

## Harmônicos de Referência Observados por Sistemas Inteligentes na Identificação de Falhas Elétricas em Motores de Indução

Wylliam S. Gongora \* Ivan N. da Silva \*\*  
 Alessandro Goedtel \*\*\* Tiago H. dos Santos \*  
 Marcelo Favoretto Castoldi \*\*\* Gustavo Henrique Bazan \*\*\*\*

\* Instituto Federal do Paraná, Campus Assis Chateaubriand, Assis Chateaubriand - PR, (e-mail: wylliam.gongora@ifpr.edu.br; tiago.santos@ifpr.edu.br).

\*\* Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos - SP (e-mail: insilva@sc.usp.br)

\*\*\* Departamento de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, Cornélio Procópio - PR, (e-mail: agoedtel@utfpr.edu.br; marcastoldi@utfpr.edu.br)

\*\*\*\* Instituto Federal do Paraná, Campus Jacarezinho, PR, (e-mail: gustavo.bazan@ifpr.edu.br).

**Abstract:** This article presents a methodology for the classification of electric faults in induction motors through the treatment of search harmonic reference signals injected into the machine's power supply. The proposal is based on the observation by intelligent systems of the electric current signals of the motor, preprocessed by the FFT and with the analysis of the signature components of the machine. However, the supply voltage signals are multiplexed with harmonic reference signals inserted by the frequency converter module of the machine itself. In order to improve accuracy in fault classification and diagnose degradation status, as well as to attest to the functionality of the method, the practical data of the actual application of the system in the laboratory are processed by different intelligent systems. In this aspect of generalization of the proposal the results are validated by different algorithms whose performances are compared between the following methods: k-nearest neighbors, Naive Bayes, Support Vector Machine, Multilayer Perceptron and Decision tree.

**Resumo:** Este artigo apresenta uma metodologia para a classificação de falhas elétricas em motores de indução através do tratamento de sinais harmônicos de referência de busca injetados pela fonte de alimentação da máquina. A proposta baseia-se na observação por sistemas inteligentes dos sinais de corrente elétrica do motor, pré-processados pela FFT e com a análise das componentes de assinatura da máquina. Para tanto, os sinais de tensão de alimentação são multiplexados com sinais de referência harmônica inseridos pelo próprio módulo inversor de frequência da máquina. Buscando melhorar a precisão na classificação de falhas e diagnosticar o estado de degradação, bem como atestar a funcionalidade do método, dados práticos da aplicação real do sistema em laboratório são processados por sistemas inteligentes distintos. Neste aspecto de generalização da proposta os resultados são validados por diferentes algoritmos cujos desempenhos são comparados entre os seguintes métodos: *k*-vizinhos mais próximos, *Naive Bayes*, Máquina de Vetor de Suporte, Perceptron multicamadas e Árvore de Decisão.

**Keywords:** Fault Identification; Classification of failures; Induction Machines; Intelligent Systems; Reference Signal Injection.

**Palavras-chaves:** Identificação de Falhas; Classificação de falhas; Máquinas de Indução; Sistemas Inteligentes; Injeção de Sinais de Referência.

## 1. INTRODUÇÃO

A hegemonia dos Motores de Indução (MI) na indústria como a principal fonte de transformação de energia elétrica em mecânica motriz é incontestável por diversos fatores, entre eles robustez e baixo custo, como apresentado por Jesus Romero-Troncoso (2017). Adjacentes a crescente aplicação das técnicas avançadas de controle e o uso de inversores de frequência encontram-se como resultado o seu uso em inúmeras aplicações industriais, de acordo com Martin-Diaz et al. (2017). Preceitos apontados por Bellini et al. (2008) e Irfan et al. (2017), apontam que esta alta performance exigida e a necessidade da garantida funcionalidade fazem com que a maquinaria em geral necessite de modelos atualizados e técnicas precisas de diagnóstico de falhas. Não diferentes, os motores de indução estão sujeitos a falhas elétricas e mecânicas e estas por suas vezes providas de variadas origens como exemplificado na Figura 1, baseada nos trabalhos de Irfan et al. (2015, 2017).

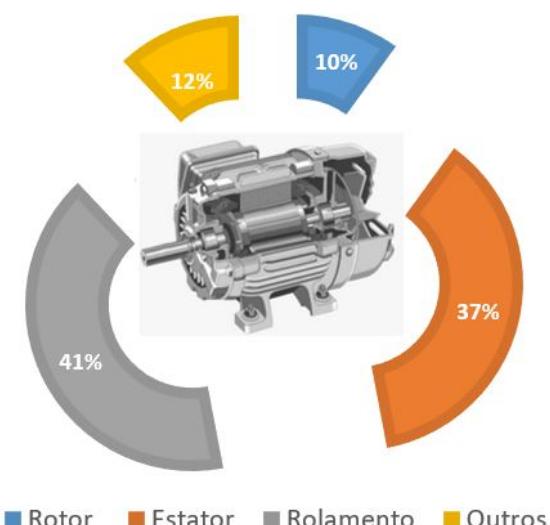


Figura 1. percentual de falhas em MI por origem

Várias técnicas têm sido pesquisadas e demonstradas para a identificação e classificação de anomalias de operação de forma preditiva, como demonstrado nos trabalhos de Mabrouk and Zouzou (2015); Li et al. (2016), e Liu et al. (2018). A escolha da técnica a ser empregada considera a dinâmica do processo, a operação do equipamento, o tipo de acionamento ou controle e os critérios adicionais diretamente relacionados às respostas dos métodos, Lakehal and Ramdane (2017).

Desta forma, uma ferramenta com capacidade de resposta diagnóstica de falhas de acordo com seu componente de origem, como mostrado na 1, classificando as falhas elétricas de estator que correspondem a 37% e de rotor com 10%, corresponde a uma ferramenta multi-classificadora de falhas elétricas abrangendo 47% dos problemas de MI.

A diversidade de métodos diagnósticos pode ser vista em Thomson and Fenger (2001) com as ferramentas de processamento de sinais como a Transformada Rápida de Fourier (FFT) aplicada em sinais de corrente elétrica, índices de vibração e ruídos acústicos. Considerando a empregabilidade maior da Análise dos Sinais das Correntes do estator do Motor (MCSA), as mudanças de padrões

de amplitude no espectro do sinal ou nos componentes espectrais da FFT permitem caracterizar e acompanhar a evolução das falhas específicas desde o seu início até inoperância da máquina, Li et al. (2016); de Jesus Romero-Troncoso (2017); Mata-Castrejón et al. (2015).

Pontos adicionais das particularidades da aplicação do motor são tratados como dificuldades extras e intensificam a complexidade desta metodologia, uma vez que há necessidade de estar definida a velocidade de operação da máquina e estabelecida a frequência específica a se observar, além de necessidade de um processamento de alta resolução dos sinais para um diagnóstico mais preciso, como são afirmados em Saddam et al. (2017) e Martin-Diaz et al. (2017). Ainda, em Bellini et al. (2008) fica evidenciado que este método funciona corretamente quando o MI está em estágio avançado de deterioração.

Dentre outras complexidades atribuídas ao diagnóstico correto por este método existe também a interferência ou alteração das características dos sinais por: variação dos níveis de carga no eixo da máquina, Mabrouk and Zouzou (2015); alternância de velocidade de operação, Martin-Diaz et al. (2017); relação Sinal-Ruído, Singh et al. (2015); indução de componentes de frequência próximos ao componente fundamental com sobreposição de sinais característicos, Naha et al. (2016) e a modulação e distorção dos sinais de alimentação pelos inversores de frequência atuando no controle da máquina, Rajeswaran et al. (2018).

Buscando alternativas as complexidades já citadas diversas ferramentas utilizam-se de Sistemas Inteligentes (SI) como o agente classificador de padrões, como é tratado por Liu et al. (2018) onde os seguintes algoritmos são mencionados: k-NN, NB, SVM, ANN e DeepLearning. Essa referência também mostra uma revisão bibliográfica dos algoritmos de Inteligência Artificial com aplicações industriais, relatando vantagens, limitações e implicações práticas de suas implementações.

Tendo por enfoque contornar essas limitações este trabalho apresenta uma estratégia para identificação e classificação de falhas em MI baseada no processamento de dados com análise espectral dos sinais de corrente da máquina, provados de uma fonte de alimentação do sinal fundamental multiplexado a uma série de Sinais Harmônicos de Referência de Busca (SHRB).

Este estudo propõe então o uso da injeção de SHRS com ferramenta no desenvolvimento de um sistema para detecção de falhas elétricas (rotor e estator), monitorando as grandezas elétricas aplicadas a um MI. Uma técnica multiplataforma que promove uma série de dados que possam ser interpretados por vários SI para diagnosticar as correntes amostradas no domínio da frequência.

Trabalhos correlatos como os de Cusido et al. (2006b) e Cusido et al. (2006a), propõem a injeção de um único sinal de tensão adicional em uma única frequência distinta à fundamental de alimentação do MI através de uma conexão paralela de outro inversor de frequência modulador da alimentação da máquina. Além disso, as referências mencionadas utilizam análise e comparação das amplitudes dos sinais por meio da observação direta da resposta em frequência e não por SI.

A metodologia proposta neste trabalho coleta os sinais das correntes do estator e observa, através de um sistema inteligente, as FFTs dos sinais da máquina operando em regime permanente. Sendo o sinal de tensão de alimentação multiplexado com uma série de SHRB pelo mesmo módulo inversor de frequência, independente da velocidade de operação do motor e da carga mecânica aplicada à máquina.

Resultados práticos dos sinais obtidos em laboratório são apresentados a cinco classificadores de padrões inteligentes, a saber: k-NN, NB, SVM, MLP e C4.5.

Este artigo está organizado da seguinte forma: A Seção 2 apresenta a metodologia proposta para injeção do SHRB. A seção 3 descreve sumariamente as características distintas e padrões das falhas abordadas, bem como os sistemas inteligentes e a ferramenta computacional utilizada para sintonia e teste dos mesmos. Na Seção 4 os resultados experimentais de laboratório são apresentados e discutidos. Finalizando, as conclusões deste estudo aparecem na Seção 5.

## 2. METODOLOGIA PARA INJEÇÃO DE SINAL DE REFERÊNCIA E PRÉ-PROCESSAMENTO DE DADOS

A proposta base da pesquisa e aumentar a capacidade de interpretação dos sinais de alimentação do MI a fim de identificar, por meio de classificadores inteligentes, falhas elétricas incipientes nas máquinas. Isto com a inserção de uma série de SHRB ao sinal de alimentação do motor, modulado pelo próprio inversor de frequência do motor em análise. Neste aspecto, para que os sinais não sofram interferência da ação de controle em malha fechada, optou-se por trabalhar com controle escalar do tipo V/F constante através de sinais de modulação por largura de pulso (PWM).

Muitos métodos podem ser aplicados para os propósitos deste controle, mas esta estratégia, em modo de malha aberta, estabelece uma relação constante entre tensão e frequência de alimentação do MI para garantir o fluxo magnético máximo no entreferro. Mais especificamente o algoritmo de modulação usado neste trabalho é baseado no proposto por van der Broeck et al. (1988), que utiliza a modulação por largura de pulso vetorial (SVPWM).

Assim, em uma primeira etapa, a tensão de alimentação da máquina é multiplexada com os SHRB nas frequências de referências proporcionais a velocidade de operação desejada do MI. A Figura 2 mostra o esquemático utilizado para essa injeção.

O sinal de alimentação fundamental é determinado pela frequência de funcionamento ao qual opera a máquina. Então, em sequência, são multiplexados um a um os SHRB proporcionais a esta frequência de funcionamento. A modulação ocorre no eixo de coordenadas  $\alpha$   $\beta$ , sendo assim aplicada por igual às três fases da alimentação. As harmônicas de ordem inteira são injetadas uma de cada vez para que não sejam tratadas ou geradas sub-harmônicas na rede com o aumento da complexidade de entendimento e manipulação por processamento digital.

O intervalo de alcance do SHRB, de acordo com a velocidade de operação do motor é composto de harmônicos

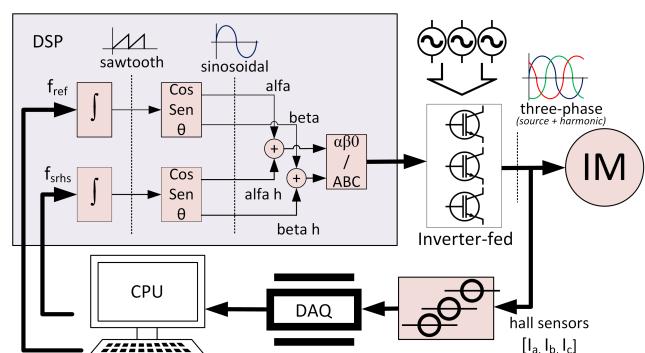


Figura 2. Estratégia de inserção de SHRB

de ordem inteira e ímpares, variando nas onze primeiras frequências harmônicas de injeção. Assim sendo, como sugerido por Likitjarernkul et al. (2017), do terceiro ao vigésimo primeiro harmônico ( $3^\circ$  ao  $21^\circ$ ), onde o limite inferior do intervalo é próximo da banda de frequências conhecida para as falhas e o limite superior acima da região de baixa inferência de outros harmônicos, como sua própria frequência de comutação.

Os dados utilizados nesta abordagem são oriundos de falhas elétricas recriadas no laboratório, fornecidas pelas metodologias que inserem essas falhas de maneira controlada. A bancada de teste é mostrada na Figura 3 onde um hardware dedicado em um kit DSP de Texas Instruments® modelo TMS320 C2000TM e processador F28335 Delfino™ com um software embarcado é usado para a modulação aplicada pelo inversor de frequência trifásico, modelo PS-3 Semikron SKS 80F, com potência nominal de 22kW.

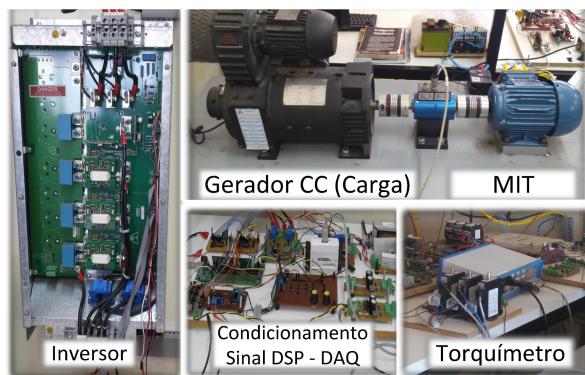


Figura 3. Bancada de Ensaios Laboratoriais

Esta bancada de testes, usada e descrita em maiores detalhes nas pesquisas referentes aos trabalhos de Godoy et al. (2016) e Bazan et al. (2017), monitora os sinais de tensão, corrente, vibração, torque e velocidade de um motor de indução trifásico conectado por acoplamento mecânico a um gerador CC, que impõe torque sobre o eixo do MI. A aquisição dos sinais é feita por uma placa de aquisição modelo DAQ da National Instruments®NI USB-6221. A taxa de aquisição estabelecida em 30.000 pontos por segundo, com tempo de aquisição definido em 2 segundos com o motor operando em regime e não havendo transitórios de carga ou de velocidade durante a aquisição.

Com este aparato, além da inclusão de defeitos controlados nos MI, é possível emular as condições de funcionamento dos motores com variação de conjugado de carga dentro da faixa de 0,5Nm (torque mínimo da bancada, sem carga adicional) até condições de excedente de torque. Porém, nesta abordagem para o motor de 1 cv, 100% de torque com 4Nm (carga nominal).

Ainda, além das condições de variação de carga, temos as variações das condições de operação de velocidade com ajuste do inversor modulando o sinal de alimentação trifásica na frequência de 20Hz (baixa velocidade) a 60Hz (velocidade nominal).

As frequências harmônicas de referência de busca foram estabelecidas com amplitudes reduzidas de 10% do valor da tensão de pico e em um intervalo curto de tempo, estabelecido heuristicamente em 160 milissegundos. Esse intervalo de tempo é condizente com um número de ciclos da senoide modulada completo que permite a realização da análise por FFT. Outrossim, este intervalo reduzido tem por objetivo apenas observar a resposta da dinâmica elétrica da máquina sem afetar a dinâmica mecânica.

### 2.1 Estruturação da Matriz de Dados

Toda a abordagem foi implementada em um modelo de classificação *off-line*. Os dados são tratados e classificados externamente em relação às frequências injetadas ou ao controle do MI. Este procedimento divide-se em três fases distintas e subsequentes como mostrado na Figura 4.



Figura 4. Etapas do processamento dos sinais

Uma vez que a primeira etapa, descrita anteriormente, esteja realizada, as informações usadas pelo SI provenientes de sinais senoidais das correntes elétricas dos motores no domínio do tempo são lidas, gravados, transformados em espectros de frequência por FTT e estruturados em sequência de modo que possam ser utilizados por qualquer

algoritmo de SI. Esses procedimentos para importar e processar os dados padronizam a implementação da análise que constituem a segunda etapa da proposta, e são realizados usando o software MatLab®.

A estruturação da matriz de dados é realizada pela composição de vetores amostrais, onde a FFT dos sinais de frequência fundamental mais a injeção de um sinal harmônico são alocados em sequência uma das outras. Sendo assim, o tipo de falha, grau de deterioração (severidade) das falhas e condição de operação (velocidade e conjugado de carga), constituem em uma sequência de frequências injetadas que geram esse vetor.

Como característica de padronização, cada FFT de um sinal senoidal acrescido do SHRB dá origem a um subvetor de 1.300 pontos onde cada ponto é a amplitude em uma frequência no espectro determinado de 1 Hz a 1.300 Hz. Os sub-vetores de uma mesma condição de operação do MI (n referências harmônicas de busca) são organizados em sequência, criando assim um único vetor amostral de 14.300 pontos, ou seja, com as 11 frequências harmônicas injetadas nesta abordagem.

Finalizado o processamento de dados os sinais são apresentados ao classificador inteligente independente que será capaz de diagnosticar a falha classificando sua origem e estado de degradação.

### 3. CLASSIFICADORES INTELIGENTES DE PADRÕES DE FALHAS

A presença de falha nos MI produz mudança na interação do fluxo entre o estator e o rotor, que resultam em distúrbios nas correntes do estator, tensões, campo magnético, vibração da máquina, temperatura de operação, entre outros de Jesus Romero-Troncoso (2017).

Usando o MCSA como um método de tratamento de sinal para composição de dados a serem analisados para identificação de falhas é possível distinguir padrões presentes nos sinais elétricos que caracterizam a especificidade de cada falha, pois aparecem distorções em frequências diferentes da frequência fundamental da máquina.

Matematicamente é possível estabelecer por meio das equações descritas a seguir uma série de frequências harmônicas de falta que se evidenciam devido a barras quebradas do rotor 1 e as falhas de curto-círcito no estator 2.

$$f_{brb} = f_{fun} \left[ k \left( \frac{1-s}{p} \right) \pm s \right] \quad (1)$$

$$f_{st} = f_{fun} \left[ \frac{n}{p} (1-s) \pm k \right] \quad (2)$$

O resultado do equacionamento determina essa série de frequências harmônicas proporcionalmente ao valor da ordem  $k$ , baseados na frequência da operação da máquina ( $f_{fun}$ ), no escorregamento ( $s$ ) e no número de polos do estator ( $p$ ). Onde  $k$  é um número de ordem inteira e ajusta as bandas laterais que são igualmente propagadas a partir da frequência fundamental.

O uso destas técnicas ou suas combinações podem identificar tanto falhas de origem mecânica quanto falhas de origem elétrica. Entretanto, a precisão do método é baseada no conhecimento prévio de diversas informações dinâmicas do MI, tais como frequência de funcionamento, velocidade de operação, escorregamento, número de polos, tamanho e características específicas dos rolamentos, entre outros para que se saiba a qual frequência característica deve-se observar de Jesus Romero-Troncoso (2017).

Outras dificuldades com metodologias tradicionais são vistas no trabalho de Martin-Diaz et al. (2017) onde são relatados os desafios de detectar falhas incipientes do rotor usando o sinal de corrente do estator sob diferentes fontes de inversor. Este estudo detecta rupturas incipientes da barra do rotor em um motor de indução trifásico alimentado pelo inversor sob diferentes condições de carga usando a técnica de alta resolução conhecida como classificação de múltiplos sinais (MUSIC).

Assim, a junção das técnicas de extração de características por observação das respostas fornecidas pelo MCSA e a análise dos dados por meio de classificação com sistemas inteligentes têm se mostrado eficaz conforme observado em Liu et al. (2018) que apresenta uma revisão bibliográfica dos trabalhos recentes com aplicação industrial das ferramentas inteligentes no método diagnóstico. O SI é capaz de perceber as anormalidades, generalizando resultados e com uma capacidade bem maior de processamento de informações do que a observação pontual de frequências distintas.

Um reconhecimento inteligente de falhas consiste em uma descoberta automática de padrões de distúrbios nos sinais amostrados por meio de algoritmos computacionais dedutivos, podendo ter sua operação supervisionada ou não Lawrynowicz (2014). Os algoritmos supervisionados usam um conjunto de sinais conhecidos para treinamento e classifica os padrões em análise de acordo com as categorias já estabelecidas. Para o reconhecimento não supervisionado dos sinais em análise é criado o conjunto de treinamento e definidos padrões novos de estratégias, em vez de separar os dados de acordo com categorias pré-existentes Haykin (2011).

### 3.1 Sistemas Inteligentes

Dos métodos de aquisição dos dados, os não invasivos geralmente utilizam-se de aquisição e pré-processamento de sinais. No entanto, ferramentas baseadas nessa sistemática aumentam a quantidade de informações para análise. Por isso, as técnicas de diagnóstico mais recentes costumam ter etapas de cálculo e de seleção de recursos ou redução de dimensionalidade, para então passar ao estágio de classificação por SI Attoui et al. (2017).

Portanto, para demonstrar uma generalização do método de injeção de sinais harmônicos de referência, proposto neste trabalho, são utilizados cinco métodos diferentes de classificação de padrões com aprendizado supervisionado, entre eles k-NN, NB, SVM, MLP e C4.5.

### 3.2 Ferramenta Computacional para Sistemas Inteligentes

Uma vez que o objetivo desta pesquisa seja a inserção de SHRB para auxiliar na classificação de falhas por sistemas

inteligentes, foi utilizado o software *Waikato Environment for Knowledge Analysis* (WEKA) como um compêndio de algoritmos de inteligência computacional. Baseado na linguagem JAVA, o software reúne algoritmos de diferentes abordagens dedicadas ao estudo de aprendizado de máquina, análise e estatística; e através de *data mining* gera hipóteses de solução Hall et al. (2009).

Este software gera as estruturas do algoritmo inteligentes de forma autônoma, mas algumas características foram configuradas conforme descrito na Tabela 1.

Tabela 1. Ajuste de Parâmetros por SI no WEKA

SI	Parâmetro	Ajuste
k-NN	Nr Neighborhoods	1
MLP	Hidden layers	20-15-5
	Learning	0.03

Para as abordagens com os algoritmos NB, SVM e C4.5, foram utilizadas as configurações padrões do software, não sendo ajustado nenhum parâmetro.

A utilização do software comprehende a terceira etapa do processo de classificação, pegando os dados já estruturados em matrizes distintas para cada tipo de falha e estado de degradação. Sendo que cada vetor das matrizes corresponde a junção para todos os harmônicos injetados e uma determinada condição de operação de velocidade e carga do MI.

## 4. RESULTADOS EXPERIMENTAIS

Vendo a aplicação prática de uma ferramenta capaz de detectar 47% das falhas de IM, buscou-se a realidade da indústria, recriando duas condições distintas de falha elétrica. Também sendo abordada a gravidade das falhas com a inclusão de dados de teste em duas condições diferentes da mesma falha, conforme apresentado na Tabela 2.

Tabela 2. Amostras do banco de dados

Classe	Local	Descrição	Amostras
a		sem falhas	240
b	Rotor	2 barras quebradas (consecutivas)	120
c	Rotor	4 barras quebradas (2 e 2)	120
d	Estator	curto-circuito - 3% da bobina	120
e	Estator	curto-circuito - 5% da bobina	120

Portanto, todas as abordagens de SI trabalharam com a classificação em cinco classes diferentes de um universo de dados com 720 amostras. Cada um dos cinco classificadores inteligentes usa o mesmo banco de dados e não executa nenhuma pré-classificação de falha ou nenhuma análise antes de determinar a degradação. Quando o algoritmo aponta a presença de anomalia, já estará determinando o tipo de falha e sua severidade.

### 4.1 Comparativo entre algoritmos SI

A descrição dos resultados e apresentada na Tabela 3 onde se compararam os melhores percentuais de classificação assertiva de cada classificador inteligente.

As cinco propostas de algoritmos inteligentes resultaram na classificação com acertos superior a 93%, sendo que estes percentuais de acerto se baseiam na classificação das

Tabela 3. Comparativo de Resultados

SI	PMC	k-NN	SVM	C4.5	NB
Nr Classes	5	5	5	5	5
Nr Amostras	720	720	720	720	720
Class. Incorreta	37	0	0	64	28
Class. Correta	683	720	720	656	692
Acurácia (%)	94,86	100	100	91,11	96,11
EQM	0,125	0,003	0,002	0,175	0,123
EMA	0,052	0,002	0,001	0,040	0,015
kappa	0,939	1	1	0,885	0,950

EQM- Erro Quadrático Médio  
EMA- Erro Médio Absoluto

instâncias em 5 classes distintas que são separadas tanto em tipo de falha como em severidade de falha.

O coeficiente *kappa*, que aponta a relação entre o valor verdadeiro e o valor estimado para a saída do classificador não apresenta grande divergência nos resultados, mostrando que os valores de saída dos classificadores, mesmo quando imprecisos, estão próximos aos valores verdadeiros, mesmo nas abordagens em que o índice difere de 1.

Observando os resultados pelos valores dos erros médios de previsão de modelo em unidades da variável de interesse, temos que todas as métricas são tratadas indiferentes em relação à direção dos erros, ou seja, são pontuadas e orientadas negativamente, o que significa que valores mais baixos são melhores. Sobre esta perspectiva, o índice EMA mostra que o algoritmo NB se destaca entre os pares que não atingem 100% de classificação. Isso representa que para este algoritmo há uma distribuição mais coesa entre os valores classificados referenciados nos padrões apresentados.

Ao observar os resultados pela métrica EQM, em que os erros são elevados ao quadrado antes da média, tem-se que o cálculo potencializa os erros absolutos de cada amostra. Este índice similar a variância significa que mesmo onde o EMA é mais baixo e o EQM percentual pode ter valores consideráveis à medida que a variância associada à distribuição de frequência das magnitudes de erro também aumenta.

Assim, ao observar as abordagens em questão, salienta-se que o índice baixo de 0,119 para o RMSE do algoritmo PMC está próximo ao valor 0,123 do algoritmo NB, consolidando uma diferença de apenas 0,004 pontos percentuais, mesmo com as divergências em seus valores de EMA em mais de 4 vezes, demonstrando-se que em ambas as propostas não são encontrados erros de valores acentuados.

Quando observados estes índices para os classificadores k-nn e SVM nota-se uma concordância interessante, pois tem-se 0,002 atribuído ao k-nn e 0,001 ao SVM como valor do EMA. Este índice define uma média de erros absolutos quase nula mas com superioridade ao SVM.

Estas métricas aqui descritas também podem ser indicadores de qual é a melhor abordagem classificadora, mesmo se comparando algoritmos que atingem 100% de acerto.

Colocadas lado a lado, elas representam a precisão em respostas mais justas e concisas e pode demonstrar a tendência do SI a generalizar e interpretar valores. Isto posto, mostra uma ligeira vantagem do classificador PMC em

relação aos classificadores C4.5 e NB. Mesmo com a maior média dos erros absolutos (EMA = 0,063), tem a maior taxa de acerto e menor índice EQM das propostas que não atingiram classificação de 100%. Enfatizando ainda que o EQM = 0,119 é menor em 0,04 pontos percentuais ao EQM = 0,159 do algoritmo C4.5, garantindo que suas respostas não apresentem erros com diferenças grandes dos valores objetivos.

#### 4.2 Classificador Simples

Aprofundando mais a análise de desempenho das propostas foi realizada, nos algoritmos que não obtiveram 100% de acerto, a observação dos resultados como um classificador simples. Utilizando-se dos mesmos resultados obtidos anteriormente é possível obter o diagnóstico apenas da presença ou não de falha, ignorando o erro entre classes de falhas ou do grau de severidade da falha. Desta forma foi estruturada a Tabela 4.

Tabela 4. Índices para Classificação Simples

Algoritmo	PMC	C4.5	NB
Verdadeiros Positivos (VP)	476	451	470
Falsos Positivos (FP)	1	29	18
Verdadeiros Negativos (VN)	239	213	222
Falsos Negativos (FN)	4	29	10
Acurácia (%)	99,30%	91,84%	96,11%

A abordagem PMC se destaca novamente, uma vez apresentou apenas 01 falso positivo e 04 falsos negativos, elevando seu nível de acerto para 99,30%. Isto corresponde ao percentual classificando de forma direta a presença de falha. Enquanto o NB permanece com a taxa de 96,11% e o C4.5 tem um pequeno ganho de cerca de 0,7%.

Assim, este aspecto operacional permite que esta abordagem ofereça uma ferramenta alternativa com 4 dos algoritmos inteligentes capazes de detectar a presença de falhas elétricas em MI com acerto superior a 95%. E destes classificadores a classificação em origem da falha e severidade da mesma em mais de 90%.

#### 4.3 Análise por ZeroR

Uma alternativa na análise de desempenho dos SI classificadores de padrões baseia-se na contraposição com o método de classificação *ZeroR*. Esse método de classificação simplista prevê a classe majoritária do problema e desconsidera os preditores. Embora não tenha a capacidade de previsibilidade, o algoritmo *ZeroR* é útil para determinar o desempenho de referência servindo de índice comparativo para os outros métodos de classificação Hall et al. (2009).

Em uma observação mais detalhada, o gráfico apresentado na Figura 5, demonstra o ganho percentual de cada abordagem de SI em relação ao valor de *ZeroR*, tanto para classificação simples como para classificação em severidade.

Estas considerações de análise, além de tudo, mostram que os algoritmos propostos não são tendenciosos e não encontram-se saturados de informação ou com baixa capacidade de generalização ou classificação.

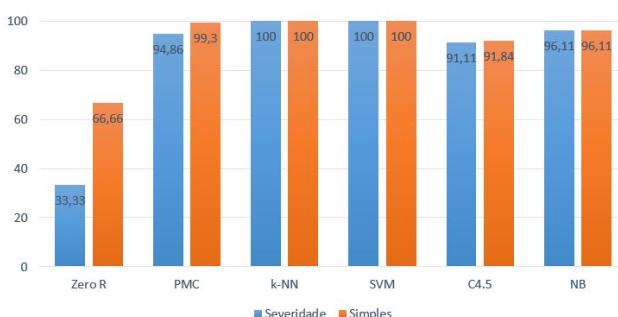


Figura 5. Comparativo percentual de desempenho *ZeroR*

## 5. CONCLUSÃO

Este trabalho apresentou um método alternativo aos convencionais para detecção de dois tipos de falhas elétricas em motores de indução trifásicos alimentados por meio de moduladores de tensão como inversores de frequência, observando e manipulando para tal as grandezas de tensão e corrente elétrica. Estes sinais foram tratados no domínio da frequência sob a ótica da análise da FFT como resposta da interações da máquina a sinais harmônicos de referências injetadas juntamente com a alimentação.

Toda a abordagem foi implementada e utilizada em um modelo de classificação *off-line*, pois os dados coletados foram tratados, estruturados e classificados externamente aos módulos inversores de frequência e controle da máquina. Mas, em simples adequação, o algoritmo de controle pode conter as rotinas de averiguação e varredura para processamento e classificação das falhas em uma abordagem *on-line* ao sistema.

A avaliação das correntes estatísticas, com as frequências harmônicas de referências injetadas na alimentação dos motores mostra-se capaz de evidenciar a existência de falhas elétricas. Em uma visão mais específica do problema busca-se a melhoria dos métodos de aquisição e especificação da falha com a evolução do algoritmo, embasado na maior capacidade de informações apresentada para processamento.

As matrizes de entradas são compostas de sinais com injeção de frequências harmônicas de referências escolhidas de forma heurística e em sequência harmônica ímpar de ordem inteira, sendo o intervalo selecionado para este trabalho compreendido por 11 sinais harmônicos entre a frequência fundamental de funcionamento, iniciando na 3<sup>a</sup> até a 21<sup>a</sup> frequência harmônica.

Com isso, os sub-vetores amostrais no espectro da frequência, determinado de 1Hz a 1.300Hz nas FFTs, contemplam a faixa de frequência conhecida para a identificação das falhas e permanecem dentro da faixa de frequência considerada de baixa inferência de outras harmônicas, como as do próprio chaveamento do inversor.

Os resultados práticos para os testes, com simulação controlada das falhas elétricas de quebra de barras de rotor e curto-círcuito em bobina do estator, mostraram a capacidade que a técnica de inserção de sinais harmônicos de referência de busca tem ao ser empregada como ferramenta no diagnóstico dos motores de indução trifásicos. Isto

porque todas as abordagens de classificadores inteligentes encontram sintonia satisfatória junto ao software WEKA e resultados de classificação condizentes.

As cinco propostas resultaram na classificação com acertos de 93% à 100%, sendo que estes percentuais de acerto se baseiam na classificação das instâncias em 5 classes distintas que são separadas tanto em tipo de falha como em intensidade de degradação. Destaca-se ainda que destas cinco abordagens, duas retornaram valor de classificação em 100% com um erro quadrático médio praticamente nulo.

Ainda, foi proposto uma análise correlata utilizando-se das mesmas respostas obtidas dos classificadores mas objetivando a classificação simples da presença ou não de falha. Nesta condição pôde-se atribuir o acerto superior a 99% também ao SI tipo PMC e acréscimo na taxa de acerto do classificador C4.5.

É possível observar que mediante a modulação e inserção de sinais harmônicos de referência de busca, bem como o pré-processamento de dados antes da submissão ao sistema inteligente, é alcançada uma abordagem mais simplificada de multiclassificação de falhas sem a necessidade de utilização de multi-agentes ou subclassificações sequenciais com redes em cascata.

Desta forma, a análise de falhas pelo método de inserção de SHRB e o processamento dos sinais empregados para as análises mostraram a versatilidade do método, uma vez que são obtidas respostas condizentes e satisfatórias para a classificação de falhas, salvo especificidades de cada abordagem de SI. Isso implica uma metodologia generalista que pode ser empregada adjacente a outras técnicas de classificação inteligente de falhas que não foram abordadas neste trabalho.

## AGRADECIMENTOS

Os autores agradecem as contribuições para com este trabalho concedidas através dos fomentos do CNPq (Processos 474290/2008 – 5, 473576/2011 – 2, 552269/2011 – 5, e 405228/2016 – 3), da Fundação Araucária (Processo 06/56093 – 3), e da FAPESP (Processo 2011/17610 – 0).

## REFERÊNCIAS

- Attoui, I., Fergani, N., Boutasseta, N., Oudjani, B., and Deliou, A. (2017). A new time-frequency method for identification and classification of ball bearing faults. *Journal of Sound and Vibration*, 397, 241 – 265.
- Bazan, G.H., Scalassara, P.R., Endo, W., Goedtel, A., Godoy, W.F., and Palácios, R.H.C. (2017). Stator fault analysis of three-phase induction motors using information measures and artificial neural networks. *Electric Power Systems Research*, 143, 347 – 356.
- Bellini, A., Filippetti, F., Tassoni, C., and Capolino, G.A. (2008). Advances in diagnostic techniques for induction machines. *IEEE Transactions on Industrial Electronics*, 55(12), 4109–4126.
- Cusido, J., Rosero, J., Romeral, L., Ortega, J.A., and Garcia, A. (2006a). New fault detection techniques for induction motors. *Electrical Power Quality and Utilization*, 2(1), 39–46.

- Cusido, J., Rosero, J., Romeral, L., Ortega, J.A., and Garcia, A. (2006b). New techniques for fault detection analysis by injecting additional frequency test. *in 2006 IEEE Instrumentation and Measurement Technology Conference Proceedings*, 2087–2090.
- de Jesus Romero-Troncoso, R. (2017). Multirate signal processing to improve fft-based analysis for detecting faults in induction motors. *IEEE Transactions on Industrial Informatics*, 13(3), 1291–1300.
- Godoy, W.F., da Silva, I.N., Goedtel, A., Palácios, R.H.C., and Lopes, T.D. (2016). Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter. *IET Electric Power Applications*, 10(5), 430–439.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I.H. (2009). The weka data mining software: An update. *SIGKDD Explor. Newsl.*, 11(1), 10–18.
- Haykin, S. (2011). *Neural Networks and Learning Machines*. Pearson Education.
- Irfan, M., Saad, N., Ibrahim, R., and Asirvadam, V.S. (2015). An on-line condition monitoring system for induction motors via instantaneous power analysis. *Journal of Mechanical Science and Technology*, 29(4), 1483–1492.
- Irfan, M., Saad, N., Ibrahim, R., and Asirvadam, V.S. (2017). Condition monitoring of induction motors via instantaneous power analysis. *Journal of Intelligent Manufacturing*, 28(6), 1259–1267.
- Lakehal, A. and Ramdane, A. (2017). Fault prediction of induction motor using bayesian network model. *in 2017 International Conference on Electrical and Information Technologies (ICEIT)*, 1–5.
- Lawrynowicz, A. (2014). Pattern based feature construction in semantic data mining. *International journal on Semantic Web and information systems*, 10, 28–67. doi: 10.4018/ijswis.2014010102.
- Li, C., de Oliveira, J.V., Cerrada, M., Pacheco, F., Cabreria, D., Sanchez, V., and Zurita, G. (2016). Observer-biased bearing condition monitoring: From fault detection to multi-fault classification. *Engineering Applications of Artificial Intelligence*, 50, 287 – 301.
- Likitjarernkul, T., Sengchuai, K., Duangsoithong, R., Chalermyanont, K., and Prasertsit, A. (2017). Pca based feature extraction for classification of statorwinding faults in induction motors. *Pertanika Journal Science & Technology*, 25(S), 197–204.
- Liu, R., Yang, B., Zio, E., and Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108, 33 – 47.
- Mabrouk, A.E. and Zouzou, S.E. (2015). Diagnosis of rotor faults in three-phase induction motors under time-varying loads. *in 2015 IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, 373–379.
- Martin-Diaz, I., Morinigo-Sotelo, D., Duque-Perez, O., Arredondo-Delgado, P., Camarena-Martinez, D., and Romero-Troncoso, R. (2017). Analysis of various inverters feeding induction motors with incipient rotor fault using high-resolution spectral analysis. *Electric Power Systems Research*, 152, 18 – 26.
- Mata-Castrejón, P.V.D., Villegas-Ortega, A., Asiaín-Olivares, T.I., and Ruiz-Vega, D. (2015). Evaluation of progressive deterioration of a squirrel-cage rotor, with a condition monitoring system that implements the sideband methodology. *in 2015 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, 1–6.
- Naha, A., Samanta, A.K., Routray, A., and Deb, A.K. (2016). A method for detecting half-broken rotor bar in lightly loaded induction motors using current. *IEEE Transactions on Instrumentation and Measurement*, 65(7), 1614–1625.
- Rajeswaran, N., Swarupa, M.L., Rao, T.S., and Chetaswi, K. (2018). Hybrid artificial intelligence based fault diagnosis of svpwm voltage source inverters for induction motor. *Materials Today: Proceedings*, 5(1, Part 1), 565 – 571. International Conference on Processing of Materials, Minerals and Energy (July 29th and 30th) 2016, Ongole, Andhra Pradesh, India.
- Saddam, B., Aissa, A., Ahmed, B.S., and Abdellatif, S. (2017). Detection of rotor faults based on hilbert transform and neural network for an induction machine. *In 2017 5th International Conference on Electrical Engineering- Boumerdes (ICEE-B)*, 1–6.
- Singh, G., Kumar, C.A., and Naikan, V.N.A. (2015). Effectiveness of current envelope analysis to detect broken rotor bar and inter turn faults in an inverter fed induction motor drive. *in 2015 International Conference on Power and Advanced Control Engineering (ICPACE)*, 191–194.
- Thomson, W.T. and Fenger, M. (2001). Current signature analysis to detect induction motor faults. *IEEE Industry Applications Magazine*, 7(4), 26–34. Cited By (since 1996): 251.
- van der Broeck, H.W., Skudelny, H., and Stanke, G.V. (1988). Analysis and realization of a pulselwidth modulator based on voltage space vectors. *IEEE Transactions on Industry Applications*, 24(1), 142–150.