

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
ENGENHARIA ELÉTRICA

NATAN TAKEO NODA LIMA

**CLASSIFICAÇÃO DE DEFEITOS DE BARRAS QUEBRADAS DE ROTOR EM
MOTORES DE INDUÇÃO TRIFÁSICOS ACIONADOS POR INVERSORES DE
FREQUÊNCIA UTILIZANDO TRANSFORMADA *WAVELET***

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO
2018

NATAN TAKEO NODA LIMA

CLASSIFICAÇÃO DE DEFEITOS DE BARRAS QUEBRADAS DE ROTOR EM MOTORES DE INDUÇÃO TRIFÁSICOS ACIONADOS POR INVERSORES DE FREQUÊNCIA UTILIZANDO TRANSFORMADA *WAVELET*

Trabalho de Conclusão de Curso de graduação, apresentado à disciplina Trabalho de Conclusão de Curso 2, do curso de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para a obtenção do título de Bacharel.

Orientador: Prof. Dr. Wagner Fontes Godoy

CORNÉLIO PROCÓPIO
2018



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



FOLHA DE APROVAÇÃO

Natan Takeo Noda Lima

Classificação de defeitos de barras quebradas de rotor em motores de indução trifásicos acionados por inversores de frequência utilizando transformada wavelet

Trabalho de conclusão de curso apresentado às 8:00hhs do dia 08/06/2018 como requisito parcial para a obtenção do título de Engenheiro Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

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

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

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

Dedico este trabalho à minha família,
por todo o apoio incondicional.

AGRADECIMENTOS

Primeiro de tudo, agradeço a Deus por ter-me capacitado, por ter sido meu refúgio em meio a todas as dificuldades que surgiram se não fossem os cuidados d'Ele, eu não teria suportado nem a metade do que suportei ao longo da graduação. Também sou eternamente grato a Nossa Senhora, por ser a minha fiel intercessora e por ser aquela que providenciava para que tudo concorresse para o meu bem.

Aos meus pais, Valentin Pereira Lima e Massako Noda Lima, meus irmãos, Nalan Tadao e Kyrios Toshiyo, minha irmã, Ana Vitória, que sempre me apoiaram incondicionalmente, principalmente com suas orações a Deus por mim, para que tudo ocorresse na mais perfeita harmonia.

Ao meu orientador, Prof. Wagner Fontes Godoy, pela sua orientação, confiança, ensinamentos profissional e pelos seus valorosos conselhos.

Aos professores da banca avaliadora, Prof. Marco Antonio Ferreira Finocchio, Prof. Danilo Sipoli Sanches e Prof. Rodrigo Henrique Cunha Palácios pelas contribuições dadas.

A todos os meus familiares, que sempre se preocuparam tanto comigo.

A todos os meus professores e colaboradores, que de uma forma ou de outra contribuíram para que tudo isso fosse possível hoje.

Aos meus amigos de graduação, que me proporcionaram momentos de descontração e que compartilharam momentos de alegria e dificuldades.

Por fim, sou grato aos meus amigos do GOU de Campo Mourão e de Cornélio Procópio, do Grupo Jovens Kairós, do Grupo Shalom e demais amigos de caminhada, por terem sido as pessoas que fizeram esses anos de graduação se tornarem mais leves, através de suas amizades e companheirismo, amizade essas que levarei por toda a vida.

“Dê-me, Senhor, agudeza para entender, capacidade para reter, método e faculdade para aprender, sutileza para interpretar, graça e abundância para falar, acerto ao começar, direção ao progredir e perfeição ao concluir”.

(São Tomás de Aquino)

RESUMO

LIMA, Natan Takeo Noda **Classificação de defeitos de barras quebradas de rotor em motores de indução trifásicos acionados por inversores de frequência utilizando transformada *wavelet***. 2018. 47 f. Trabalho de Conclusão de Curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2018.

Devido ao importante papel desempenhado pelos motores de indução na indústria torna-se necessário o desenvolvimento de ferramentas preditivas que ofereçam suporte para o correto diagnóstico e a classificação de falhas ainda em fase inicial, permitindo aumento na produtividade e redução das perdas econômicas geradas por paradas indesejadas. Este trabalho apresenta um estudo relacionado as falhas de barras quebradas de rotor em motores de indução trifásicos acionados por diferentes inversores de frequência. Para o pré-processamento dos sinais de correntes utiliza-se a Transformada *Wavelet* Discreta, onde são aplicados diretamente os sinais das correntes de estator. Para o diagnóstico e a classificação do nível de severidade das falhas são utilizadas e comparadas duas técnicas distintas de aprendizado de máquina: (i) Árvores de Decisão e (ii) *Random Forest*.

Palavras-chave: Sistemas inteligentes. Motores de Indução Trifásicos. Falhas de Rotor. Transformada *Wavelet* Discreta. Árvore de Decisão. *Random Forest*.

ABSTRACT

LIMA, Natan Takeo Noda **Classification of defects of broken rotor bars in three-phase induction motors driven by frequency inverters using wavelet transform**. 2018. 47 f. Course competition assignment (Undergraduate) – Electrical Engineering. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2018.

Due to the important role played by the induction motors in the industry it is necessary to develop predictive tools that offer support for the correct diagnosis and classification of failures still in the initial phase, allowing an increase in productivity and reducing of the economic losses generated by unwanted stops. This work presents a study related the failures of broken rotor bars in three-phase induction motors driven by different frequency inverters. For the pre-processing of the current signals using the Discrete Wavelet Transform, where they are applied directly to the signs of the stator currents. For the diagnosis and the classification of the severity level of faults are used and compared two different techniques of machine learning: (i) Decision Trees and (ii) Random Forest.

Keywords: Intelligent systems. Three-phase induction motor. Rotor faults. Discrete Wavelet Transform. Decision Trees. Random Forest.

LISTA DE FIGURAS

Figura 1 – MIT de fabricação da WEG.....	14
Figura 2 – Rotor gaiola de esquilo.....	15
Figura 3 – Efeitos nas correntes do estator e do rotor devida à assimetria do rotor.....	16
Figura 4 – Espectro de frequência (a) motor sem defeito e (b) motor com 4 barras quebradas.....	17
Figura 5 – Decomposição por transformada <i>wavelet</i>	21
Figura 6 – Decomposição multinível por transformada <i>wavelet</i>	22
Figura 7 – Decomposição multinível por transformada <i>wavelet-packet</i>	23
Figura 8 – Exemplo de Árvore de Decisão.....	24
Figura 9 – Trabalho metodológico da <i>Random Forest</i>	26
Figura 10 – Bancada experimental do laboratório de Sistemas Inteligentes da UTFPR.....	28
Figura 11 – Rotor com quebra forçada das barras.....	29
Figura 12 – Precisão global de multiclassificação – Comparativo dos resultados deste Trabalho com os resultados do Godoy (2016) – Todos os inversores.....	40
Figura 13 – Precisão de multiclassificação – barras quebradas de rotor – Sinamics G110 x Micromaster MM440 x ATV12H075M2.....	41

LISTA DE TABELAS

Tabela 1 – Características do motor utilizado no trabalho.....	28
Tabela 2 – Características básicas dos inversores de frequência.....	30
Tabela 3 – Número de aquisição em cada estado do rotor.....	30
Tabela 4 – Faixa de variação de frequência em função da taxa de amostragem.....	31
Tabela 5 – Tabela para interpretação da estatística <i>Kappa</i>	33
Tabela 6 – Exemplo de uma matriz de confusão para um problema de duas classes.....	34
Tabela 7 – Resultados experimentais – Classificação de falhas de barras quebradas de rotor – Inversor Sinamics G110.....	35
Tabela 8 – Matriz de confusão – Multiclassificação de barras quebradas de rotor – Inversor Sinamics G110.....	36
Tabela 9 – Resultados experimentais – Classificação de falhas de barras quebradas de rotor – Inversor Micromaster MM440.....	36
Tabela 10 – Matriz de confusão – Multiclassificação de barras quebradas de rotor – Inversor Micromaster MM440.....	37
Tabela 11 – Resultados experimentais – Classificação de falhas de barras quebradas de rotor – Inversor ATV12H075M2.....	37
Tabela 12 – Matriz de confusão – Multiclassificação de barras quebradas de rotor – Inversor ATV12H075M2.....	38
Tabela 13 – Resultados experimentais – Classificação de falhas de barras quebradas de rotor – Todos os inversores.....	39
Tabela 14 – Matriz de confusão – Multiclassificação de barras quebradas de rotor – Todos os Inversores.....	39

SUMÁRIO

1	INTRODUÇÃO.....	11
1.1	OBJETIVOS.....	12
1.1.1	Objetivo geral.....	12
1.1.2	Objetivos específicos.....	13
1.2	JUSTIFICATIVA.....	13
2	REVISÃO BIBLIOGRÁFICA.....	14
2.1	MOTORES DE INDUÇÃO TRIFÁSICOS.....	14
2.1.1	Falhas de rotor.....	15
2.2	INVERSORES DE FREQUÊNCIA.....	18
2.3	SISTEMAS INTELIGENTES.....	19
2.3.1	Transformada <i>Wavelet</i> Discreta.....	20
2.3.2	Árvore de Decisão.....	23
2.3.3	<i>Random Forest</i>	25
3	METODOLOGIA	27
3.1	BANCADA EXPERIMENTAL.....	27
3.2	REPRODUÇÃO DE DEFEITOS DE ROTOR NO MOTOR.....	28
3.2.1	Banco de dados.....	31
3.3	PRÉ-PROCESSAMENTO DOS SINAIS.....	31
3.4	ESTRUTURAS DE CLASSIFICAÇÃO.....	32
4	RESULTADOS EXPERIMENTAIS.....	35
4.1	CLASSIFICAÇÃO DE BARRAS QUEBRADAS DE ROTOR.....	35
4.2	COMPARATIVO ENTRE OS INVERSORES – FALHAS DE BARRAS QUEBRADAS DE ROTOR.....	40
5	CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS.....	42
5.1	CONSIDERAÇÕES FINAIS.....	42
5.2	TRABALHOS FUTUROS.....	43
	REFERÊNCIAS	44

1 INTRODUÇÃO

Os motores de indução trifásicos (MIT) são amplamente utilizados em grande parte das aplicações industriais devido à sua construção simples, robustez, elevada confiabilidade, e mais recentemente devido à possibilidade de emprego de inversores de frequência, em que diferentes estratégias de controle podem ser aplicadas nestas máquinas (BELLINI et al., 2008). Estas chegam a representar 68% do consumo energético industrial no Brasil. O setor industrial consome 35% da energia elétrica total demandada no país (SAUER et al., 2015).

Por mais que estes motores sejam robustos, eles ainda continuam suscetíveis a falhas devido a sua constante utilização causando assim desgastes naturais em suas partes. Ainda existem ocasiões em que as cargas aplicadas e os ambientes de operação não são adequados para o seu melhor desempenho. Desta forma, pode-se acelerar o processo de deterioração da máquina e, por consequência, reduzir sua vida útil ou até mesmo vir a causar danos irreparáveis em seus componentes (TRIGEASSOU, 2013).

As falhas dos MIT podem ser classificadas entre elétricas ou mecânicas, as elétricas ocorrem no estator, rotor, anéis e conexões, já as mecânicas estão relacionadas aos rolamentos, excentricidade e desgaste de acoplamento. Os defeitos em rolamentos e estator representam juntos mais de 75% das falhas em motores de indução. As falhas de rotor totalizam 10% das paradas indesejadas do MIT e as demais, tais como excentricidade, desalinhamento, desgaste de acoplamento ou conexões elétricas correspondem a 12% do total de defeitos (VAIMANN; BELAHCEN; KALLASTE, 2015).

Entretanto, antes que ocorram as falhas mais significativas, dentro da máquina já começam a ocorrer defeitos, o que pode ocasionar uma diminuição em seu rendimento. Segundo Bellini et al. (2008) o diagnóstico correto de falhas e sua detecção na fase inicial permitem a realização de manutenções programadas de forma rápida, e redução do tempo de inatividade no processo em questão, o que auxilia também na redução de perdas financeiras. O mesmo autor ainda afirma que nas falhas de estator, por exemplo, quando ocorre assimetria nos enrolamentos, a máquina continua operando com o conjugado reduzido. No entanto, a falha de curto-circuito de estator pode evoluir em um curto espaço de tempo, causando um dano irreparável.

Com o avanço das tecnologias na área de eletrônica de potência, a participação do inversor de frequência em acionamentos industriais tem crescido com o passar dos anos, 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 sobretensão (FAIZ; GHORBANAIN; EBRAHIMI, 2012).

Este tipo de acionamento possibilita ainda outras vantagens como a regulação de velocidade, rápida resposta dinâmica além da possibilidade de incorporar o controle direto do torque (GODOY, 2016). Os acionamentos alimentados por inversores de frequência também podem influenciar de forma positiva na vida útil do motor, uma vez que a partida suave permite eliminar os altos esforços da partida nos enrolamentos estatóricos e nas barras do rotor, os quais são fortemente solicitados no caso de motores acionados diretamente pela rede elétrica (WEG, 2009).

Por este motivo é importante um monitoramento preditivo das condições de operação associado ao diagnóstico de falhas e assim prevenindo quebras indesejadas e alertando a ocorrência de possíveis danos futuros.

Neste trabalho será tratado o problema da identificação e diagnóstico de falhas de rotor em um MIT acionado por inversores de frequência.

Assim, os Sistemas Inteligentes (SI) tem sido utilizados na identificação e resolução de diversos problemas relacionados ao controle e acionamento de máquinas elétricas sendo capazes de classificar e determinar a origem de falhas ainda em sua fase prematura (MUTHUSELVAN; DASSH; SOMASUNDARAM, 2006; SAYOUTI et al., 2011). Dito isso, para se aumentar a confiabilidade e a disponibilidade das máquinas, é necessário uma intervenção planejada. Assim sendo, nesta pesquisa utilizaremos técnicas inteligentes como ferramenta para a identificação precoce de falhas.

1.1 OBJETIVOS

Os objetivos deste trabalho encontram-se divididos em objetivo geral e objetivos específicos, os mesmos estão expostos nas subseções apresentadas a seguir.

1.1.1 Objetivo geral

Este trabalho tem como objetivo geral aplicar um método de pré-processamento dos sinais de corrente no domínio da frequência visando aumentar a precisão da multiclassificação de falhas de barras quebradas de rotor de MIT acionado por inversores de frequência.

1.1.2 Objetivos específicos

- Selecionar as amostras necessárias do banco de dados;
- Fazer o pré-processamento dos sinais extraídos do banco de dados utilizando a Transformada *Wavelet* Discreta, ou, *Discrete Wavelet Transform* (DWT) para transformar os sinais que estão no domínio do tempo para o domínio da frequência decompondo-os e assim adquirir-se a faixa de frequência desejada, com o auxílio do software MATLAB®;
- Com os dados pré-processados criar vetores de entrada para os algoritmos classificadores;
- Com os classificadores *Árvore de Decisão* (AD) e *Random Forest* (RF), realizar o diagnóstico e multiclassificação da falha de barras quebradas de rotor, com o auxílio do software WEKA; e
- Analisar se os resultados obtidos com os sinais no domínio da frequência foram melhores que os resultados no domínio do tempo apresentados por Godoy (2016).

1.2 JUSTIFICATIVA

Recentemente foi demonstrado que, o setor industrial tem consumido cerca de um terço da matriz energética do Brasil, dos quais, cerca de dois terços estão relacionados a sistemas motrizes (EPE, 2016). Sendo assim, fica claro a importância dos MIT no setor industrial, desta forma também se torna importante o estudo de técnicas de manutenção que contribuem para o aumento da vida útil do motor e consequentemente possibilitando uma maior continuidade do processo produtivo e reduzindo das perdas econômicas, bom como métodos capazes de identificar e diagnosticar as possíveis falhas dos mesmos.

O uso de SI para identificação e classificação de falhas de MIT tem sido uma opção viável, (SANTOS, 2013), dentre as principais vantagens do uso de SI, destaca-se a simplicidade na sua implementação computacional, tornando possível o diagnóstico de falhas ainda em origem de evolução, dispensando o conhecimento do modelo do sistema.

2 REVISÃO BIBLIOGRÁFICA

Nesta seção do trabalho, apresenta-se uma revisão bibliográfica abordando os principais aspectos que compõem o desenvolvido do mesmo, como o método de processamento dos sinais, os classificadores inteligentes, entre outras coisas.

2.1 MOTORES DE INDUÇÃO TRIFÁSICOS

No motor de indução a corrente alternada é fornecida diretamente ao estator, ao passo que o rotor recebe por indução, como em um transformador, a partir do estator. Quando a excitação é feita por uma fonte polifásica equilibrada, um campo magnético é produzido no entreferro girando na velocidade síncrona. Essa velocidade é determinada pelo número de polos do estator e pela frequência aplicada ao estator (FITZGERALD; JR.; UMANS, 2006).

Figura 1 – MIT de fabricação da WEG



Fonte: Royal Máquinas (2017)


Quando se fala de rotor de indução, Chapman (2013) cita dois que podem ser acoplados no interior do estator: rotor bobinado e rotor gaiola de esquilo.

O mesmo autor descreve o primeiro da seguinte forma.

Um rotor bobinado tem um conjunto completo de enrolamentos trifásicos que são similares aos enrolamentos do estator. As três fases dos enrolamentos do rotor são usualmente ligadas em Y e suas três terminações são conectadas aos anéis deslizantes no eixo do rotor (CHAPMAN, 2013, p. 310).

Já em relação ao rotor gaiola de esquilo, continua o autor, “Esse rotor consiste em uma série de barras condutoras que estão encaixadas dentro de ranhuras na superfície do rotor e postas em curto-circuito em ambas as extremidades por grandes anéis de curto circuito”.

Figura 2 – Rotor gaiola de esquilo



Fonte: Adaptado de Quora (2017)

Santos (2013) complementa alegando que as falhas elétricas e mecânicas podem ocorrer como consequência dos constantes esforços térmicos, elétricos e mecânicos durante o funcionamento do motor.

2.1.1 Falhas de rotor

Uma falha pode ser definida como um desvio de uma propriedade característica de um processo, o que irá causar uma diminuição do seu desempenho. Esse desvio pode ser causado por mudanças físicas temporárias ou permanentes no sistema (BARAKAT et al., 2011).

As principais falhas de rotor são oriundas da quebra da barra ou por meio de rachaduras nos anéis terminais. Tais falhas têm como características: vibração excessiva, ruídos e faiscamentos durante a partida do MIT. Além disso, este tipo de falha não provoca uma parada imediata na máquina, podendo o dispositivo continuar a sua operação mesmo com a presença de barras quebradas ou trincadas. No entanto, deve-se analisar o estado e a gravidade do problema, pois a barra pode atingir o enrolamento do estator, causando o


rompimento do seu isolamento e, conseqüentemente, provocar um curto-circuito entre as espiras ou até mesmo entre as fases do estator (MERTENS, 2008).

A identificação de falhas pela técnica MCSA é baseada na decomposição espectral da corrente do estator, onde se pode encontrar a informação da falha, através do processamento do sinal pela Transformada Rápida de Fourier.

Alves (2017) afirma que a presença de barras quebradas ocasiona o surgimento de modulações na amplitude da corrente e, por conseqüência disso, ocorre a origem das componentes espectrais de bandas laterais, que ficam em torno da componente fundamental. A frequência de falha é constituída por essas frequências de bandas laterais, mostradas pela Equação 1, onde s e f são constantes referentes ao escorregamento e frequência de alimentação, respectivamente e k é um número inteiro.

$$f_{br} = (1 \pm 2ks)f \quad (1)$$

Figura 3 – Efeitos nas correntes do estator e do rotor devido à assimetria do rotor



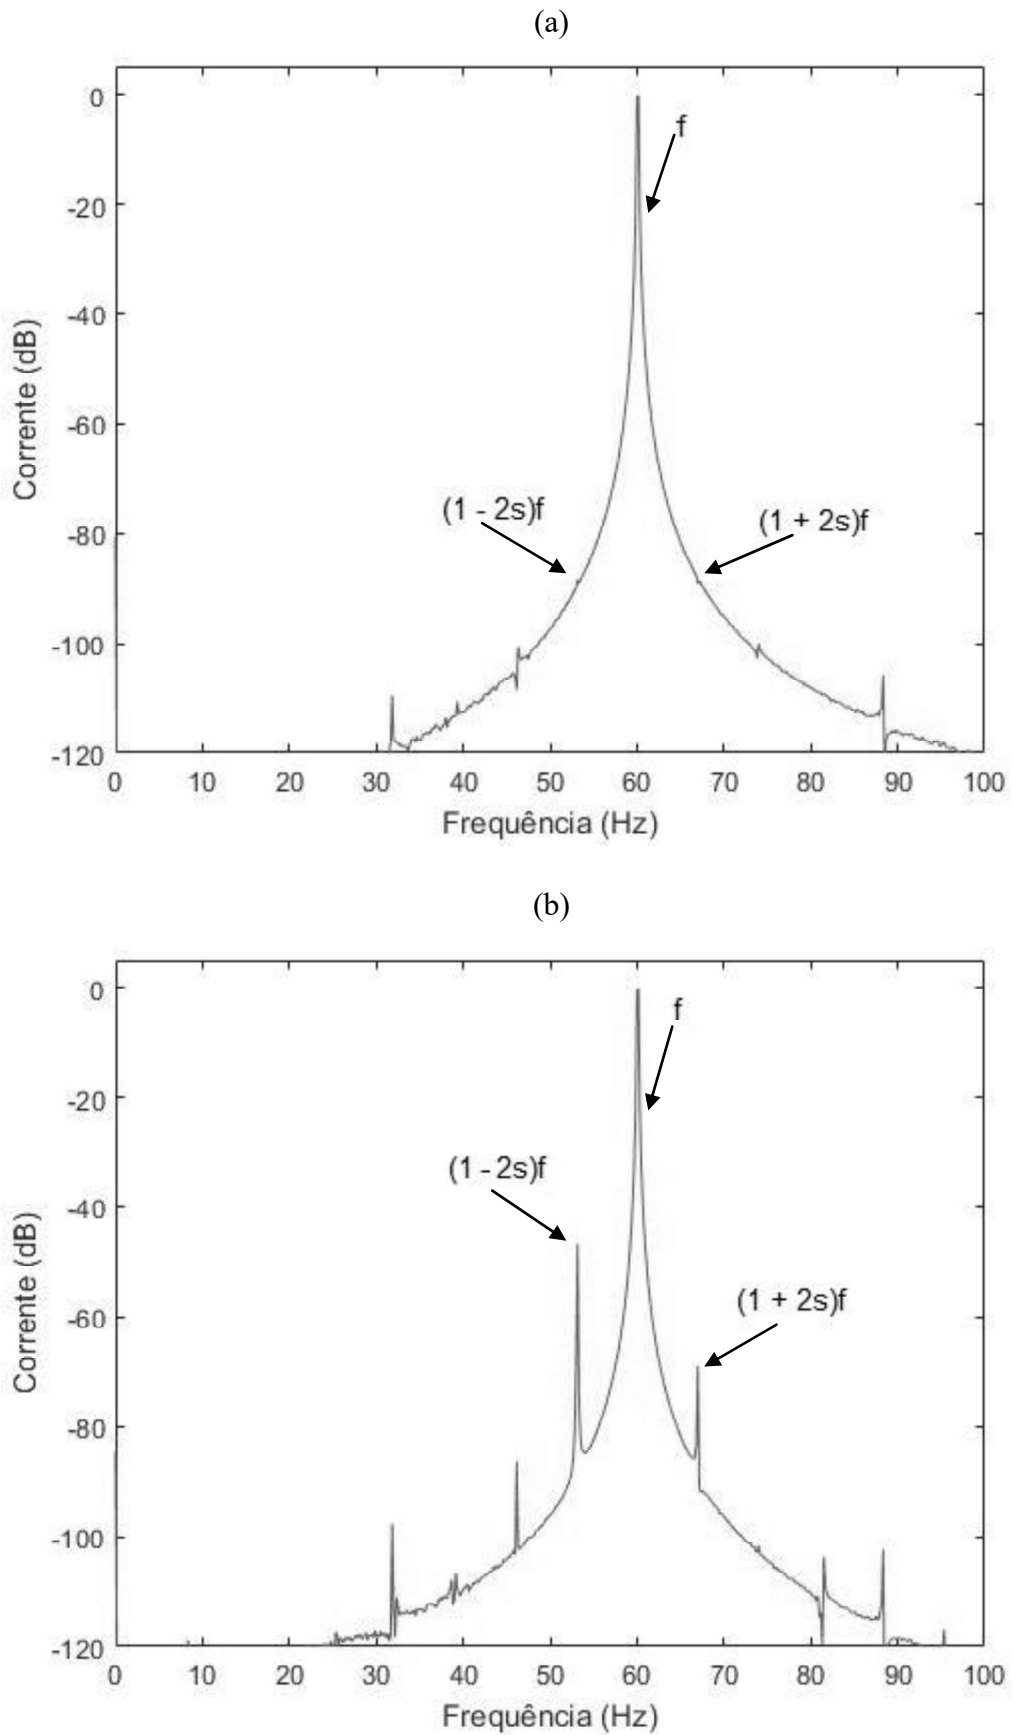
Fonte: Santos; Silva; Suetake (2012)

Observa-se que ocorre um surgimento de duas frequências de bandas laterais, onde a componente $(1 + 2ks)f$ é referente à oscilação da velocidade e a componente $(1 - 2ks)f$ é relacionado com a modulação causada pela barra quebrada do rotor, ou, por conseqüência da assimetria inerente à máquina, como imperfeições ocorridas na fabricação (ALVES, 2017).

Assim sendo, através do monitoramento da corrente do estator é possível identificar falhas por quebra de barras no rotor em MIT, ao se analisar as frequências de escorregamento em torno da frequência fundamental. Quanto maior a severidade da falha do rotor, maior a amplitude dessas frequências (SIDDIQUI; GIRI, 2012).

A Figura 4 apresenta o espectro de Fourier obtidos dos dados computacionais, gerados sob duas condições, sem defeito e com quatro barras quebradas.

Figura 4 - Espectro de frequência (a) motor sem defeito e (b) motor com 4 barras quebradas



Fonte: Autoria Própria

Além da severidade das falhas nos elementos do motor às variações de carga também podem influenciar nas frequências em torno da frequência fundamental. Os harmônicos referentes aos efeitos de variação de carga (f_{load}) são dados pela Equação 2 (BENBOUZID, 2000).

$$f_{load} = f_e \pm k_1 \cdot f_r \quad (2)$$

Segundo Benbouzid (2000), se o motor opera sob condições de cargas variáveis, a oscilação no torque resulta em características de harmônicos nos sinais de corrente que podem ser confundidas com as produzidas em situações de falha.

2.2 INVERSORES DE FREQUÊNCIA

Santos et al. (2012) em sua literatura afirma que os MIT podem ser acionados diretamente pela rede elétrica, cujos sinais são caracterizados como senoidais, ou por inversores de frequência, cujos sinais são não-senoidais. Os inversores de frequência PWM, são compostos pelo modo de controle *open-loop* ou *closed-loop*, são responsáveis em controlar a frequência da velocidade do rotor.

Vários dispositivos de controle *closed-loop* surgem como fontes controladoras de corrente e tensão. Nesta situação, a assinatura da falta estará presente tanto na corrente do motor quanto na tensão, o que aumenta a dificuldade em definir falhas num MIT (PIRES et al., 2009).

Os métodos convencionais para análise de sinais de MIT se tornam ineficientes para identificação de falhas em motores acionados por inversores. Isto se dá pelo fato do controlador de realimentação de corrente mascarar a assinatura da falta, ou como já dito anteriormente, pela mudança constante da carga e pela produção de componentes de frequências próximas à componente fundamental, os quais indicam a quebra de barra do rotor (BELLINI et al., 2008; KIM et al., 2011).

Porém, muitos trabalhos demonstram um aumento da presença de inversores nos sistemas de detecção e diagnóstico de falhas de motores, mesmo estes sendo responsáveis pelo fornecimento de variáveis elétricas para o sistema e até mesmo atuarem como mais um componente gerador de falhas. Diversas literaturas destacam o uso de inversores *closed-loop*

ou *open-loop*, aliados aos modelos matemáticos e às técnicas de processamento de sinais, a fim de identificar falhas no rotor, principalmente as quebras nas barras do rotor (AYHAN et al., 2008; NEMEC et al., 2010; KIM et al., 2011; WOLBANK et al., 2011).

Tendo dito como os métodos tradicionais escondem os problemas dos MIT acionados por inversores, torna-se necessário outros métodos para analisar e diagnosticar o estado dos dispositivos elétricos. O método adotado neste caso será os SI, que podem ser implementados em controladores ou em aplicações *offline* do sistema de diagnóstico.

2.3 SISTEMAS INTELIGENTES

A dificuldade em se detectar falhas nos rotores está justamente na classificação das linhas de frequência presentes nos sinais. Para minimizar este problema e obter uma ferramenta eficiente de detecção de falhas, os sistemas inteligentes têm sido também utilizados para mapear estes processos considerados complexos (SANTOS; SILVA; SUETAKE, 2012). Além disso, a análise do sinal de corrente elimina a necessidade de sensores de vibração e outros equipamentos.

Para se detectar as falhas em MIT pelo sinal de corrente pode se utilizar a transformada de Fourier, entre tanto, para uma melhor extração das características, utiliza-se também a transformada *wavelet* (LEE et al., 2004). Essas informações são utilizadas como entradas de uma rede neural para decisão sobre o tipo de falha.

Barakat et al. (2011) apresenta uma técnica baseada em redes neurais adaptativas e DWT para classificar falhas mecânicas em elementos girantes de um sistema de maquinário. Esta método proposto foi aplicado a um simulador de reator químico, composto por motor elétrico, correias, engrenagens e rolamentos. Essas medidas estatísticas extraídas dos sub-sinais após a decomposição foram utilizadas como entradas das redes neurais artificiais (RNA).

Silva (2014) em seu trabalho cita Ye, Wu e Zargari (2000) que apresentam um método para diagnóstico de falhas mecânicas em MIT (falhas nas barras do rotor), analisando sinais de corrente de estator, com base em redes neurais e nos coeficientes de Decomposição *Wavelet-Packet (DWP)*. Os componentes da decomposição analisados foram escolhidos de acordo com as frequências características das falhas de rotor. Dessa maneira, o nível de decomposição e o componente escolhido variam conforme o regime de torque e a velocidade

em que o motor esta operando. Os valores medidos dos coeficientes são comparados para motores operando com e sem a presença de falhas.

2.3.1 Transformada *Wavelet* Discreta

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). De forma geral essa função é descrita matematicamente pela Equação 3:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi \left[\frac{t-b}{a} \right] \quad (3)$$

Como a Transformada *Wavelet* Continua ou *Continuos Wavelet Transform* (CWT), contém problemas inerentes, o que dificulta sua implementação, por este motivo torna-se mais aplicável a DWT, que é definida matematicamente conforme a Equação 4 e é aplicável em sinais discretizados (FANUCCHI, 2014).

$$DWT(a, b) = \frac{1}{\sqrt{a_0^m}} \sum_{k=-\infty}^{\infty} f(k) \Psi \left(\frac{k - nb_0 a_0^m}{a_0^m} \right) dt \quad (4)$$

Os coeficientes a_0 e b_0 referem-se ao passo que indicam a escala e a translação da função *wavelet* mãe, respectivamente. Os indicadores m e n são relacionados à discretização da escala e translação da função “mãe” (FANUCCHI, 2014).

A DWT usa banco de filtros na análise multirresolução e foi desenvolvida por Mallat (1989). Os bancos de filtros divide o espectro do sinal em duas partes relacionadas, conhecidos como coeficientes de aproximação (c_n) e detalhe (d_n), que são, respectivamente, as componentes de baixa e alta frequência.

Um sinal é decomposto em vários níveis através da DWT (DINIZ; SILVA; NETTO, 2002). A decomposição consiste na convolução entre um dado sinal discreto $x[n]$, com n amostras e um par de filtros passa-alta ($g[n]$) e passa-baixa ($h[n]$). Os mesmos são relacionados com as funções *wavelet*-mãe (Ψ) e escala (ϕ), respectivamente, as funções são expressas nas Equações 5 e 6.

$$c_j[f(n)] = f[n] \phi(n) \quad (5)$$

$$d_j[f(n)] = f[n] \Psi(n) \quad (6)$$

Como o par de filtro $g[n]$ e $h[n]$ esta relacionado com as funções ϕ e Ψ , os mesmo são representados pelas seguintes Equações 7 e 8 (FANUCCHI, 2014):

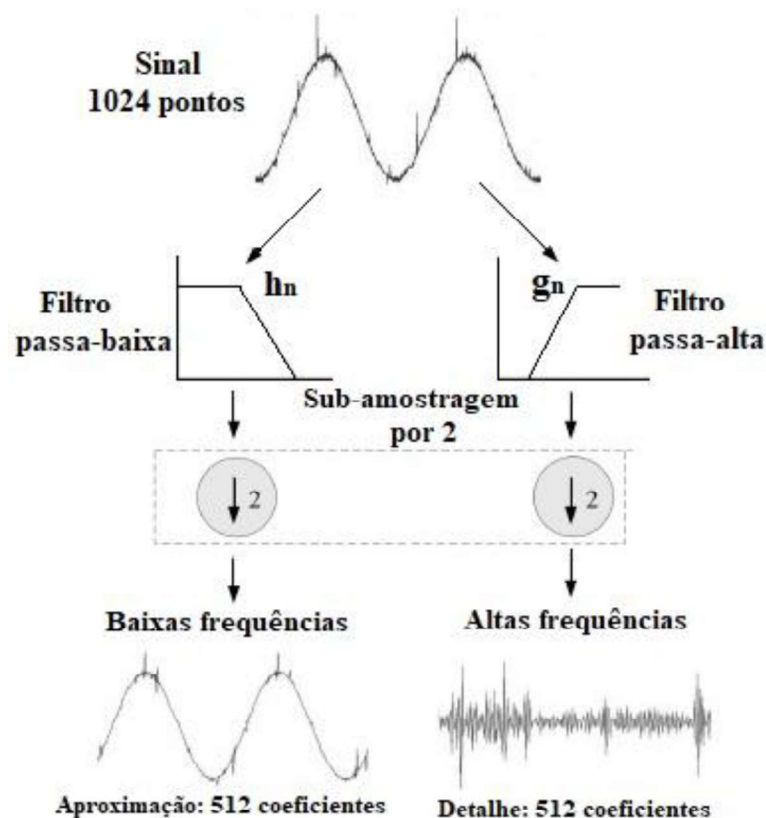
$$\phi[n] = \sum_j h[n] \phi[2n - j] \quad (7)$$

$$\Psi[n] = \sum_j g[n] \phi[2n - j] \quad (8)$$

Onde, j é o índice de somatória, que varia conforme o comprimento do filtro e n é o índice do sinal.

Após um sinal passar pelo par de filtro ele será subamostrado por um fator 2 a cada nível. Se considerarmos um sinal com 1024 pontos, pode-se obter os coeficientes de detalhe e aproximação, cada qual com 512 pontos, como pode ser observado na Figura 4.

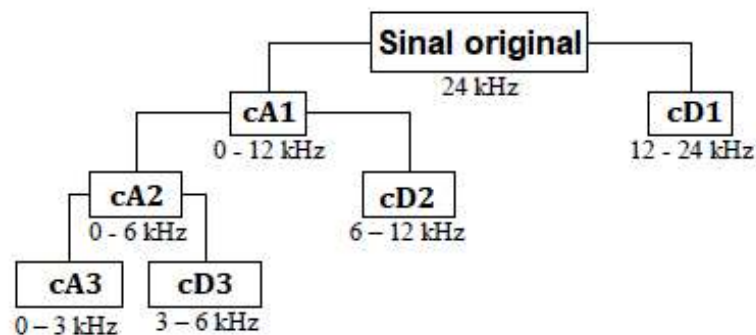
Figura 5 – Decomposição por transformada *wavelet*



Fonte: Adaptado de Mallat (1999)

Em análises multinível, os coeficientes de aproximação são decompostos sucessivamente, como é demonstrado na Figura 5. Essa decomposição deve ocorrer até que se obtenha a banda de frequência adequada para se fazer uma análise mais ideal possível do sinal, do contrario, caso o sinal não seja decomposto vezes suficientes ou ocorra mais que o necessário, pode acontecer distorções significativas no sinal, o que iria comprometer as análises futuras do mesmo.

Figura 6 – Decomposição multinível por transformada *wavelet*

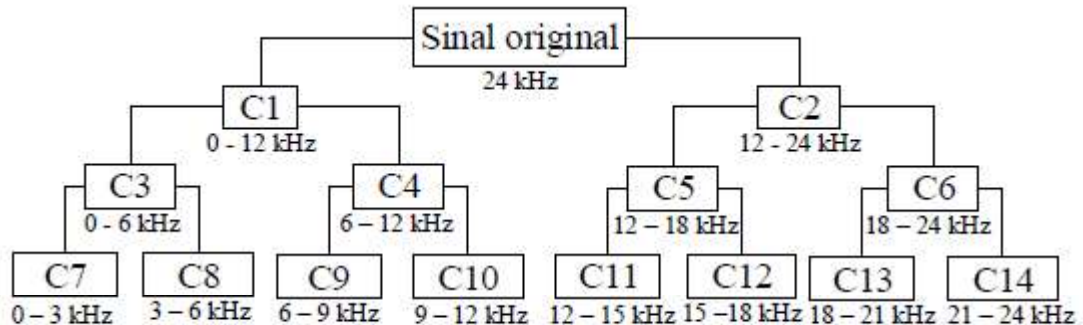


Fonte: Adaptado de Silva (2014)

Como se pode observar na Figura 5 o sinal original tem uma frequência igual a 24 kHz. Os coeficientes de aproximação e detalhe do primeiro nível de decomposição são representados pelos blocos cA1 e cD1. Esses coeficientes são referentes a bandas de frequência de 0 a 12 kHz e 12 a 24 kHz, respectivamente. No segundo nível é decomposto apenas o componente relacionado às baixas frequências que são referentes ao bloco cA1. Desta maneira é possível obtermos as faixas de frequência de 0 a 6 kHz e 6 a 12 kHz, que corresponde as componentes cA2 e cD2. Esse processo se repete nos níveis seguintes, até que se obtenha a faixa de frequência desejada.

A diferença entre a DWT e a DWP é que no segundo ambas as componentes de baixa e alta frequência são decompostos novamente em cada um dos próximos níveis (MALLAT, 1999) como é demonstrado na Figura 6.

Figura 7 – Decomposição multinível por transformada *wavelet-packet*



Fonte: Silva (2014)

2.3.2 Árvore de Decisão

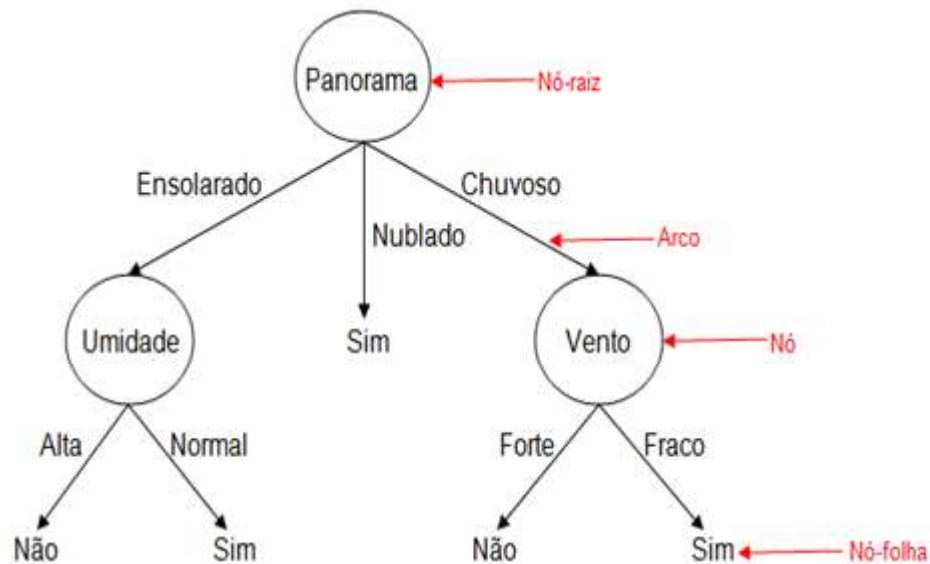
A árvore de decisão é um modelo de classificador cuja estrutura é construída de um determinado número de nós e arcos. Seu modelo é composto por uma estrutura no formato de uma árvore, sendo cada nó interno da árvore um determinado teste em uma característica de uma instância, e sendo os arcos, uma representação do resultado. Os nós-folha, isto é, os nós externos da árvore, representam as classes de classificação (FÜRNRANZ et al., 2012)

No trabalho do Bazan (2016) ele afirma que a classificação de uma determinada amostra se dá ao percorrer toda a árvore de decisão, de cima para baixo (“*Top-Down*”), ou seja, do seu nó-raiz, seguindo pelos arcos dos nós até alcançar um nó-folha, onde contém a nova classificação da instância. O autor ainda dá um exemplo demonstrado na Figura 4, onde o processo de classificação de uma árvore de decisão para o problema de haver ou não um jogo de Tênis dependendo do panorama do dia.

As principais variantes de AD incluem ID3, C4.5 e Árvore de Classificação e Regressão (*Classification And Regression Tree – CART*). A diferença entre essas variantes reside na maneira como eles escolhem o recurso para dividir em cada nó. O ID₃ escolhe o recurso que tem o ganho com mais entropia nas características restantes em cada nó. Na aplicação desta estratégia a árvore tende a escolher o recurso que tem mais atributos primeiro, que pode ser uma estratégia não muito sábia em muitas situações. Por conta disto surgiu o C_{4.5} que usa a relação de ganho de entropia para escolher a característica em cada nó. Já o CART tem uma estratégia diferente, ele seleciona os recursos que tem o menor erro quadrado (YAO et al., 2016).

Os mesmos autores continuam, afirmando que a AD tem dimensão infinita, ela pode comportar quaisquer dados. Em aplicações práticas, as AD tendem a ter excessos de ajustes devido ao ruído nos dados, ou seja, a árvore pode ter erro de trem muito pequeno, enquanto têm grande erro de teste, que não pode ser usado como um modelo qualificado para prever em aplicações reais. Por este motivo a poda é necessária para diminuir a complexidade da árvore. A poda é o processo para eliminar nós que tem baixo ganho de entropia. Em certa medida, a poda pode diminuir a taxa de excesso, porem não é aplicável em grandes conjuntos de dados.

Figura 8 – Exemplo de Árvore de Decisão



Fonte: Autoria própria

O método utilizado neste trabalho é o C4.5, pois ele trabalha de uma maneira onde ele divide o conjunto de dados de treinamento em alguns subconjuntos, de maneira recursiva, como critério de seleção, utiliza dados estatísticos, esse algoritmo também é conhecido como dividir-e-conquistar. Após a escolha da árvore de decisão mais geral é definido o nó-raiz, a partir do mesmo refina-se a árvore, até o surgimento dos nós-folhas, onde se encerra a construção da árvore.

Alguns critérios de seleção dos dados estatísticos para a escolha dos nós são necessários, como a entropia, o ganho de informação e a taxa de ganho de informação dos atributos de cada amostra presente no subconjunto de treinamento. A fim de minimizar a quantidade de informação necessária para classificar uma dada amostra e obter uma árvore

simplificada é fundamental que os três critérios sejam realizados na ordem em que foram apresentados. Essas medidas são definidas no trabalho do Bazan (2016).

Devido ao surgimento de muitas sub-árvores durante a construção da árvore, é necessário poda-las, pois elas causam um problema conhecido como *over-fitting*, que causa um aprendizado muito específico do conjunto de treinamento o que não permite uma generalização do modelo. Estas sub-árvores são substituídas por um nó folha, que recebe a atribuição mais comum das amostras de treinamento relacionado a ele (HAN; KAMBER; PEI, 2012). A técnica de poda utilizada por esse algoritmo é denominada poda "pessimista", conhecida também como "poda posterior".

2.3.3 *Random Forest*

Nos últimos anos, a RF que é uma variante da árvore de decisão provou ser uma ferramenta poderosa em grandes classificações de dados e tarefas de regressão. Por ela ser baseada igualmente na AD, ela é composta por múltiplas árvores, por isso o nome *Forest* ou Floresta. Esse método utiliza a estratégia CART para construir cada uma das árvores dessa floresta.


Segundo Costa (2006), para uma apropriada construção de uma árvore de decisão é necessário que o CART a princípio cresça a árvore de forma extensiva, com base na amostra dos dados adquiridos em sua entrada, que são os dados utilizados para o treinamento. Como resultado, se obtém uma sequência de árvores de tamanhos variados. Através de outra amostra de dados, que são os dados de teste, é possível selecionar uma árvore que melhor efetuou a classificação desses dados.

Conforme relatado na literatura (GODOY et al., 2017) no treinamento da árvore é utilizado a estratégia *bagging*, que reduz a variância e ajuda a evitar o *over-fitting*.

Para a RF classificar uma nova amostra de uma determinada entrada, cada árvore é alimentada com a mesma entrada na floresta que realiza a classificação. O classificador toma sua decisão com base na contagem de votos dos componentes preditores de cada classe e, a seguir, escolhe como classe vencedora aquela que acumulou mais votos (GODOY et al., 2017). A Figura 8 mostra o trabalho metodológico da RF.

Aumentando a semelhança entre as árvores aumenta-se a taxa de erro da floresta e vice-versa, uma árvore com uma taxa de erro menor torna-se um classificador forte. Diminuir o número de atributos reduz a correlação e a força, enquanto que o aumento do mesmo, aumentará ambos.

Figura 9 – Trabalho metodológico da *Random Forest*



Fonte: Jokhakar et al. (2016)

O conjunto de treinamento para cada árvore é tomada por amostragem de correia de reforço com substituição, cerca de um terço dos casos são deixados fora da amostra e não são usados na construção de uma árvore em particular. Estes dados excluídos são chamados de dados fora do saco (*out of bag data* – OOB). Eles são então utilizados para calcular uma estimativa neutra do erro à medida que as árvores crescem.

Depois que cada árvore é construída, todos os dados são executados para cada árvore, e as proximidades são computadas para cada par de casos. As amostras que foram separadas da árvore de ordem k são então executadas pela k -ésima árvore, a fim de obter uma classificação. Assim, cada caso do conjunto de teste obtém uma classificação. Cerca de um terço das árvores tem a possibilidade de serem utilizadas para avaliar a precisão do classificador (GODOY et al., 2017; SON et al., 2009).

Como estas árvores não são podadas, estas árvores crescidas se tornam bastante imparciais, mas são altamente variáveis, variações estas que são reduzidas através de ensacamento e randomização. A RF também pode fornecer medidas de importância variável, dependência parcial, proximidades, protótipos, etc (JOKHAKAR et al., 2016).

3 METODOLOGIA

Conforme mencionado no Capítulo 1, mesmo o MIT sendo uma máquina confiável e robusta, a mesma ainda esta suscetível a falhas por conta de desgastes naturais, por aplicações de cargas excessivas, operação em ambientes não adequados e entre outros fatores. Destas falhas as de rotor representam 10% das paradas indesejadas do MIT (VAIMANN; BELAHCEN; KALLASTE, 2015).

A fim de analisar o comportamento das falhas e seus efeitos, são realizados estudos em laboratório, onde é possível simular o ambiente industrial, com situações de falhas e diversas condições de operação, com o propósito de desenvolver métodos mais eficientes para diagnosticar as falhas em situações reais.


Assim sendo, este trabalho propõe um método para detecção de falhas de rotor por meio de sinais de corrente. A metodologia foi testada e validade utilizando um banco de dados composto por ensaios em laboratório, simulando várias condições de operação e falhas. Este banco de dados foi usado em Broniera (2014), Bazan (2016), Godoy (2016), Lopes (2016) e Palácios (2016).

3.1 BANCADA EXPERIMENTAL

A bancada utilizada para a simulação das falhas foi projetada por Goedtel (2007) para a inspeção de tensões, correntes, vibrações, torque e velocidade de um MIT. O condicionamento de sinal dos sensores *Hall* faz com que as tensões e correntes de fase sejam enviadas para as entradas analógicas da placa de aquisição de dados (PAD) em canais analógicos. Com uma interface de comunicação USB da PAD com o computador, as informações são recebidas e armazenadas com o auxílio do software MATLAB®.

A bancada presente na Figura 10 apresenta: (1) Variadores de Tensão, (2) Carga da Máquina CC, (3) Gerador de Corrente Contínua, (4) Torquímetro, (5) Sensor de Vibração, (6) Motor de Indução, (7) *Display* do Torquímetro, (8) Contator para Geração Automática de Curto-Circuito de Estator, (9) Placa de Aquisição, (10) Fonte CC, (11) Inversor Schneider ATV12H75M2, (12) Inversor Siemens Sinamics G110 e (13) Inversor Siemens Micromaster 440.

Figura 10 - Bancada experimental do laboratório de Sistemas Inteligentes da UTFPR



Fonte: Godoy (2016)

3.2 REPRODUÇÃO DE DEFEITOS DE ROTOR NO MOTOR

As informações utilizadas neste trabalho foram geradas por um motor operando em condições sem defeito e em condições de defeitos de barras quebradas de rotor. As características básicas do motor utilizado no presente trabalho estão presentes na Tabela 1.

Tabela 1 – Características do motor 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 polos	4
Número de ranhuras	36
Velocidade nominal (RPM)	1730
Torque nominal (N.m)	4,1
Número de barras de rotor	44

Como a quebra de barra é uma falha incipiente, seus efeitos sobre o MIT são quase imperceptíveis no início. Este fato tem motivado o monitoramento online das condições dos mesmos, ao longo dos anos, muitos métodos foram propostos pelas literaturas com o intuito de se obter um maior controle do estado do rotor, entre eles temos o que envolve a medição de vibração da máquina, potência instantânea, a frequência e a corrente do estator da máquina. Essas detecções de falhas ainda em estágios iniciais são importantes para o controle e proteção do motor (SRIDHAR; K.; JADE, 2015).

O rotor gaiola de esquilo dos MIT são compostos por um conjunto de barras que estão interligadas, formando uma bobina curto-circuitada, isso favorece a distribuição do fluxo magnético em toda a peça de forma homogênea (FITZGERALD; JR.; UMANS, 2006).

No banco de dados foram armazenadas variáveis elétricas e mecânicas tais como: torque, velocidade, tensões e correntes, porem para o desenvolvimento deste trabalho foi analisado apenas as correntes. Para a simulação em laboratório das falhas de barras quebradas, utilizou-se 5 diferentes rotores.

Para a reprodução deste defeito, um procedimento de cisalhamento das barras que compõem a gaiola do rotor foi utilizado, esse procedimento foi feito conforme a metodologia de Suetake (2012), e desenvolvida por Godoy (2016). Como resultado obteve-se um conjunto de rotores para os ensaios em bancada. As quebras foram feitas para 1, 2, 4 e 2/2 barras com disposição em sequência e também opostas na circunferência do rotor conforme a Figura 11.

Figura 11 - Rotor com quebra forçada das barras



Fonte: Godoy (2016)

Segundo Suetake (2012) as falhas apresentadas, normalmente são atribuídas ao excesso de vibração, desalinhamento ou excentricidade. Esse tipo de defeito pode ser

provocado por outros fatores como altas temperaturas que podem ser consequência de outros problemas, ou mesmo a fadiga do motor. Em adicional, a carga excessiva no eixo também pode gerar sua ruptura ou trinca (BACCARINI, 2005).

Algumas literaturas relatam que a dificuldade para se detectar defeitos nos rotores ocorre por conta da complexidade em classificar as frequências características nos sinais. Para auxiliar esse processo complexo, os sistemas inteligentes têm sido empregados para minimizar este problema e assim dispor de uma ferramenta mais eficiente na detecção de falhas (CHUA et al., 2010; NUSSBAUMER; STOJICIC; WOLBANK, 2011; CHEN et al., 2011).

Os sinais de correntes analisados advêm do estator do MIT alimentado por diferentes modelos de inversores de frequência, apresentados na Tabela 2, operando em regime permanente no domínio do tempo.

Tabela 2 – Características básicas dos inversores de frequência

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

A Tabela 3 apresenta as características gerais das condições adotadas para a criação do banco de dados utilizados neste trabalho, bem como a quantidade de dados adquiridos em cada situação.

Tabela 3 – Número de aquisição em cada estado do rotor

Condições	Número de amostras
Sem defeito	258
1 barra quebrada de rotor	260
2 barras quebradas de rotor	260
4 barras quebradas de rotor	259
2/2 barras quebradas de rotor	256
Número total de aquisição	1293

3.2.1 Banco de dados

Para os experimentos realizados com o filtro analógico, utilizou-se uma taxa de amostragem dinâmica, e assim manteve-se o mesmo número de pontos por ciclo da amostra em análise independente da frequência fundamental utilizada na alimentação do MIT.

As taxas de aquisição das amostras ajustadas na PAD variaram em função da frequência de alimentação, como demonstrado na Tabela 4, isso foi realizado com o intuito de otimizar o tamanho dos vetores de entrada nos experimentos realizados com filtro analógico.

Tabela 4 – Faixa de variação de frequência em função da taxa de amostragem

Grandezas	Faixa de variação									
Frequência (Hz)	12	18	24	30	36	42	48	54	60	
Taxa de amostragem (kamostras/s)	3	4,5	6	7,5	9	10,5	12	13,5	15	

Para os ensaios com barras quebradas de rotor, foram realizadas amostragens com intervalos de tempo de 6 segundos. O torque de carga 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. Como as medidas foram realizadas com o motor operando em regime permanente, o tempo de aquisição adotado é suficiente para representar os sinais a serem analisados sem sobrecarregar as amostras com vetores de tamanhos exorbitantes.

3.3 PRÉ-PROCESSAMENTO DOS SINAIS

Na tensão de alimentação dos MIT existe uma frequência fundamental que influencia diretamente a amplitude e o período dos sinais de corrente, essa perturbação ocorre por conta do acionamento por inversores de frequência e isso acaba por dificultar ainda mais o desenvolvimento de um sistema de diagnóstico e classificação de falhas no domínio do tempo que seja confiável (GODOY, 2016).

Como dito anteriormente, se torna inviável este tipo de análise, quando os dados se encontram no domínio do tempo, por isso a necessidade de se fazer um pré-processamento dos sinais e muda-los para o domínio da frequência antes que os mesmos possam ser submetidos aos classificadores.

Para se obter os dados em função da frequência, aplicou-se a DWT no sinal, utilizando as funções da família *Daubechies*. O presente trabalho considerou a vigésima

ordem das *wavelets Daubechies* (db20). O número de níveis N de decomposição da onda foi definido a partir da Equação 9 (SRIDHAR; K.; JADE, 2015).

$$N \geq \text{int} \left[\frac{\log\left(\frac{f_s}{f}\right)}{\log 2} \right] \quad (9)$$

Para um sinal de 60 Hz com uma frequência de amostragem de 90 kHz o número de níveis de decomposição de onda deve ser $N = 11$, tal como calculado conforme a última equação.

Após o sinal passar pela DWT e adquirir-se a faixa de frequência desejada, foram extraídos 1000 pontos para representar cada ensaio, o mesmo foi feito em cada um dos sinais de corrente (I_a, I_b, I_c). Como os sinais são resultantes das correntes de uma máquina trifásica, torna-se necessário a criação de um vetor coluna com os pontos de cada fase do sistema adquirido, seguidos um do outro, originando assim uma matriz com 3000 pontos de entrada.

3.4 ESTRUTURAS DE CLASSIFICAÇÃO

Para a correta classificação da severidade da falha do rotor, foram implementadas duas diferentes estratégias inteligentes de classificação, uma já mais usual e presente em várias literaturas para classificar este tipo de falha e outra menos utilizada (PENG; CHIANG, 2011; AYDIN; KARAKOSE; AKIN, 2014; PALÁCIOS, 2016).

O conjunto de dados é submetido à execução da ferramenta *Waikato Environment for Knowledge Analysis* – WEKA, a mesma é uma ferramenta de KDD – *Knowledge Discovery in Databases* que abrange vários algoritmos de preparação de dados, de aprendizagem de máquina (mineração) e de validação de resultados, o que permite treinar e testar variadas estratégias de classificação de forma interativa (HALL et al., 2009). Este sistema possibilita que os algoritmos apresentem relatórios com dados analíticos e estatísticos do domínio de operação.

Os algoritmos considerados neste trabalho, AD e RF, têm suas características e topologias descritas nos parágrafos abaixo, respectivamente e mantiveram-se fixos os mesmos parâmetros e especificações para todas as condições avaliadas.

Para treinamento e teste em todos os casos, os classificadores foram avaliados através do método de validação cruzada em k -partições, usando $k = 13$. Desta maneira, cada classificador foi treinado com $(k - 1)$ sub-conjuntos escolhidos aleatoriamente e em seguida são testados com o sub-conjunto restante. Lembrando que para cada cenário de teste todos os classificadores utilizaram a mesma base de dados.

As configurações do método AD - C4.5, empregadas neste trabalho, foram definidas de maneira a não utilizar as divisões binárias em atributos nominais para a construção das árvores. Foi definido valor 1 para o uso da semente para randomizar os dados. O fator confiança empregado para a poda ficou definido em 0,25. O número de instâncias por folha da árvore foi de 2 e a quantidade de dados utilizados para redução de erros de poda foi fixado com valor 3.

Para a RF as configurações utilizadas neste trabalho, definem a não utilização da quebra dos laços aleatórios, quando vários atributos parecem igualmente bons. Ficou estabelecido o uso da semente para randomizar os dados com valor 1. Foi determinada máxima profundidade com valor 0. O número de *slots* de execução recebeu valor 1 e foi atribuído valor 100 para o ensacamento das interações e aprendizado básico.

Para apuração dos resultados referentes aos testes executados por meio dos classificadores inteligentes, recorreu-se a matriz de confusão e aos índices estatísticos: *Kappa*, erro absoluto médio, erro absoluto relativo, tempo de construção do modelo, entre outros.

O coeficiente *Kappa* é uma informação que pode ser definido como uma medida de associação, que é utilizada para descrever ou testar o grau de concordância, ou confiabilidade e precisão, na classificação. A literatura determina diferentes faixas para os valores de *Kappa*, de acordo com o grau de concordância sugerido. Desta forma, valores superiores a 0,79 representam uma excelente concordância, quando valores menores que 0,40 mostram uma baixa concordância, de acordo com a Tabela 5 (LANDIS; KOCH et al., 1977).

Tabela 5 – Tabela para interpretação da estatística *Kappa*

Valores de Kappa	Concordância
< 0	Nenhuma
0 - 0,19	Pobre
0,20 - 0,39	Fraca
0,40 - 0,59	Moderada
0,60 - 0,79	Substancial
0,80 - 1,00	Perfeita

O erro absoluto estabelece a diferença entre um valor encontrado e o valor desejado. No caso de um grupo de amostras passadas ao classificador, considera-se a medida do erro absoluto médio para delinear o quão distante estão as amostras com erros de classificação. O erro absoluto relativo é estabelecido pelo quociente entre o erro absoluto e o módulo do valor exato.

A Matriz de confusão demonstra a qual classe cada exemplo pertence e também a qual classe ele foi classificado pelo classificador. Pode haver C matrizes de confusão, onde C é igual ao número de classes. Considerando a matriz confusão dada como exemplo na Tabela 6, de acordo com Basgalupp (2010) os conceitos de VP, FP, FN e VN são descritos como segue:

Verdadeiros Positivos (VP): são as amostras que pertencem à classe positiva e o classificador as classificou corretamente.

Falsos Positivos (FP): são as amostras que pertencem à classe negativa, entre tanto foram classificadas erroneamente como positivas pelo classificador.

Verdadeiros Negativos (VN): são as amostras que pertencem à classe negativa e que o classificador as classificou corretamente como negativas.

Falsos Negativos (FN): são as amostras que pertencem à classe positiva, no entanto foram classificadas incorretamente como negativas pelo classificador.

Tabela 6 - Exemplo de uma matriz de confusão para um problema de duas classes

Classe real	Classe predita	
	Positiva	Negativa
Positiva	VP	FN
Negativa	FP	VN

A partir dos valores da matriz de confusão é possível determinar facilmente os índices estatísticos comentados anteriormente.

Para todos os testes computacionais efetivados neste trabalho, foi utilizado um computador composto por um processador Intel® Core™ i5 4200U 1.60 GHz, memória RAM 6GB e HD de 1TB.

4 RESULTADOS EXPERIMENTAIS

Neste capítulo, são apresentados os principais resultados adquiridos utilizando os algoritmos de classificação AD e RF, treinados a partir das amostras retiradas dos sinais de correntes trifásicas de estator, obtidos por meio de ensaios experimentais utilizando diferentes modelos de inversores de frequência e um MIT, considerando que os sinais de corrente trifásicas de estator utilizados como entrada para os classificadores foram submetidos à filtragem analógica.

No contexto deste trabalho, a metodologia apresentada foi utilizada para identificar e classificar motor sem defeito, motor com defeito de barras quebradas de rotor, classificando a severidade da falha do rotor quando houver.

4.1 CLASSIFICAÇÃO DE BARRAS QUEBRADAS DE ROTOR

As Tabelas 7 e 8 apresentam os resultados de classificação do conjunto composto por 411 ensaios experimentais coletados com o MIT acionado pelo inverso Sinamics G110. Gera-se assim um conjunto de amostras de mesma quantidade utilizadas para o treinamento e validação dos classificadores.

Tabela 7 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor - Inversor Sinamics G110

Atributos	AD	RF
Instâncias corretamente classificadas (%)	78,10	78,83
Instâncias incorretamente classificadas (%)	21,90	21,17
Estatística <i>Kappa</i>	0,73	0,74
Erro absoluto médio	0,09	0,12
Erro quadrático	0,28	0,24
Erro absoluto relativo (%)	29,23	36,23
Erro quadrático relativo (%)	70,75	60,36
Tempo para criação do modelo (s)	0,78	0,99

A Tabela 7 permite observar que ambos os algoritmos apresentaram uma pequena diferença na precisão global, enquanto a AD teve 78,10% de acerto, a RF atingiu 78,83% de acerto. O índice *Kappa* dos dois indica que há uma substancial concordância com os resultados atingidos, confirmando assim a capacidade do método de diagnosticar a severidade

de barras quebradas de rotor a partir da simples utilização dos sinais de corrente de estator no domínio da frequência, quando o MIT é acionado com o inversor Sinamics G110.

Tabela 8 – Matriz de confusão - Multiclassificação de barras quebradas de rotor - Inversor Sinamics G110

Classificador	AD					RF				
	Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	76	5	1	0	0	75	5	1	1	0
1 B	5	75	0	3	0	3	77	0	3	0
2 B	1	0	67	11	4	1	1	63	16	2
4 B	2	2	13	55	11	1	2	11	44	14
2/2 B	0	1	3	28	48	0	0	7	19	54

Assim como os resultados globais demonstram um elevado índice de precisão, é possível observar na Tabela 8 que o algoritmo AD apresenta precisão igual a 92,7% para classificação de motor sem defeito, enquanto a RF obteve 91,5% de acerto para a mesma classe.

As Tabelas 9 e 10 demonstram os resultados de classificação do conjunto composto por 433 ensaios experimentais coletados com o MIT acionado pelo inverso Micromaster MM440. Obtém-se assim um conjunto de amostras de mesma quantidade utilizadas para o treinamento e validação dos classificadores.

Tabela 9 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor - Inversor Micromaster MM440

Atributos	AD	RF
Instâncias corretamente classificadas (%)	53,58	54,73
Instâncias incorretamente classificadas (%)	46,42	45,27
Estatística <i>Kappa</i>	0,42	0,43
Erro absoluto médio	0,19	0,20
Erro quadrático	0,38	0,33
Erro absoluto relativo (%)	60,80	63,93
Erro quadrático relativo (%)	96,01	83,36
Tempo para criação do modelo (s)	1,32	1,55

Para a multiclassificação de barras quebradas de rotor, é possível observar através da Tabela 9, que os algoritmos possuem precisão global inferior a 55% de defeitos. Para os dois algoritmos, a estatística *Kappa* indica concordância moderada, demonstrando assim a capacidade do método de diagnosticar a severidade de barras quebradas de rotor fundamentado

na simples utilização dos sinais de corrente de estator no domínio da frequência, quando o MIT é acionado com o inversor Micromaster MM440.

Tabela 10 – Matriz de confusão - Multiclassificação de barras quebradas de rotor - Inversor Micromaster MM440

Classificador	AD					RF				
	Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	46	32	1	5	2	50	28	1	5	2
1 B	10	74	2	1	0	11	75	0	1	0
2 B	3	2	25	36	21	4	0	29	32	22
4 B	4	1	19	40	23	3	0	34	35	15
2/2 B	2	0	22	15	47	1	0	22	15	48

Na Tabela 10 observa-se que o algoritmo RF atingiu precisão de 58,1%, 86,2%, 33,3%, 40,2% e 55,8% respectivamente para classificação de motor sem defeitos, falhas de 1, 2, 3 e 2/2 barras quebradas de rotor. Índices ligeiramente inferiores foram obtidos pelo algoritmo AD, o mesmo apresentou desempenho superior somente para o motor com 4 barras rompidas de rotor, atingindo nesta classe precisão igual a 46%.

As Tabelas 11 e 12 expõem os resultados de classificação do conjunto composto por 449 ensaios experimentais coletados com o MIT acionado pelo inverso ATV12H075M2. Dispõem-se assim de um conjunto de amostras de mesma quantidade utilizadas para o treinamento e validação dos classificadores.

Tabela 11 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor - Inversor ATV12H075M2

Atributos	AD	RF
Instâncias corretamente classificadas (%)	72,83	75,72
Instâncias incorretamente classificadas (%)	27,17	24,28
Estatística <i>Kappa</i>	0,66	0,7
Erro absoluto médio	0,11	0,12
Erro quadrático	0,26	0,25
Erro absoluto relativo (%)	33,57	37,36
Erro quadrático relativo (%)	66,19	63,44
Tempo para criação do modelo (s)	0,67	1,11

Observando a Tabela 11 é possível notar que o algoritmo RF apresenta melhor precisão global de classificação, atingindo 75,72% de precisão global, enquanto a AD obteve uma precisão ligeiramente menor, alcançando 72,83% de precisão global. Novamente, ambos

os classificadores obtiveram uma substancial concordância, mais uma vez evidenciando a capacidade do método de diagnosticar a severidade de barras quebradas de rotor com base na simples utilização dos sinais de corrente de estator no domínio da frequência, porém, desta vez com o MIT sendo acionado com o inversor ATV12H075M2.

Tabela 12 – Matriz de confusão - Multiclassificação de barras quebradas de rotor - Inversor ATV12H075M2

Classificador	AD					RF				
	Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	79	7	3	1	0	82	5	2	0	1
1 B	5	80	3	2	0	3	81	0	3	3
2 B	2	3	19	64	2	2	1	51	32	4
4 B	1	3	17	67	1	0	4	39	44	2
2/2 B	0	3	5	0	82	2	0	3	3	82

A matriz de confusão da Tabela 12, mostra que o algoritmo RF possui 91,1% de precisão, para diagnóstico de motor sem defeito, 90% para reconhecimento de motor com defeito de 1 barra de rotor e respectivamente 56,7%, 49,4% e 91,1% de precisão para diagnosticar as falhas de 2, 4 e 2/2 (diametralmente opostas) barras quebradas de rotor. Neste mesmo cenário, o algoritmo AD apresenta precisão de 87,8% para motor sem defeitos e 88,9%, 21,1%, 75,3% e 91,1% respectivamente, para 1, 2, 4 e 2/2 (diametralmente opostas) barras quebradas de rotor.

As Tabelas 13 e 14 expõem os resultados de classificação do conjunto composto por 1293 ensaios experimentais coletados com o MIT acionado pelos três inversores. Detêm-se assim um conjunto de amostras de mesma quantidade utilizadas para o treinamento e validação dos classificadores.

Tabela 13 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor - Todos os inversores

Atributos	AD	RF
Instâncias corretamente classificadas (%)	61,95	64,04
Instâncias incorretamente classificadas (%)	38,05	35,96
Estatística <i>Kappa</i>	0,52	0,55
Erro absoluto médio	0,16	0,18
Erro quadrático	0,36	0,3
Erro absoluto relativo (%)	49,63	55,09
Erro quadrático relativo (%)	88,9	75,27
Tempo para criação do modelo (s)	6,89	6,84

Neste cenário, observa-se a partir da Tabela 13 que os algoritmos AD e RF possuem precisão global de 61,95% e 64,04% respectivamente, na configuração de multiclassificação de defeitos de barras quebradas de rotor, enquanto a estatística *Kappa* indica uma concordância moderada para ambos os casos, confirmando a capacidade do método de diagnosticar a severidade de barras quebras de rotor baseado na simples utilização dos sinais de corrente de estator no domínio da frequência, entre tanto, desta vez com o MIT sendo acionado com os três inversores de frequência.

Tabela 14 – Matriz de confusão - Multiclassificação de barras quebradas de rotor - Todos os Inversores

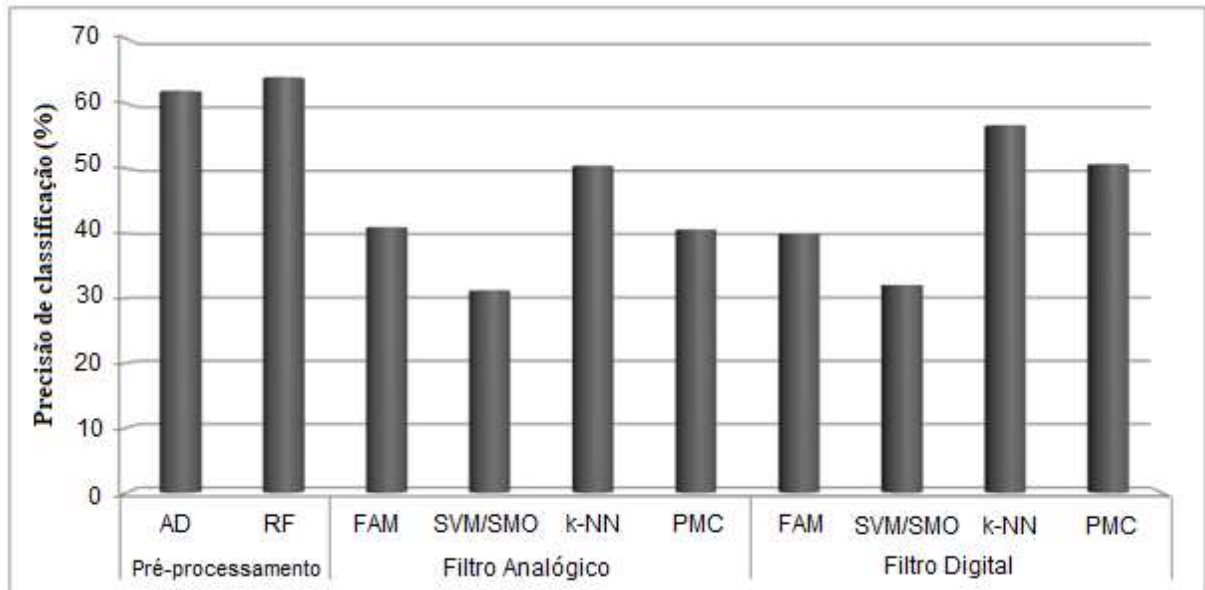
Classificador	AD					RF				
	Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	179	63	9	5	2	192	52	4	5	5
1 B	40	203	5	7	5	32	218	1	6	3
2 B	6	2	137	74	41	5	1	123	88	43
4 B	6	4	95	114	40	6	3	82	119	49
2/2 B	5	7	39	37	168	4	4	40	32	176

A matriz de confusão apresentada na Tabela 14 demonstra que o algoritmo RF atingiu precisão de 74,4%, 83,8%, 47,3%, 45,9% e 68,8% respectivamente para classificação de motor sem defeitos, falhas de 1, 2, 4 e 2/2 (diametralmente opostas) barras quebradas de rotor. Resultados levemente inferiores foram obtidos pelo algoritmo AD, que demonstrou desempenho superior para o motor operando com 2 barras quadradas de rotor, atingindo nesta classe precisão igual a 52,7%.

Para o caso em que o MIT foi acionado pelos três inversores de frequência, considerando classificação simples (motor com defeito / motor sem defeito) de barras quebradas de rotor a precisão global foi superior a 89% em ambos os classificadores. Quando considerado os inversores de frequência individualmente o melhor resultado ocorreu quando o motor foi acionado pelo inversor Sinamics G110 e alcançou precisão global de 97% pelo classificador RF.

Na Figura 12 é apresentado um gráfico comparativo entre os resultados obtidos pelo método desenvolvido neste trabalho e os resultados apresentados por Godoy (2016), os dados apresentados no gráfico são referentes a precisão global da multiclassificação das falhas de barras quebradas de rotor obtido por cada um dos classificadores. Os grupos de dados classificados em ambos os trabalhos são composto pelos sinais do MIT acionado por todos os inversores.

Figura 12 – Precisão global de multiclassificação - Comparativo dos resultados deste trabalho com os resultados do Godoy (2016) - Todos os inversores



Fonte: Autoria Própria

No gráfico acima é apresentado três diferentes métodos de tratamento de sinal, onde o primeiro é referente a este trabalho e os demais ao trabalho do Godoy (2016). A partir disso, é possível observar que a metodologia empregada neste trabalho obteve resultados superiores às outras.

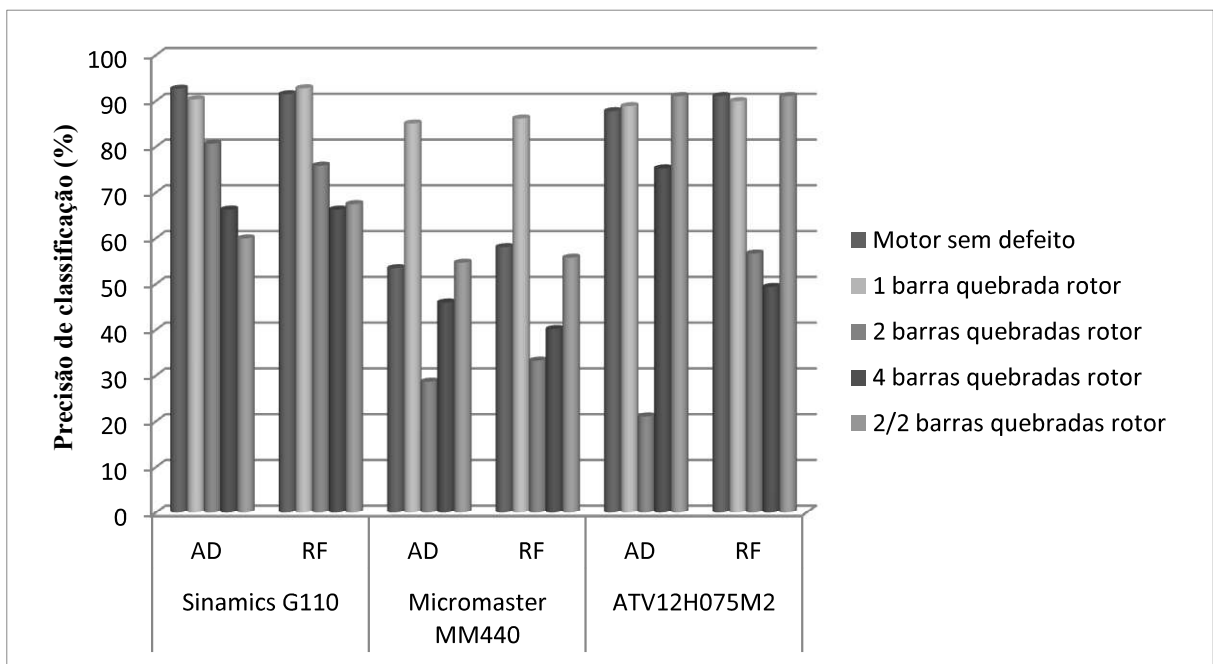
4.2 COMPARATIVO DOS RESULTADOS ENTRE OS INVERSORES – FALHAS DE BARRAS QUEBRADAS DE ROTOR

O gráfico apresentado na Figura 13 descreve os índices de precisão da multiclassificação por nível de severidade das falhas de barras quebradas de rotor obtidas com o MIT sendo acionado por três inversores de frequência distintos operando ao longo da faixa de 12 a 60 Hz, para cada um dos métodos avaliados.

Em uma análise comparativa com o auxílio da Figura 13, é possível observar que os melhores índices foram obtidos com o MIT sendo acionado pelo inversor Sinamics G110 da Siemens, seguido pelo inversor ATV12H075M2 da Schneider, com uma única exceção, o segundo demonstrou desempenho superior para o motor operando com 2/2 (diametralmente opostas) barras quebradas de rotor, atingindo nesta classe precisão de 91,1% em ambos os classificadores, enquanto o primeiro obteve precisão de 60% e 67,5% respectivamente para os classificadores AD e RF.

Por fim os dados do MIT sendo acionado com o inversor Micromaster MM440 também da Siemens, foram os que obtiveram o menor desempenho entre todos os três analisados, aqui também ocorreu uma ressalva, ele apresentou resultados ligeiramente melhores para o motor operando com 2 barras quebradas de rotor e atingiu 28,7% de precisão nesta classe, contra os 21,1% de precisão na mesma classe do inversor da Schneider, sendo que ambos os resultados foram obtidos pelo classificador AD.

Figura 13 – Precisão de multiclassificação - barras quebradas de rotor - Sinamics G110 x Micromaster MM440 x ATV12H075M2



Fonte: Autoria Própria

5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Neste capítulo serão apresentadas as conclusões e sugestões de trabalhos futuros.

5.1 CONSIDERAÇÕES FINAIS

Este trabalho apresenta o emprego de duas técnicas inteligentes com análise no domínio da frequência para o diagnóstico e multiclassificação de barras quebradas de rotor, que correspondem a 10% das falhas presente no MIT. Os dados experimentais foram coletados com o MIT acionado por três diferentes modelos de inversores de frequência ao longo de uma ampla faixa de frequência e variação de carga mecânica no eixo da máquina.

Um método de pré-processamento baseado na decomposição do sinal das correntes de estator através da Transformada *Wavelet* Discreta é utilizada para se obter os dados no domínio da frequência e assim formar os vetores de entrada dos algoritmos classificadores para diagnóstico e multiclassificação da falha analisada neste trabalho.

Quando se consegue uma correta classificação da falha aumenta-se a confiabilidade das máquinas o que gera uma redução de custos com manutenção. Sendo assim, a proposta deste trabalho apresenta um aperfeiçoamento de um sistema de multiclassificação de barras quebradas de rotor em motores de indução proposto por Godoy (2016) que utiliza dados coletados por sensores de corrente, que são comumente utilizados na indústria e que possibilitam diagnóstico de falhas tanto elétricas quanto mecânicas da máquina.

Falhas de barras quebradas de rotor de 1 a 4 barras quebradas foram diagnosticadas. Os resultados globais confirmam a viabilidade do método apresentado para multiclassificação de barras quebradas de rotor independente da velocidade de operação da máquina, das condições de carga ou mesmo do inversor utilizado. Embora o grupo de dados que teve o MIT sendo acionado pelo inversor Micromaster MM440 tenha tido uma precisão global inferior a 55%, pode-se dizer que os resultados são aceitáveis tendo em vista que a estatística *Kappa* indica uma concordância moderada.

Considerando o desempenho dos classificadores AD e RF para a multiclassificação da severidade de falhas de barras quebradas de rotor, para os casos em que o MIT foi acionado apenas por um único inversor, em geral, ambos são capazes de proporcionar diagnósticos rápidos e com precisão global acima de 72%, com exceção de quando utilizado o inversor Micromaster MM440.

Para os casos de classificação simples quando o MIT também foi acionado apenas por um único inversor de frequência, os melhores resultados foram obtidos a partir dos dados experimentais coletados utilizando os inversores Sinamics G110 e ATV12H075M2 que apresentaram precisão global superior a 95% para os dois classificadores utilizados e os resultados alcançados quando utilizado o inversor Micromaster MM440 foi de 82,68% e 86,37% respectivamente para os classificadores AD e RF. Neste mesmo cenário o trabalho do Godoy (2016) apresenta como melhor resultado os dados experimentais coletados utilizando o inversor Micromaster MM440, que obteve precisão global de 80,9%.

Por fim, na multiclassificação da severidade de falhas de barras quebradas de rotor, o conjunto composto por todos os inversores obteve uma precisão global superior a 61%, enquanto os resultados de precisão global obtidos por Godoy (2016) com este mesmo conjunto foram inferiores a 57%.

Neste estudo de diagnóstico e multiclassificação da severidade de falhas de barras quebradas de rotor de motor de indução alimentado por diferentes inversores de frequência, o método RF se saiu um pouco melhor que a AD, porém a diferença entre os índices de precisão global dos dois classificadores não excedeu os 3% em nenhum dos casos analisados.

Portanto os resultados comprovam a viabilidade do método proposto para a multiclassificação da severidade de falhas de barras quebradas de rotor, independente da velocidade de operação da máquina ou condições de carga, que não influenciam os resultados de diagnóstico. Além do mais, esta metodologia ainda é aplicável a MIT diretamente acionados pela rede elétrica.

5.2 TRABALHOS FUTUROS

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

- Utilizar a Transformada Wavelet-Packet, visando obter uma maior quantidade de sinais decompostos e bandas de frequência;
- Usar o cálculo da energia do sinal como entrada dos algoritmos classificadores para diagnóstico e multiclassificação de barras quebradas de rotor;
- Desenvolver métodos para o diagnóstico de falhas durante o regime transitório de máquinas acionadas por inversores de frequência.

REFERÊNCIAS

ALVES, D. A. **Técnicas de Detecção de Falhas em Barras do Rotor nos Motores de Indução Trifásicos**. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de São João del-Rei – Centro Federal de Educação Tecnológica de Minas Gerais, 2017.

AYDIN, I.; KARAKOSE, M.; AKIN, E. An approach for automated fault diagnosis based on a fuzzy decision tree and boundary analysis of a reconstructed phase space. **ISA Transaction**, 2014. v. 53, n. 2, p. 220 – 229, 2014. ISSN 0019-0578.

AYHAN, B.; TRUSSELL, H. J.; CHOW, M.-Y.; SONG, M.-H. On the use of a lower sampling rate for broken rotor bar detection with DTFT and ARbased spectrum methods. In: **IEEE Transactions on Industrial Electronics**. p. 1421–1434, 2008.

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

BARAKAT, M.; DRUAUX, F.; LEFEBVRE, D.; KHALIL, M.; MUSTAPHA, O. Self adaptive growing neural network classifier for faults detection and diagnosis. **Neurocomputing**, v. 74, n. 18, p. 3865–3876, 2011.

BASGALUPP, M. P. **LEGAL–Tree: Um Algoritmo Genético Multi–objeto Lexicográfico para Indução de Árvores de Decisão**. Tese (Doutorado) – Programa de Pós-Graduação em Ciências de Computação, Universidade de São Paulo – Instituto de Ciências Matemáticas e Computação de São Carlos, 2010.

BAZAN, G. H. **Medidas de Informação e Sistemas Inteligentes Aplicados no Diagnóstico de Curto-Circuito do Estator de Motores de Indução Trifásicos**. Tese (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, Cornélio Procópio, 2016.

BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G. A. Advances in diagnostic techniques for induction machines. In: **IEEE Transactions on Industrial Electronics**, 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. In: **IEEE Transactions on Industrial Electronics**, v. 47, n. 5, p. 984–993, 2000.

BRONIERA, P. **Diagnóstico de Curto-Circuito no Enrolamento de Estator em Máquinas de Indução Trifásicas Utilizando Redes Neurais Artificiais**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2014.

CHAPMAN, S. J. **Fundamentos de Máquinas Elétricas**. 5. ed. Porto Alegre, RS: AMGH, p. 309-310, 2013.

CHEN, C.; ZHANG, B.; VACHTSEVANOS, G.; ORCHARD, M. Machine condition prediction based on adaptive neuro fuzzy and high-order particle filtering. **IEEE Transactions on Industrial Electronics**, 2011. V. 58, n. 9, p. 4353 – 4364, 2011.

CHUA, T.; TAN, W. W.; WANG, Z. X.; CHANG, C. Hybrid time-frequency domain analysis for inverter-fed induction motor fault detection. In: **IEEE International Symposium on Industrial Electronics (ISIE)**. [S.l.: s.n.], p. 1633 – 1638, 2010.

COSTA, H. R. do N. **Aplicação de Técnicas de Inteligência Artificial em Processos de Fabricação de Vidro**. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia de Sistemas, Escola Politécnica da Universidade de São Paulo, São Paulo, 2006.

DINIZ, P. S. R.; SILVA, E. A. B. da; NETTO, S. L. **Digital Signal Processing: System Analysis and Design**. Cambridge: Cambridge University Press, 2002.

EPE., Balanço energético nacional 2016 - ano base 2015 - relatório final. **Empresa de Pesquisa Energética - Ministério de Minas e Energia**, p. 291, 2016.

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

FANUCCHI, R. Z. **A Detecção e a Localização de Falhas de Alta Impedância em Sistemas de Distribuição Utilizando Transformadas Wavelets e Redes Neurais Artificiais**. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo – Escola de Engenharia de São Carlos, 2014.

FITZGERALD, A. E.; JR., C. K.; UMANS, S. D. **Máquinas Elétricas: Com Introdução à Eletrônica de Potência**. 6. ed. Porto Alegre: Bookman, Companhia Editora, p. 295, 2006.

FÜRNKRANZ, J.; GAMBERGER, D.; LAVRAC, N. **Foundations of Rule Learning**. Heidelberg, GER: Springer-Verlag Berlin, 2012.

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.

GODOY, W. F.; LOPES, T. D.; GOEDEL, A.; PALÁCIOS, R. H. C. Aplicação do algoritmo random Forest como classificação de padrões de falhas em rolamentos de motores de indução. Em: **XIII Simpósio Brasileiro de Automação Inteligente**, p. 264-265, 2017. ISSN 2175-8905.

GOEDEL, A. **Estimador Neural de Velocidade para Motores de Indução Trifásicos**. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo – Escola de Engenharia de São Carlos, 2007.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: An update, *sigkdd explor.* 2009. v. 11, n. 1, p 10 – 18, 2009.

HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and Techniques**. San Francisco, CA, USA: Morgan Kaufmann, 2012.

JOKHAKAR, V. N.; PATEL S. V. A random forest based machine learning approach for mild steel defect diagnosis. In: **IEEE International Conference on Computational Intelligence and Computing Research (ICIC)**. 2016.

KIM, B.; LEE, K.; YANG, J.; LEE, S. B.; WIEDENBRUG, E. J.; SHAH, M. R. Automated detection of rotor faults for inverter-fed induction machines under standstill conditions. In: **IEEE Transactions on Industry Applications** p. 55–64, 2011.

LANDIS, J. R.; G., K. G. The measurement of observer agreement for categorical data. **International Biometric Society**, 1977. v. 33, n. 1, p. 159 – 174, 1977.

LEE, S. H.; KIM, S.; KIM, J. M.; LEE, M. H. Fourier and wavelet transformations for the fault detection of induction motor with stator current. In: **30th Annual Conference of IEEE Industrial Electronics Society (IECON'2004)**. Busan, South Korea: [s.n.], v. 1, p. 383–388, 2004.

LOPES, T. D. **Aplicação de Redes Perceptron Multicamadas na Detecção de Falhas em Motores Elétricos**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2016.

MALLAT, S. A theory for multiresolution signal decomposition: the wavelet representation. In: **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.

MERTENS, A. **Uma Abordagem Sobre Detecção de Barras Quebradas em Motores de Indução Trifásicos**. 214 p. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, PR, Brasil, 2008.

MUTHUSELVAN, N. B.; DASH, S.; SOMASUNDARAM, P. A high performance induction motor drive system using fuzzy logic controller. In: **IEEE Region 10 Conference (TENCON)**. [S.l.: s.n.], p 1–4, 2006.

NEMEC, M.; DROBNIC, K.; NEDELJKOVIC, D.; FISER, R.; AMBROZIC, V. Detection of broken bars in induction motor through the analysis of supply voltage modulation. In: **IEEE Transactions on Industrial Electronics**. p. 2879–2888, 2010.

NUSSBAUMER, P.; STOJICIC, G.; WOLBANK, T. Exploiting switching transients for broken rotor bar detection in inverter-fed induction machines at all operating conditions. In: **IEEE International Electric Machines Drives Conference (IEMDC)**. [S.l.: s.n.], p.418 – 423, 2011.

PALÁCIOS, R. H. C. **Aplicação de Técnicas Inteligentes com Análise no Domínio do Tempo para Reconhecimento de Defeitos em Motores de Indução Trifásicos**. Tese

(Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo – Escola de Engenharia de São Carlos, 2016.

PENG, H. W.; CHIANG, P. J. Control of mechatronics systems: Ball bearing fault diagnosis using machine learning techniques. In: **Control Conference (ASCC), 2011 8th Asian**. [S.l.: s.n.], p. 175 – 180, 2011.

PIRES, D. F.; PIRES, V. F.; MARTINS, J. F.; PIRES, A. J. Rotor cage fault diagnosis in three-phase induction motors based on a current and virtual flux approach. In: **Energy Conversion and Management**. p. 1026–1032, 2009.

QUORA. **Por que Não é Possível Conectar Resistência Externa no Motor de Indução de Gaiola de Esquilo?**. Disponível em: < <https://www.quora.com/Why-it-is-not-possible-to-connect-external-resistance-in-squirrel-cage-induction-motor>>. Acesso em: 10 de Maio de 2017.

ROYAL MÁQUINAS. **Motor Trifásico Blindado – 4,00 CV – 4 polos – 220/380V - WEG**. Disponível em: < https://www.royalmaquinas.com.br/motor-trifasico-blindado-4-00cv-4-polos-220-380v.html?gclid=CjwKEAajw9MrIBRCr2LPek5-h8U0SJAD3jfht8vjIFZmfsr7rgk_8AE-DZss2rfWplCWyYfGvcMJvgRoCUsbw_wcB>. Acesso em: 10 de Maio de 2017.

SANTOS, F. M. C. **Identificação de Falhas em Motores de Indução trifásicos Usando Sistemas Inteligentes**. 106 p. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, São Carlos, 2013.

SANTOS, F. M. C.; SILVA, I. N.; SUETAKE, M. Sobre a Aplicação de Sistemas Inteligentes para Diagnóstico de Falhas de Indução – Uma Visão Geral. Em: **Revista Controle & Automação** v.23, p. 553–569, 2012.

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

SAYOUTI, Y.; ABBOU, A.; AKHERRAZ, M.; MAHMOUDI, H. Sensor less low speed control with ann mras for direct torque controlled induction motor drive. In: **International Conference on Power Engineering, Energy and Electrical Drives (POWERENG)**. [S.l.: s.n.], p. 1–5, 2011.

SIDDIQUI, K. M.; GIRI, V. K. Broken rotor bar fault detection in induction motors using wavelet transform. In: **International Conference on Computing Electronics and Electrical Technologies (ICCEET'2012)**. [S.l.: s.n.], p. 1–6, 2012.

SILVA, L. R. B. **Classificação de Falhas em Máquinas Elétricas Usando Redes Neurais, Modelos Wavelet e Medidas de Informação**. Tese (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, 2014.

SON, J. D.; NIU, G.; YANG, B. S.; HWANG, D. H.; KANG D. S. Development of smart sensors system for machine fault diagnosis. In: **Expert Systems with Applications**, p. 11981 – 11991, 2009.

- SRIDHAR. S.; K. U. R.; JADE. S. Identification of broken rotor bar fault and degree of loading in induction motor using neuro-wavelets. In: **TENCON 2015 - 2015 IEEE Region 10 Conference**. [S.l.: s.n.], p. 2, 2015.
- SRIDHAR. S.; K. U.R.; JADE. S. Detection of broken rotor bar fault in induction motor at various load conditions using wavelet transforms. In: **2015 International Conference on Recent Developments in Control, Automation and Power Engineering (RDCAPE)**. [S.l.: s.n.], p. 77, 2015.
- 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.
- TRIGEASSOU, J. C. **Electrical Machines Diagnosis**. [S.l.]: John Wiley & Sons, 2013.
- VAIMANN, T.; BELAHCEN, A.; KALLASTE, A. Necessity for implementation of inverse problem theory in electric machine fault diagnosis. In: IEEE. **Diagnostics For Electrical Machines, Power Electronics and Drives (SDEMPED), 2015 IEEE 10th International Symposium on**. [S.l.], p. 380–385, 2015.
- WEG,. Guia de aplicações de inversores de frequência. **Guia do Usuário**, p. 1–192, 2009.
- WOLBANK, T. M.; NUSSBAUMER, P.; CHEN, H.; MACHEINER, P. E. Monitoring of rotor-bar defects in inverter-fed induction machines at zero load and speed. In: **IEEE Transactions on Industrial Electronics**. p. 1468–1478, 2011.
- YAO, Q.; WANG, J.; YANG, L.; SU, H.; ZHANG, G. A fault diagnosis method of engine rotor based on random forest. In: **IEEE International Conference on Health Management and Forecasting (ICPHM)**. 2016
- YE, Z.; WU, B.; ZARGARI, N. Online mechanical fault diagnosis of induction motor by wavelet artificial neural network using stator current. In: **26th Annual Conference of the IEEE Industrial Electronics Society (IECON'2000)**. Nagoya: [s.n.], v. 2, p. 1183–1188, 2000.