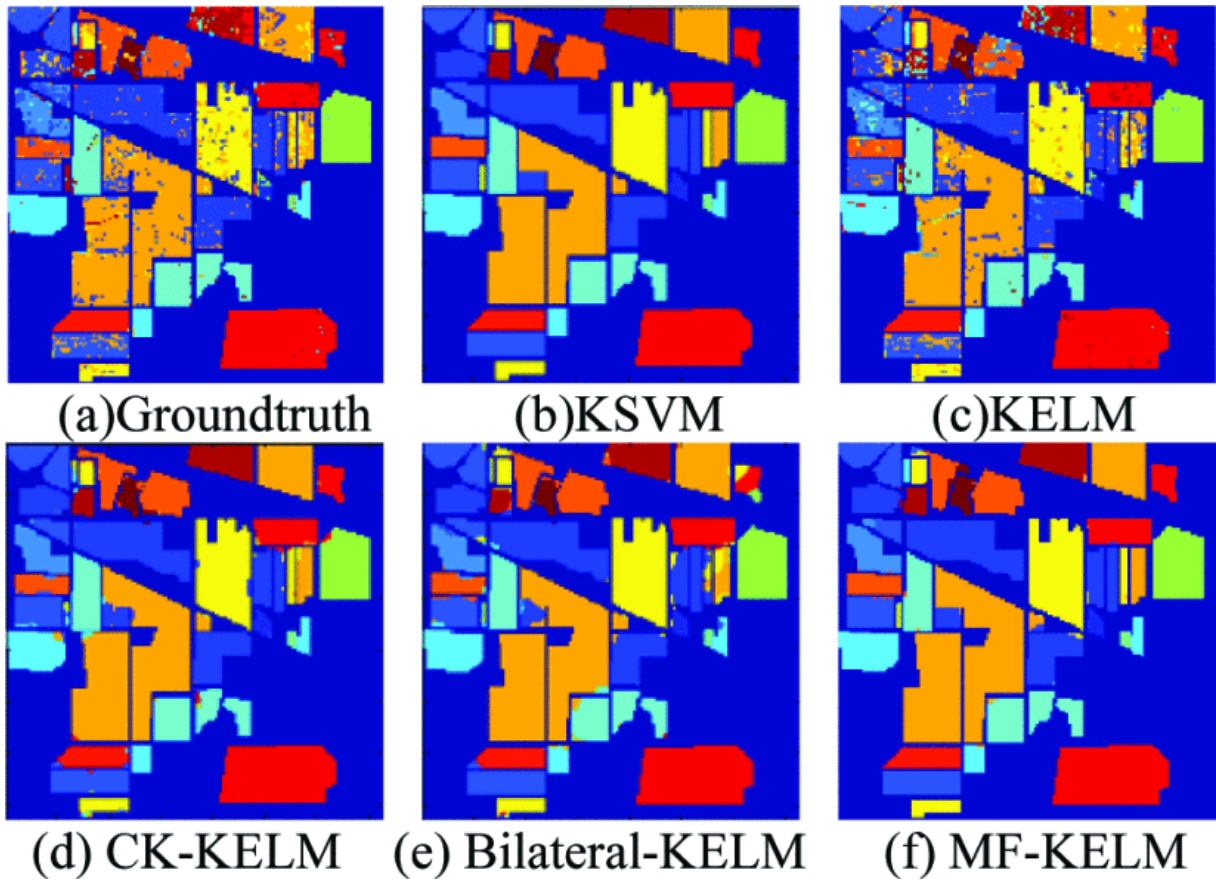
3.2.1 *Kernel*

A *Extreme learning machine (ELM)* é uma rede neural com uma única camada oculta com os pesos de entrada e os de saída gerados aleatoriamente, mantendo assim, a vantagem do dinamismo e eficiência (LEI; ZHOU; ZHANG, 2018). Assim, a função *Kernel* foi implementada a *ELM*, superando a inicialização aleatória sobre os pesos e não precisando satisfazer alguns teoremas. Em geral, a função *Kernel* adicionada a um classificador, deixa o sistema mais robusto aos parâmetros. (SHANG et al, 2018).

Em função disso, vários métodos estão sendo bem sucedidos com a aplicação do método, principalmente se tratando de processamentos de sinais, precisões de classificações, regressões, etc. Além do que, essa função aplicada a uma das redes neurais deste trabalho, no caso a RBF, tem alcançado resultados promissores na classificação de imagens hiperespectrais (SHANG et al, 2018).

O princípio da função *Kernel* é transformar as amostras do espaço dimensional baixo para o espaço dimensional alto utilizando uma função para que a transformação não-linear se transforme em linearmente separável (LEI; ZHOU; ZHANG, 2018). O filtro pode ser adaptado em diversos classificadores, trazendo resultados significativos. Na Figura 08, são apresentadas comparações de imagens com o filtro *Kernel* aplicado em diversas redes neurais, com destaque para MF-KELM, que atinge aproximadamente 98.52% de precisão.

Figura 8 - Comparação de classificações de mapas.



Fonte: SHANG et al (2018).

Assim, é notável que aplicando esse tipo de filtragem, independente da classificação, o sistema poderá reduzir as interferências de outros sinais e obter os melhores resultados de classificações (LEI; ZHOU; ZHANG, 2018).

3.2.2 Análise de Componentes Principais (PCA)

No processo de diagnóstico de falhas de estator, diversas características são obtidas a partir dos sinais, com o intuito de identificar falhas relacionadas a curto-circuito no estator, além da amplitude da corrente no mesmo. Desse modo, através da Análise de Componentes Principais, é possível processar todas as características de falhas e, em seguida, selecionar as que contribuem mais significativamente para a solução (SILVA, 2008).

A Análise de Componentes Principais tem como principal característica reduzir a dimensão das variáveis de entrada. É um procedimento matemático para análise multivariada, utilizando transformação ortogonal para converter um conjunto de observações variáveis correlacionadas a um conjunto de valores linearmente não correlacionados. A redução é executada pela geração de novas variáveis, por meio da combinação linear das variáveis originais (GODOY et al, 2016).

Portanto, será aplicada com o intuito de eliminar características não-significantes para este trabalho, reduzindo assim o vetor de entrada e os recursos computacionais e, conseqüentemente, simplificar e compactar a estrutura.

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

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

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).

A principal motivação para a escolha desta técnica, justifica-se por ela possibilitar a redução do conjunto de dados, preservando, simultaneamente, as principais informações contidas neles.

3.2.3 Wavelet

Uma das maneiras consideradas apreciáveis para detecção de falhas em máquinas de indução, é a utilização da transformada *Wavelet* (TW), e para a parte prática, a aplicação de um banco de filtros discretos passa-altas e passa-baixas. A TW gera uma representação do sinal por meios de versões escalonadas e deslocadas de uma mesma função, sendo assim, similar a transformada de Fourier.

Na TW é possível representar o sinal em diferentes resoluções de tempo e frequência, obtendo assim, um conteúdo espectral que se modifica com o tempo, e com isso, a possível detecção de alterações transitórias no sinal (BELLINI et al, 2008; BENBOUZID, 2000).

Diferentemente da transformada discreta de Fourier, a transformada discreta *Wavelet* não é necessariamente a versão discreta da TW contínua (MALLAT, 2009). Em função disso, outra característica importante é a concentração de energia do sinal transformado em um número pequeno de coeficientes, podendo assim ser aplicados em métodos para redução de ruídos (MOURÃO; ABREU, 2016).

De acordo com a aplicação dos filtros, seguem abaixo As Equações 2 e 3, referentes à resposta do filtro passa-baixa e do filtro passa-alta, respectivamente:

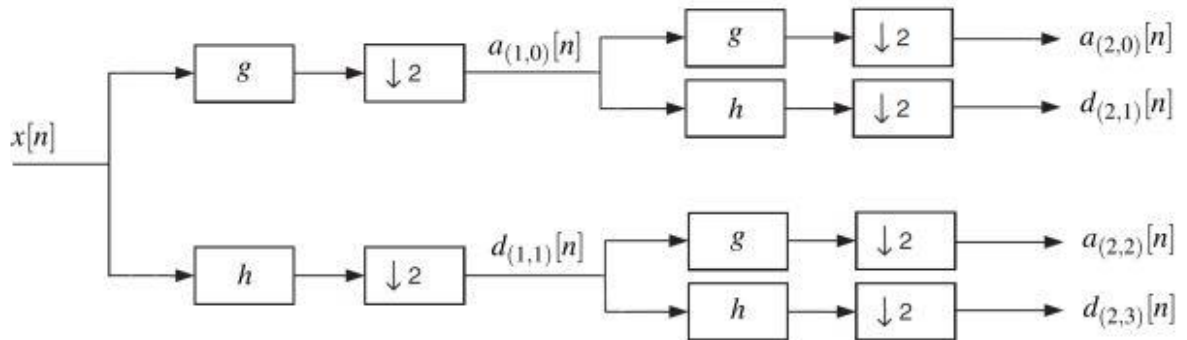
$$a[n] = x[n] * g[n] = \sum_{k=0}^{N-1} g[k] \cdot x[2n - k] \quad (2)$$

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

Sendo $g[n]$ o filtro de decomposição passa-baixa e, $h[n]$ o filtro de decomposição passa-alta, e N é o tamanho do sinal (GUIDO R.C.; SLAETS, 2006). A Figura 09 reproduz o comportamento dos sinais com a aplicação dos filtros. O filtro passa-baixa remove as componentes de alta frequência, enquanto o filtro passa-alta remove as de baixa frequência. O processo é realizado em cascata, obtendo duas saídas em cada filtro aplicado, as quais representam os coeficientes de aproximação

e de detalhes do primeiro nível. A cada nível, é implicada uma subamostragem por um fator igual a dois e são obtidas novas duas saídas referentes àquele nível.

Figura 9 - Decomposição Wavelet aplicada a sinais filtrados



Fonte: Adaptado de WEEKS (2012).

3.3 Classificação inteligente de falhas

A proposta deste trabalho considera o emprego dos classificadores *Random Forest*, Função de Base Radial (BRF) e *k-Nearest Neighbors* (k-NN), que serão descritas detalhadamente nas próximas Subseções.

3.3.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs), são modelos computacionais inspirados no funcionamento do sistema nervoso de seres vivos. Estas redes são compostas por unidades de processamento que representam os neurônios, e que estão associadas a alguns pesos, que representam as conexões sinápticas. Assim, o conhecimento adquirido é propagado por todos os neurônios, alterando os pesos sinápticos. Na fase de treinamento ou aprendizagem, os pesos sinápticos são ajustados ao longo da rede de neurônios até que se obtenham padrões de respostas aos estímulos (entradas) que estejam de acordo com os valores desejáveis (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

No contexto das engenharias, as RNAs são processamentos e monitoramentos de dados técnicos para extração máxima de informações pertinentes, a fim de realizar previsões e minerações dos dados para desenvolvimento de modelos. As RNAs vêm obtendo bons resultados em detecções de falhas, e em base disso, será aplicada no desenvolvimento do trabalho (TRIGEASSOU, 2011).

Outro aspecto construtivo é a capacidade de lidar com problemas que possuem grandes volumes de variáveis e conjunto de dados, além da habilidade de mapear sistemas não-lineares e variantes no tempo. Para modelagem de sistemas complexos, as redes podem se transformar internamente de acordo com critérios autodesenvolvidos por ela para adaptação ao algoritmo utilizado (SUETAKE, 2012; SILVA; SPATTI; FLAUZINO, 2010).

3.3.2 Random Forest

Random Forest é um algoritmo baseado em criar muitas árvores de decisão de maneira aleatória, partindo da premissa de que cada árvore, ou cada ramo da árvore, é uma amostra de dados que está sendo analisada. Portanto, para classificação de um novo vetor de entrada, este será aplicado a diversas árvores, onde cada árvore trará um voto para o vetor. Por fim, o algoritmo da floresta irá escolher a classe e/ou o vetor mais votado em comparação a todas as árvores da floresta (BREIMAN; CUTLER, 2004).

Neste processo, após serem definidos os valores de entrada, as árvores são desenhadas por amostragens com substituições, onde aproximadamente um terço dos valores são deixados de fora da amostra, fator conhecido como OOB - *out of bag*. Esses valores deixados, são importantes para uma estimativa imparcial em relação ao erro de classificação, o qual é gerado à medida que novas árvores surgem. Ademais, é também utilizado para estimativas variáveis do processo.

Após serem definidas as árvores, todos os valores de entrada serão executados na sua respectiva árvore. Além disso, o algoritmo identifica casos de proximidade, ou seja, se dois casos ocupam o mesmo terminal, sua proximidade é aumentada em um. Ao final, as proximidades serão divididas pelo número de árvores presentes e, serão usadas principalmente na substituição de dados ausentes e localização/ melhorias em dados que fogem do padrão.

Algumas vantagens da aplicação do *Random Forest* são:

- 1- É eficaz com grandes bases de dados;
 - 2- Fornece estimativas precisas de quais variáveis são importantes na classificação;
 - 3- Através do OOB, gera uma estimativa imparcial interna em relação ao erro geral;
 - 4- Calcula proximidades de casos, que são usados para localizar dados fora do padrão gerado (*Outliers*);
 - 5- É um algoritmo computacionalmente leve, porém resistente à ruídos.
- (BREIMAN, 2001).

Basicamente, a RF é um algoritmo de classificação de conjuntos, que classifica diversas bases com a utilização de diversas árvores, ou seja:

$$\{h(x, \theta_k), k = 1, 2, \dots, \} \quad (4)$$

Sendo x o vetor de entrada e θ_k os vetores aleatórios independentes e distribuídos de maneira identificada. (Breiman, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009)

Na combinação de classificadores, onde cada classificador contribui com um único voto para a atribuição da classe mais frequente, ou melhor, mais votada ao vetor de entrada (x). Sendo assim:

$$C_{rf}^B = \text{voto majoritário } \{ C_b(x) \}_1^B \quad (5)$$

Sendo $C_b(x)$ a previsão da classe da b -ésima árvore aleatória da floresta.

A medida em que a quantidade de árvores aumenta, o algoritmo requer um atributo que mantenha uma seleção confiável, mesmo com maior dissimilaridade entre as classes. Os métodos de aproximações mais conhecidos para esta aplicação, são: *gain-ratio*, *Chi-square* e *Gini index*, sendo o último o mais utilizado.

O Gini index é utilizado como uma medida para identificar e medir a impureza de determinado elemento em relação ao todo. Sendo assim, para uma base de dados Y , este índice pode ser expresso como:

$$\sum \sum_{j \neq i} (f(C_i, Y)/|Y|) \cdot (f(C_j, Y)/|Y|) \quad (6)$$

Onde, $f(C_i, Y)/|Y|$ é a probabilidade de um caso selecionado pertencer a classe C_i .

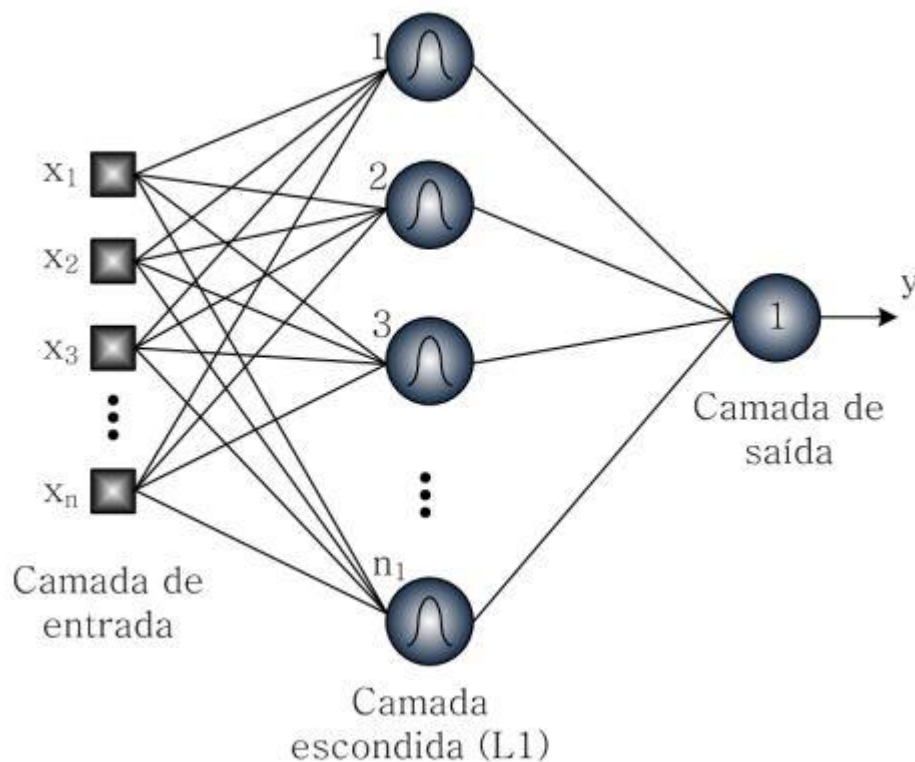
Portanto, a RF pode produzir medidas de proximidade diante de uma vasta base de dados, identificar outliers e comparar dados em relação ao todo. Essas características podem ser úteis para diversos tipos de estudos, nos quais, independente da base e do tipo dos dados, é possível identificar como cada variável

interfere no sistema como todo e, a partir disso, selecionar as melhores (Breiman, 2001).

3.3.3 Rede Função de Base Radial

A rede Função de Base Radial (*RBF*) é caracterizada devido aos neurônios da camada intermediária utilizarem funções de base radial (BRAGA; CARVALHO; LUDERMIR, 2007). Ela é estruturada como mostrado na Figura 10, sendo composta apenas por uma camada neural intermediária (escondida), na qual as funções de ativação são sempre do tipo gaussiana.

Figura 10 - Estrutura da Função de Base Radial



Fonte: Adaptado de SILVA, SPATTI e FLAUZINO (2010).

Em algumas redes multicamadas, como a RBF, ocorre que a ativação de um neurônio pode ser função da distância entre seus vetores de entrada e de peso. Esta rede é arquitetada para problemas de ajustes de curvas em um espaço de alta dimensionalidade, com o intuito principal de atuar como aproximador universal de

funções, sendo dessa maneira, muito utilizada para identificar sistemas complexos. (HAYKIN, 2001).

O processo de treinamento desta rede também é dividido em duas partes, sendo a primeira de modo não-supervisionado, e a segunda de modo supervisionado.

Na primeira etapa, são calculadas as distâncias euclidianas entre cada amostra e os ajustes dos pesos sinápticos dos neurônios da camada intermediária, dependendo apenas das características dos dados de entrada. Assim, os pesos serão modificados a cada iteração, em busca do centro de um grupo de amostras. O principal objetivo é que os neurônios aloquem os centros de suas gaussianas em regiões onde os padrões de entrada tenderão a se agrupar.

Já na segunda etapa, os pesos ajustados serão aplicados aos neurônios de saída, de forma que seja representado por um vetor linearmente separável. Com isso, os pesos poderão ser determinados por modelos lineares.

Ao final das duas etapas, será notável que esta rede consegue generalizar e responder bem a padrões de dados de entrada que não foram utilizados, tendo assim, uma maior tolerância aos ruídos de entrada (Santos, 2012).

3.3.4 *k* Vizinhos mais Próximos

Este algoritmo é baseado em instâncias *k* vizinhos mais próximos. Possui como objetivo principal maximizar a precisão das classificações, comparando instâncias atuais com instâncias armazenadas em memória. Com isso, apresenta característica ímpar em criar suposições a partir de incrementações de dados selecionados e armazenados. Seu ideal é contribuir para a seleção de boas classificações, reduzindo ruídos e requisitos de armazenagem. (KIBLER; AHA, 1988; AHA, 1989)

Diferentemente do *Random Forest*, que obtém generalização dos dados de entrada e os classificam com critérios simples, este algoritmo não armazena generalizações, fazendo reduzir muito seu trabalho no início do processo. Porém, é destinado muito trabalho no momento de classificação, no qual são calculadas semelhanças com instâncias salvas em memória. Este processo exige altos custos de atualizações para contabilizar erros nas instâncias usadas como previsão (AHA; KIBLER; ALBERT, 1991).

Este classificador, com algoritmo de aprendizado baseado em instâncias, é uma vertente da rede IBL (*Instance-based learning*). Contudo, neste caso, a saída é baseada na média dos *k*-vizinhos mais próximos. Os algoritmos consideram que instâncias semelhantes tenham classificações semelhantes, classificando assim, novas instâncias de acordo com as *k*-classificações mais semelhantes de seus vizinhos. (Godoy, 2016).


Em um estudo feito pela Embrapa, foi definida matematicamente a Função 7, similar ao funcionamento do algoritmo, sendo:

$$\text{Similaridade}(x, y) = -\sqrt{\sum_{i=1}^n f(x_i, y_i)} , \quad (7)$$

onde as instâncias são descritas por *n* atributos (MILORI et al, 2007).

Segue exemplo prático do estudo na Figura 11, simplificando o entendimento.

Figura 11 - Exemplo de aplicação do k-NN



Fonte: (AHA; KIBLER; ALBERT, 1991).

Para a classificação k-NN ao conjunto desconhecido, é atribuída a classe mais comum entre seus k-vizinhos mais próximos. Quando $k=1$, o conjunto desconhecido é atribuído à classe do conjunto de treinamento mais próxima do seu espaço padrão. O algoritmo possui apenas um parâmetro livre (o número de k-vizinhos) que é controlado pelo usuário, visando obter melhor classificação (DUDA; HART; STORK, 2001).

A grande vantagem em utilizar algoritmos baseados em instâncias, é a capacidade de se adaptar a dados nunca vistos anteriormente, criando assim uma nova instância de armazenagem ou, descartando a anterior. Já em relação aos pontos negativos, deve-se ressaltar que possui um preço computacional alto, devido ao armazenamento de diversas instâncias; certa intolerância com atributos irrelevantes; além de fornecer poucas informações sobre a estrutura de dados como um todo.

4 Metodologia

Como já descrito anteriormente, os motores de indução são de suma importância, principalmente no setor industrial. Já também supracitado, falhas relacionadas a curto circuito no estator representam pouco mais de 20% dos tipos de falhas presentes neste tipo de máquina. Sendo assim, foi feita a análise a partir de sinais de correntes do motor em estado normal e, posteriormente, foi analisado com falhas de curto circuito do estator.

As aferições foram realizadas em laboratório, para simular o ambiente industrial. A conexão do motor foi realizada em delta, com tensão de alimentação de linha em 220 V equilibrada. O motor foi acionado por três inversores de frequência diferentes para a análise.

Seguem abaixo os dados referentes ao motor utilizado e, também, dos inversores responsáveis pelos acionamentos. Na sequência os dados foram tratados e simulados no software *Weka*. Dentro do software, foram aplicados três métodos de filtragem em três classificadores diferentes para comparação de desempenho.

4.1 Banco de dados

Os parâmetros e características do motor utilizado para aquisição dos dados práticos deste trabalho, estão descritos na Tabela 1.

Tabela 1 - Parâmetros e características do MIT utilizado no trabalho

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

A Tabela 2, apresenta os parâmetros e características dos inversores de frequência utilizados no trabalho.

Tabela 2 - 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
Frequência de chaveamento (kHz)	8	8	4

A Tabela 3, apresenta dados obtidos através do banco de dados utilizado para este trabalho. Os valores representam a quantidade de aquisições com o motor saudável e com determinados curtos-circuitos aplicados no estator, os diferenciando pelo inversor que realizou o acionamento. Esse banco de dados também foi utilizado em Godoy (2016), Palácios (2016), Lopes (2016), entre outros.

Tabela 3 - Quantidade de aquisições utilizados por defeito

Motor	Condição	Sinamics G110	Micromaster MM440	ATV12H075M2
Motor 1 (0,74 kW)	Saudável	74	73	84
	1% CC no estator	76	76	83
	3% CC no estator	76	70	84
	5% CC no estator	76	70	84
	10% CC no estator	75	76	84

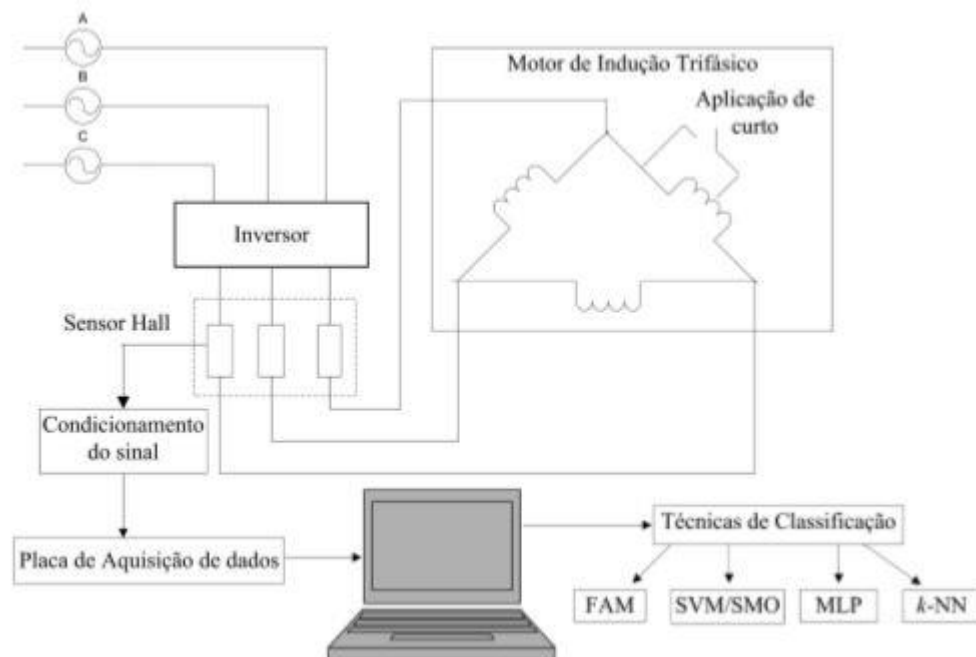
4.2 Inserção de falhas

Para desenvolvimento do banco de dados utilizados no trabalho, foram aplicados curtos-circuitos no estator do motor, como já mostrado na Tabela 3. A seguir, será detalhado o método para esta aplicação.

4.2.1 Aplicação de curto circuito no estator

Nesta série, será detalhada como foi feita a inserção de curto-circuito entre as espiras do enrolamento do estator. O estator do motor utilizado (0,74kW) possui 6 bobinas, isoladas com verniz. Além disso, são respeitadas as medidas originais e a classe de isolamento do motor. As três fases do enrolamento do estator foram montadas de forma a possibilitar a geração artificial de falhas de isolamento entre as espiras, permitindo ensaios com 1%, 3%, 5% e 10% de curto-circuito no estator. A Figura 12 ilustra como foi feito o esquema de acionamento do motor.

Figura 12 - Diagrama de acionamento do MIT.



Fonte: Godoy, 2016.


Portanto, as falhas emuladas são consequências de um processo de deterioração do isolamento entre as bobinas, no qual se altera a simetria da corrente do estator para uma forma assimétrica. (DLAMINI; BARENDSE, 2012). É importante salientar, que o fato do estator possuir assimetrias em relação aos seus enrolamentos, não impede a máquina de continuar operando com torque reduzido, podendo agravar ainda mais a situação.

Para identificar tais anomalias, podem ser realizados testes comuns de isolamentos entre fases, ou até verificando o possível aumento da corrente de alimentação da máquina. (Godoy, 2016)

Como já abordado, o ensaio foi realizado em ambiente de laboratório, simulando em ótimas condições o ambiente de operação. O ensaio foi feito com o motor operando em regime permanente, sob circunstâncias de cargas constantes. Além disso, houve utilização de três inversores diferentes para o acionamento, a fim de validar a estratégia para diferentes modelos e fabricantes.

A Figura 13 apresenta o motor (0,74kW) rebobinado com *taps* de derivação dos enrolamentos. O dispositivo com as chaves *on/off*, mostrado no detalhe desta figura, é acoplado aos bornes de ligação dos *taps* de derivação. Sendo assim, quando as chaves são acionadas, é possível selecionar a ocorrência de curto-circuito entre as espiras com as taxas de porcentagens citadas no início do Capítulo 4.

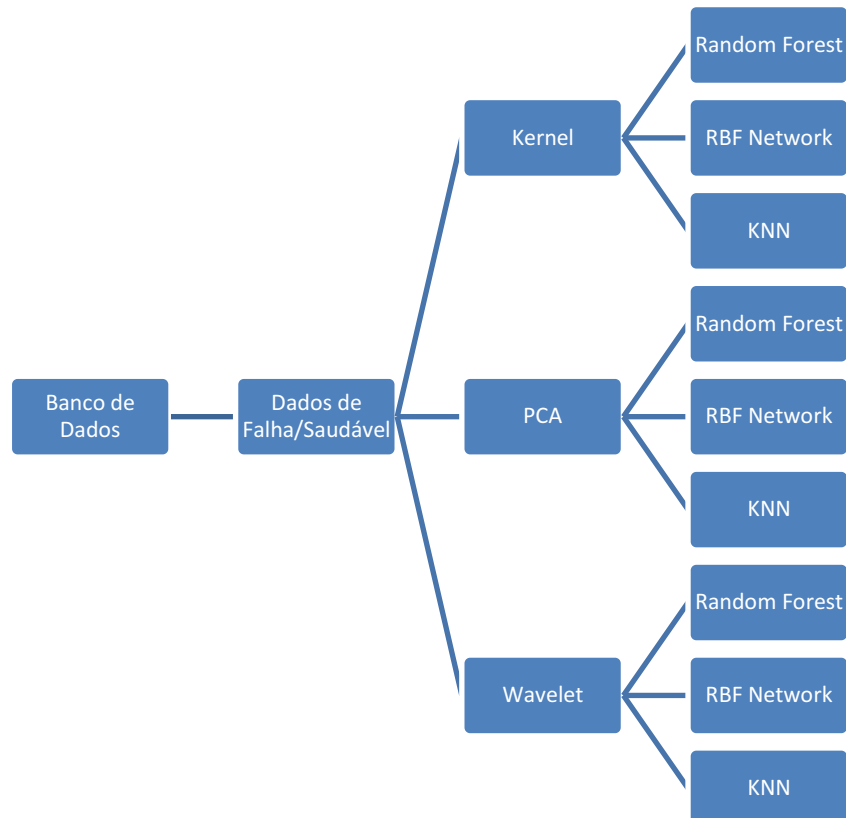
Figura 13 - Estator do MIT rebobinado com *taps*.



4.3 CLASSIFICAÇÃO

A Figura 14, descreve o sistema de como foram feitas as classificações dos dados e, as aplicações dos métodos de filtragem junto aos classificadores.

Figura 14 - Diagrama de pré-processamento e classificação de falhas



Fonte: Autoria própria

Com a base de dados tratada, serão comparados os valores apresentados com a MIT em operação saudável, e com aplicação de curto-circuito nos enrolamentos do estator. A etapa posterior, consiste em passar esses dados através de sinais de correntes discretizados no tempo por métodos de filtragens, neste caso, *Kernel*, *PCA* e *Wavelet*. Por fim, dispõe-se a classificá-los de maneira inteligente, como já descrito anteriormente no trabalho, utilizando *Random Forest*, *RBF Network* e *k-NN*.

4.3.1 Estruturas de classificação

Nesta subseção, serão apresentados os parâmetros utilizados em cada classificador para todas as classificações.

Para o método k-NN, foi notado que as melhores precisões foram obtidas com valores de k menores ou igual a 4. Nas simulações, foi utilizado $k=1$, sendo um único vizinho mais próximo, fato que contribuiu com um melhor desempenho no trabalho. O algoritmo de busca utilizado é baseado no método de cálculo da distância Euclideana.

Já para as classificações realizadas com a RBF, o algoritmo é descrito por uma regressão logística aplicada a K grupos significativos como funções básicas. Para todas as simulações envolvendo esta aplicação, foram adotadas regressões com o parâmetro máximo de $1.0E-8$.

Por fim, em todas as classificações empregando a RF, foram utilizadas 100 iterações. Este algoritmo apropria-se do método *base learner*, o qual busca uma generalização entre os dados iterados no sistema. Todas as simulações foram realizadas junto ao software *Weka*.

5. Resultados Experimentais

Neste Capítulo, serão apresentados os resultados obtidos a partir da implementação dos métodos descritos na seção anterior. O objetivo é obter conclusões sobre a eficácia do método apresentado, além de detectar anomalias referentes a falhas na máquina.

Os resultados obtidos serão mostrados em matrizes de confusão geradas nas simulações, e montadas com os melhores valores obtidos em alguns testes realizados. Para uma comparação visual sobre os resultados, foram desenvolvidos gráficos que também estão expostos a seguir.

A matriz de confusão dimensiona quantos exemplos da base de dados utilizada foram classificados de forma correta pelo modelo construído (representado na diagonal principal), em oposição às classificações preditas para cada classe. Os valores contidos na diagonal principal da matriz indicam os acertos no reconhecimento dos padrões, que estão sendo indicados pelas respectivas colunas e linhas.

Os dados utilizados foram de sinais de corrente do estator, no domínio do tempo. Estes dados passaram por métodos de filtragens e classificações para comparações e melhores conclusões. Em todas as simulações, temos 3288 amostras utilizadas para treinamento e validação dos classificadores.

5.1 Kernel

A Tabela 4 apresenta as matrizes de confusões geradas a partir de aplicações deste método de filtragem, em cada um dos classificadores utilizados. Já a Tabela 5, apresenta os resultados gerais, referente as precisões globais das classificações.

Tabela 4 - Comparação das matrizes de confusão geradas pelo método Kernel

RF			RBF		k-NN	
Classes	Saudável	Falha	Saudável	Falha	Saudável	Falha
Saudável	429	231	0	660	445	215
Falha	122	2506	0	2628	204	2424

Tabela 5 - Comparação dos desempenhos dos classificadores para o método Kernel

Método de filtragem - Kernel	RF	RBF	k-NN
Total de instâncias	3288	3288	3288
Instâncias Classificadas Corretamente	2935	2628	2869
Instâncias Classificadas Incorretamente	353	660	419
% Correta	89,3%	79,9%	87,3%
% Incorreta	10,7%	20,1%	12,7%

Analisando a Tabela 5, notamos que para este método de filtragem, a maior precisão global foi utilizando a RF, com 89,3% das amostras classificadas corretamente. Em contrapartida, ao utilizarmos o filtro junto a RBF, foi obtido uma precisão global de aproximadamente 80%. Para detalhar ainda mais a análise, o próximo passo é a aferição da Tabela 4.

Na Matriz, para a análise do motor saudável, observamos que a melhor classificação se manteve, com 77,86% de precisão utilizando a RF, contra 68,57% com o k-NN. Percebemos também, que para o motor saudável, a RBF não identificou nenhuma amostra corretamente, fato que demonstra uma inviabilidade total desta classificação.

Detalhando essa impraticabilidade, ao não conseguirmos categorizar nenhuma competência com o motor saudável, concluímos que todos os dados tratados e/ou todos os dados futuros adicionados, serão considerados como instâncias para o motor em falha, operando como um falso classificador. Ou seja,

aprendemos que o mesmo não conseguiu realizar nenhuma classificação e todos os dados, saudáveis ou não, foram e serão considerados diretamente como motor em falha, demonstrando assim, nenhuma confiabilidade.

Para a classificação de falha, a partir da aplicação de curto-circuito no estator da máquina, observamos que utilizando o k-NN, obtivemos 91,85% de precisão, seguido de 91,56% com a RF e, 79,93% empregando a RBF.

Por fim, concluímos que tanto a RF quanto o k-NN apresentaram dificuldades para categorização dos dados referentes ao motor saudável. Além disso, verificamos a inviabilidade da classificação através da RBF para este filtro. Assim, para a catalogação utilizando o método de filtragem Kernel, a RF manifestou o melhor desempenho em comparação aos outros classificadores.

5.2 PCA

A Tabela 6 apresenta as matrizes de confusões geradas a partir de aplicações desse método de filtragem, em cada um dos classificadores utilizados. Já a Tabela 7 apresenta os resultados gerais, referente as precisões globais das classificações.

Tabela 6 - Comparação das matrizes de confusão geradas pelo método PCA

Classes	RF		RBF		k-NN	
	Saudável	Falha	Saudável	Falha	Saudável	Falha
Saudável	355	305	91	569	391	269
Falha	145	2483	69	2559	264	2364

Tabela 7 - Comparação dos desempenhos dos classificadores para o método PCA

Método de filtragem - PCA	RF	RBF	k-NN
Total de instâncias	3288	3288	3288
Instâncias Classificadas Corretamente	2838	2650	2755
Instâncias Classificadas Incorretamente	450	638	533
% Correta	86,3%	80,6%	83,8%
% Incorreta	13,7%	19,4%	16,2%

Analisando a Tabela 7, notamos que para este método de filtragem, a maior precisão global foi utilizando a RF novamente, com 86,3% das amostras classificadas corretamente, seguido pelo k-NN com 83,8% e RBF com 80,6%. Logo, em aspectos de classificação geral, novamente obtivemos os melhores resultados com a *Random Forest*. Para detalhar ainda mais a análise, o próximo passo é a observação da Tabela 6.

Na Matriz, para a análise do motor saudável, observamos que a melhor classificação se manteve, com 71% de precisão empregando a RF, contra 59,7% utilizando o k-NN, e aproximadamente 57% com a RBF. Nessa categorização, é notório que as redes tiveram dificuldades para organização dos dados, sendo que duas delas apontaram menos de 60% das amostras com precisão. Ademais, mesmo sendo o melhor classificador neste filtro, ao compararmos a *Random Forest* junto ao filtro Kernel, obtivemos um escalonamento inferior em quase 10% das amostras.

Para a classificação de falha, a partir da aplicação de curto-circuito no estator da máquina, percebemos que utilizando o k-NN, conseguimos 89,78% de precisão, seguido de 89,06% com a RF e, 81,8% utilizando a RBF.

Posto isso, concluímos que as redes apresentaram dificuldades ainda maiores para organizar os dados referentes ao motor saudável, com dois classificadores obtendo menos de 60% de precisão. Já na máquina com falha, alcançamos resultados semelhantes à categorização anterior. Em outros termos, nos é explanado que são possíveis duas classificações com aproximadamente 90% de exatidão com o estator da máquina em falha, tornando-os assim, até aqui, bons classificadores para estudos e aplicações mais elaboradas.

5.3 Wavelet

A Tabela 8 apresenta as matrizes de confusões geradas a partir de aplicações deste método de filtragem, em cada um dos classificadores utilizados. Já a Tabela 9 apresenta os resultados gerais, referente às precisões globais das classificações.

Tabela 8 - Comparação das matrizes de confusão geradas pelo método Wavelet

Classes	RF		RBF		k-NN	
	Saudável	Falha	Saudável	Falha	Saudável	Falha
Saudável	128	532	2	658	375	285
Falha	23	2605	1	2627	294	2334

Tabela 9 - Comparação dos desempenhos dos classificadores para o método Wavelet

Método de filtragem - Wavelet	RF	RBF	k-NN
Total de instâncias	3288	3288	3288
Instâncias Classificadas Corretamente	2733	2629	2709
Instâncias Classificadas Incorretamente	555	659	579
% Correta	83,1%	80,0%	82,4%
% Incorreta	16,9%	20,0%	17,6%

Analisando a Tabela 9, o primeiro fato notório, é que para este método de filtragem, os três classificadores se comportaram de maneira semelhante, obtendo precisões globais na faixa de 80%. Mais uma vez, a melhor precisão foi utilizando a RF, com 83,1% de precisão, seguido pelo k-NN com 82,4% e por fim, pela RBF, com 80% de precisão nas classificações.

Em vista disso, a primeira conclusão é que para o estudo de viabilidade para aplicação de qualquer um dos métodos de filtragem deste trabalho, em questões globais de análise, obteremos os melhores resultados aplicando o método escolhido junto à *Random Forest*. Para detalhar ainda mais a análise, o próximo passo é a análise da Tabela 8.

Nas Matrizes, para a análise do motor saudável, vislumbramos que a melhor classificação se deu pelo emprego da RF, com aproximadamente 85% de precisão. Entretanto, nesta classificação, notamos uma queda significativa no número de instâncias elencadas junto ao motor saudável, apesar da melhor categorização global.

Portanto, mesmo com uma boa taxa de exatidão, o número baixo de instâncias questiona a aplicabilidade deste classificador junto à TW. Adiante, para esse filtro junto ao k-NN, notamos uma baixa precisão, mesmo classificando muitas competências para o motor saudável, com aproximadamente 56%, atuando de maneira contrária à RF.

A classificação utilizando a RBF foi novamente ineficaz, catalogando apenas três instâncias com o motor saudável, fato que nos leva a descartar a mesma em possíveis aplicações futuras, visto que, independente dos dados, o classificador desconsidera o motor em estado saudável, atuando novamente como falso classificador.

Nessa análise, é possível visualizar uma alta discrepância entre a exatidão entregue pela RF e as outras classificações. Percebemos que, para o motor saudável, somado a este método de filtragem, o k-NN teve extrema dificuldade na classificação, propondo assim, precisões ruins quando comparadas à RF.

Também foi notório, apesar da boa precisão na classificação, que o número de instâncias elencadas com o motor saudável, reduziu muito na utilização da RF. Isso ilustra uma divergência na utilização desse filtro com todos esses classificadores para a máquina em estado saudável, dado que o k-NN não reluziu boas precisões e, a RBF não atuou.

Para a classificação de falha, a partir da aplicação de curto circuito no estator da máquina, reforçamos novamente o padrão obtido nas análises anteriores para o motor com falha. A melhor exatidão se manteve empregando o k-NN, com 89,12% de precisão, seguido de aproximadamente 83% com a RF e, 80% utilizando a RBF.

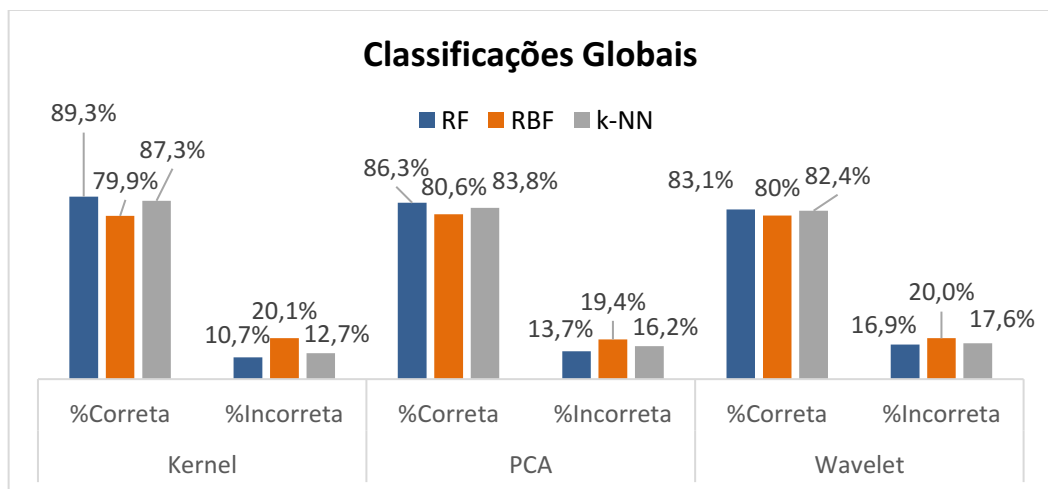
Concluimos assim, que obtivemos também um padrão para análise do motor com falha, onde o melhor classificador foi o k-NN, seguido pela RF, e pela RBF, salientando, principalmente, que a última não é confiável, posto que classifica praticamente todos os dados considerando o motor em falha.

Outro fator relevante observado, é que nas demais catalogações, as diferenças entre as precisões para o motor em falha, ao utilizarmos o k-NN e a RF, eram mínimas (detalhes menores que 1%). Já neste classificador final, tivemos uma diferença de quase 7% entre elas, fator que pode estar ligado com a queda significativa de instâncias elencadas para o motor saudável. Esta mesma análise, comparando o k-NN com a RBF, é ineficaz, pois a RBF em duas categorizações não se mostrou uma classificadora confiável para os respectivos filtros.

5.4 RESULTADOS GERAIS

Nesta seção, serão apresentados de maneira mais objetiva e visual, os resultados discutidos nas Seções 5.1, 5.2 e 5.3, com o objetivo de salientar as conclusões prévias. A Figura 15 apresenta o comparativo entre as classificações médias globais para cada método de filtragem aplicado a cada classificador.


Figura 15 - Comparação de resultados globais.



Fonte: Autoria própria.

A Figura 16 apresenta o comparativo das classificações, tanto no motor saudável, quanto em falha.

Figura 16 - Comparação dos resultados para motor saudável e em falha.



Fonte: Autoria própria.

Como podemos analisar, para todos os métodos de filtragem aplicados à RF, obtivemos as melhores precisões, tanto para as classificações médias globais, quanto para o motor em estado saudável. Para o motor em falha, todos os filtros tiveram melhores classificações junto ao k-NN, apresentando precisões próximas à 90%.

É importante citar que, tanto a RF quanto o k-NN aplicados a *Wavelet*, não performaram bem para o motor saudável, sendo que a primeira reduziu significativamente o número de instâncias classificadas, enquanto o k-NN, apresentou uma precisão muito ruim, próxima de 55%. Para mais, aplicando a RBF, obtivemos apenas 3 instâncias elencadas para o motor saudável e, portanto, podemos considerar que esse classificador não atuou junto ao método de filtragem.

Ainda, notamos que os outros filtros também não atuaram bem quando categorizados com a RBF, tanto na máquina saudável quanto na máquina com falha. Esses resultados refletem diretamente nas classificações médias gerais, nas quais essa rede teve a menor precisão em todos os casos, com destaque para o filtro *Kernel* e *Wavelet*. Nessa circunstância, o classificador além de não ter atuado, catalogou todos os dados como motor em falha, não demonstrando assim, nenhuma confiabilidade para esse tipo de aplicação.

Generalizando, é possível garantir que para esta base de dados, ordenando o desempenho de máquinas de indução trifásicas, aplicando curto circuito nos enrolamentos do estator, a melhor classificação se deu pelo emprego do *Kernel* junto à RF. Podemos também, afirmar que a RF foi a melhor classificadora em termos gerais, pois mesmo com a máquina em falha, ela junto aos filtros, obteve precisões notáveis.

Deve-se salientar que, para a máquina em falha, a melhor classificação se deu através da k-NN junto aos filtros. Em termos gerais, ela expôs o segundo melhor desempenho para a base de dados e os métodos aplicados. Por fim, tivemos a RBF, que se mostrou não confiável, visto que ela não atuou em dois métodos de filtragens e, classificou poucas instâncias junto ao PCA. Essa baixa catalogação mostrada pela RBF, pode vincular-se ao fato de ser uma rede neural multicamadas e, portanto, não se comportar muito bem diante de apenas 3288 instâncias, visto que um de seus diferenciais é a boa atuação com ampla base de dados.

Em vista disso, analisando os gráficos e os resultados, percebemos a imprescindibilidade da escolha do método adequado de classificação, visto que ele afeta diretamente o desempenho da máquina. Deste modo, se o contexto do trabalho

almeja classificações com boas precisões, e busca por métodos computacionais leves, temos a RF como a melhor opção, se destacando com bom desempenho para grandes bases de dados, escalando-os no conceito de floresta.

Para aplicação baseada em instâncias (k vizinhos mais próximos), o custo computacional é maior, devido à alta armazenagem de novas instâncias. Assim, vemos que essa aplicação seria indicada para atualizações de base de dados totalmente diferentes dos padrões das anteriores – um dos motivos pelos quais essa classificação se destacou trabalhando com a máquina em falha.

Por último, os resultados mostraram que para este tipo de classificação a RBF não obtêm eficiência e ela não é recomendada para essa finalidade. Esse classificador pode se comportar melhor em análises com mais dados aplicados, devido à estrutura multicamadas que ele comporta.

6. CONSIDERAÇÕES FINAIS

Este trabalho consistiu na análise e avaliação de diferentes classificações, para diagnóstico do estator do motor em estado saudável e em aplicação de falha. Os dados utilizados foram referentes a experimentos realizados em motores de indução trifásicos, acionados por inversores de frequência. O experimento foi realizado em laboratório, simulando de maneira muito eficiente o ambiente industrial.

Nas Seções 5.1, 5.2 e 5.3 foram apresentadas as classificações médias globais e as matrizes de confusões para todos os métodos de filtragens aplicados aos três classificadores. Na Seção 5.4, foi feita uma abordagem mais detalhada sobre os resultados, além de mostrá-los de maneira mais visual. Finalmente, foi constatado que a *Random Forest* apresentou melhor precisão e eficácia em relação ao k-NN e RBF Network.

Para a classificação referente à máquina em estado saudável, foi notada dificuldade na maioria das categorizações, obtendo precisões inferiores a 60% em alguns casos. Neste cenário, a *Random Forest* se mostrou mais eficaz, demonstrando precisões superiores à 71% nas três classificações. Para a máquina em falha, os classificadores k-NN e *Random Forest* performaram satisfatoriamente, com destaque para a primeira, que apresentou precisões superiores a 89% nas três classificações.

A rede RBF *Network* não alcançou exatidões em todos os casos e não se mostrou eficaz para esse tipo de análise. Sabe-se, entretanto, que esse classificador pode ser empregado de modo eficiente em outras análises e métodos, para condições que cataloguem uma quantidade de dados muito maior do que a coletada nesse estudo. O k-NN por sua vez, se revelou muito eficiente lidando com a máquina em falha, sendo recomendado para este tipo de análise, em sistemas que demandam muito computacionalmente, pois ela comporta a característica de armazenar milhares de novas instâncias diferentes.

Finalmente, a *Random Forest* expôs ótimas precisões médias globais, em consequência do bom desempenho tanto para a máquina saudável quanto em falha. Sendo assim, esse classificador também é recomendado para o tipo de projeto abordado, não demandando muito computacionalmente e se comportando muito bem à frente de uma extensa base de dados.

Assim sendo, os resultados conquistados neste trabalho apresentam os níveis de precisões de três métodos de filtragem, aplicados a três classificadores inteligentes

de falhas de estator em uma máquina de indução trifásica. Ainda, foram apresentadas a viabilidade e as conclusões sobre as aplicações de tais métodos junto ao contexto demandado, focando principalmente em esforço computacional e em nível de precisão.

REFERÊNCIAS

- ABB GROUP, **Fundamentals of Motors**, 2015. Disponível em:<<http://sites.ieee.org/houston/files/2016/01/3-Fundamentals-of-Motors-IEEE-Houston-February-2015.pdf>>. Acesso em: 15 de maio de 2019.
- AHA, W.; KIBLER, D. **Noise-tolerant instance-based learning algorithms**. Proceedings of the Eleventh International Joint Conference on Artificial Intelligence. Detroit, p.794-799, 1989.
- AHA, W.; KIBLER, D; ALBERT, M. **Instance-Based Learning Algorithms**. Machine Learning, vol. 6, pg. 37-66, 1991.
- ARAÚJO, R. d. S. **Desgaste Prematuro e Falhas Recorrentes em Rolamentos de Motores de Indução Alimentados por Inversores: Análise e Proposta de Solução**. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2011.
- BACCARINI, L. M. R.; MENEZES, B. R. de; CAMINHAS, W. M. **Fault induction dynamic model for computer simulation: simulation results and experimental validation**. Mechanical Systems and Signal Processing, vol. 24, no. 1, 2010.
- BACCARINI, L.; AVELAR, V. S.; SILVA, V.; AMARAL, G. F. V. **Intelligent system design for stator windings faults diagnosis: suitable for maintenance work**. *Journal of Software Engineering and Applications*, vol. 6, no. 10, pp. 526-532, 2013.
- BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G.-A. **Advances in diagnostic techniques for induction machines**. IEEE Transaction on Industrial Electronics, vol. 55, no.12, pp.4109-4126, 2008.
- BENBOUZID, M. E. H. **A Review of Induction Motors Signature Analysis as a Medium for Faults Detection**. IEEE Transactions on Industrial Electronics, v. 47, October, n. 5, pp. 984-993, 2000.
- BONNETT, A.; SOUKUP, G. **Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors**. Industry Applications, IEEE Transactions on, v. 28, n. 4, p. 921-937, 1992.
- BONNETT, A.; YUNG, C. **Increased efficiency versus increased reliability**. IEEE Industry Applications Magazine, v. 14, n. 1, p. 29–36, jan./feb. 2008.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. Ed. Rio de Janeiro: LTC, 2007.
- BREIMAN, L. **Random Forests**. Machine Learning, v.45, n.1, p.5-32, 2001.
- BREIMAN, L.; CUTLER, A. **Random Forest**, 2004. Disponível em:<https://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm>. Acesso em: 22 de Agosto de 2020.

CHAPMAN, S. J. **Fundamentos de Máquinas Elétricas**: 5. Ed. Porto Alegre: AMGH Editora Ltda., 2013.

DLAMINI, M.; BARENDSE, P. **The detection of inter-turn stator faults on inverter fed induction motors**. In: IEEE Power Engineering Society Conference and Exposition in Africa (PowerAfrica). [S.l.: s.n.], pg. 1-8, 2012.

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

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2. Ed. New York: J. Willey and Sons, Inc, 2001.

EPE, “2014 national energy balance – base year 2013 – final report (in portuguese),” **Empresa de Pesquisa Energética – Ministério de Minas e Energia**, p.288, 2014.

FITZGERALD, A.; KINGSLEY, C.; UMANS, S. **Máquinas Elétricas**: 7. ed. Porto Alegre: AMGH Editor Ltda., 2014.

GODOY, W. F.; SILVA, I. N.; GOEDEL, A.; PALÁCIOS, H. C.; BAZAN, G. H.; SOTELO, D. M. **An Application of Artificial Neural Networks and PCA for Fault Diagnosis in Inverter-Fed Induction Motors**. In: IEEE, XXII International Conference on Electrical Machines (ICEM), 2016.

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.

GUIDO, R. C.; SLAETS, J. K. R. A. L. P. J. **A New Technique to Construct a Wavelet Transform Matching a Specified Signal with Applications to Digital, Real Time, Spike, and Overlap Pattern Recognition**. Digital Signal Processing, v.16, n. 1, p. 24-34, 2006.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **Random Forests, The Elements of Statistical Learning**. Springer, New York, p.587-604, 2009.

HAYKIN, S. S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

IEEE P1719, **Draft Guide for Evaluating Stator Cores of AC Electric Machines Rated 1MVA and Higher**. Materials Subcommittee of the Electric Machinery Committee. *IEEE Standards Department*, 2013.

KIBLER, D.; AHA, W. **Case-based classifications**. Proceedings of the Case-Based Reasoning Workshop at AAAI, p. 62-67, 1988.

LEI, Z.; ZHOU, Y.; ZHANG, X. **A Classification of Milling TCM Based on Bandpass Filter and Kernel Extreme Learning Machine**. In: IEEE, 2018 Prognostics and System Health Management Conference (PHM-Chongqing), 2018.

MALLAT, S. **A Wavelet Tour of Signal Processing: The Sparse Way**. 3. ed. Burlington, USA: Elsevier, 2009.

MILORI, D.; FERREIRA, E.C.; FERREIRA, E.J.; NETO, L.; SILVA, R. **Métodos de Seleção de Comprimentos de Onda e Redes Neurais Artificiais como Estratégias de Calibração em Espectroscopia de Emissão Ótica Induzida por Laser**. Boletim de pesquisa e desenvolvimento – Embrapa Instrumentação Agropecuária de São Carlos, 2007.

MOURÃO, E. S.; ABREU, C. C. E. de. **Sobre a escolha dos filtros wavelet e da função janela para sistemas de melhoramento de voz baseados na DWT**. XXXIV Simpósio Brasileiro de Telecomunicações, Santarém, PA, 2016.

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

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

SHANG, W.; WU, Z.; XU, Y.; ZHANG, Y.; WEI, Z. **Hyperspectral Supervised Classification Using Mean Filtering Based Kernel Extreme Learning Machine**. In: IEEE, Fifth International Workshop on Earth Observation and Remote Sensing Applications (EORSA), 2018.

SIDDIQUI, K. M.; SAHAY, K.; GIRI, V. K. **Health monitoring and fault diagnosis in induction motor, a review**. International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, v. 3, n. 1, p. 6549 – 6565, 2014.

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

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

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

TRAN, V. T.; ALTHOBIANI, F.; BALL, A.; CHOI, B.-K. **An application to transient current signal based induction motor fault diagnosis of fourier besel expansion**

and simplified fuzzy artmap. Expert Systems with Applications, vol. 40, no. 13, pp. 5372 – 5384, 2013.

TRIGEASSOU, J.-C. **Electrical Machines Diagnosis.** London, UK: ISTE Ltd.; Hoboken, USA: John Wiley & Sons, Inc., 2011.

V. D. Katkar and D. S. Bhatia, "Lightweight approach for detection of denial of service attacks using numeric to binary preprocessing," *2014 International Conference on Circuits, Systems, Communication and Information Technology Applications (CSCITA)*, Mumbai, 2014, pp. 207-212.

WASSERMAN, P.; SCHWARTZ, T. Neural networks II. What are they and why is everybody so interested in them now? **IEEE Expert**, v.3, n. 1, p. 10-15, 1988.

WEEKS, M. **Processamento de Sinais Utilizando Matlab e Wavelets.** 2 ed. Rio de Janeiro: LTC, 2012.

WEG. **Motores Elétricos.** Guia de Especificação de Motores Elétricos. 2017. Disponível: <<https://static.weg.net/medias/downloadcenter/h32/hc5/WEG-motores-eletricos-guia-de-especificacao-50032749-brochure-portuguese-web.pdf>>. Acesso em 17 de maio de 2019.

WEG. **Motor de Indução Trifásico: Rotor Bobinado com Sistema Motorizado de Levantamento das Escovas.** 2013. Disponível em: <<https://static.weg.net/medias/downloadcenter/h6c/h8a/WEG-motor-com-sistema-de-levantamento-das-escovas-folheto-50042391-catalogo-portugues-br.pdf>>. Acesso em: 20 de maio de 2019.

YEH, C.-C.; SIZOV, G. Y.; SAYED-AHMED, A.; DEMERDASH, N. A. O.; POVINELLI, R. J.; YAZ, E. E.; IONEL, D. M. **A Reconfigurable Motor for Experimental Emulation of Stator Winding Inter-Turn and Broken Bar Faults in Polyphase Induction Machines.** In: IEEE INTERNATIONAL CONFERENCE OF ELECTRIC MACHINES & DRIVES (IEMDC), 2007. **A nais...**[S.1.: s.n.], 2007, v.2, p.1413-1419.