

## CLASSIFICAÇÃO DE CONDIÇÕES DE BALANCEAMENTO DE TENSÃO EM UM MOTOR ELÉTRICO DE INDUÇÃO TRIFÁSICO

**Resumo:** Os Motores de Indução Trifásicos (MITs) são peças fundamentais, pois são os principais responsáveis por realizar o processo de trabalho mecânico na indústria. No Brasil, eles são responsáveis por consumir mais da metade de toda a energia destinada ao setor industrial. Desta forma, qualquer falha de operação em motores deste tipo se reflete em perdas energéticas, econômicas e ambientais. Dentre as falhas mais comuns, está o desbalanceamento das tensões de alimentação, que pode causar perda total da máquina dependendo da magnitude de desbalanceamento. O presente artigo expõe um método de classificação de condições de tensão de alimentação balanceadas e desbalanceadas em um motor elétrico de indução trifásico utilizando uma árvore de decisão (Decision Tree - DT). Para tal, usou-se um banco de dados com variáveis mecânicas e elétricas relativas a operação balanceada e desbalanceada do motor, divididos em classes de diferentes níveis de desbalanceamento de acordo com a National Electrical Manufacturers Association (NEMA). Assim, realizou-se as simulações da árvore de decisão onde obteve-se uma acurácia superior a 95%, reforçando a aplicabilidade desta técnica de Machine Learning (ML) na classificação de fenômenos desta natureza.

**Palavras-chave:** Árvore de Decisão, Machine Learning, Desbalanceamento de tensão, Motor de Indução Trifásico.

### 1 INTRODUÇÃO

O Motor de Indução Trifásico (MIT) é uma máquina elétrica rotativa designada para realizar o processo de conversão de energia elétrica em energia mecânica, sendo amplamente empregado no setor industrial. Neste processo de conversão de energia, o MIT utiliza campos magnéticos rotativos.

Estima-se que os motores de indução sejam responsáveis por consumir 68% de toda a energia destinada ao setor elétrico brasileiro. O amplo emprego dessas máquinas na indústria se justifica não só pela sua robustez, como também pela sua simplicidade e baixo custo de manutenção (SANTOS *et al.*, 2015).

Isto posto, é evidente que quaisquer falhas em máquinas desta natureza refletir-se-ão em perdas energéticas, pela queda de rendimento; econômicas, pelo gasto da energia desperdiçada; e ambientais, pelos recursos naturais utilizados na geração da energia não aproveitada. Um dos principais fatores que favorecem as perdas em um MIT é a alimentação com tensões desbalanceadas, que promove a circulação de sobrecorrentes elétricas, aumentando as perdas, a temperatura e a redução da vida útil da máquina (REZENDE; SAMESIMA, 2012).

O fenômeno das tensões desbalanceadas provoca o desbalanceamento das correntes. Estima-se que um desbalanceamento de 1% das tensões acarreta em um desbalanceamento das correntes de plena carga de um MIT entre 7,5% a 8,5%, e de 12,5% a 15% a vazio. Ademais, desbalanceamentos de 3,5% na tensão podem potencializar as perdas do MIT em 20% e desbalanceamentos iguais ou superiores a 5% causam perdas ainda mais severas, podendo levar até a perda do motor. Por outro lado, perdas de 1% a 2%, embora sejam prejudiciais e causarem acréscimo considerável no consumo de energia por longo período de tempo, não são perceptíveis com facilidade, essencialmente se a máquina estiver

superdimensionada. Portanto, as tensões devem ser supervisionadas e qualquer desbalanceamento superior a 1% precisa ser corrigido (REZENDE; SAMESIMA, 2012).

A técnica de Árvore de Decisão (*Decision Tree* - DT) é utilizada em problemas de regressão ou classificação. Em MITs, uma das principais aplicações de DTs é a extração de regras interpretáveis para diagnóstico de falhas mecânicas ou elétricas. Como exemplos de aplicações de DTs em MITs temos: (i) (POMORSKI; PERCHE, 2001) para detecção de falhas de isolamento; (ii) (TRAN *et al.*, 2009) para diagnóstico de falhas mecânicas; e (iii) (DIAZ *et al.*, 2018) para o diagnóstico de falhas incipientes associados ao rotor.

Os dados utilizados neste trabalho foram adquiridos a partir da operação simulada de um MIT de 415 V obtidos de (ADEKITAN; SAMUEL; AMUTA, 2019). Na simulação, a fonte de tensão variou do estado balanceado (0% de desequilíbrio de tensão) até atingir o nível de 5% de desequilíbrio, considerado como valor máximo recomendado pela National Electrical Manufacturers Association (NEMA) (ADEKITAN; SAMUEL; AMUTA, 2019).

Este trabalho apresenta o conceito de qualidade da energia elétrica na seção 2. Na seção 3 é explicado o fenômeno de desequilíbrio de tensão, com suas causas e implicações. A técnica de árvore de decisão é comentada na seção 4. Já na seção 5, a topologia da árvore de decisão e os resultados do estudo realizado são apresentados. Finalmente, na seção 7, são indicados as conclusões e os trabalhos futuros.

## 2 QUALIDADE DA ENERGIA ELÉTRICA

O conceito de qualidade de energia está associado a um grupo de alterações ao qual o sistema elétrico pode estar exposto. Desta forma, problemas de qualidade de energia podem ser descritos como qualquer problema de energia referente a tensão, corrente ou a variações de frequência que resultem em falha ou na operação indesejável de equipamentos. Todas essas alterações podem se originar de diversas partes do sistema elétrico, não só nas instalações consumidoras como também no sistema da concessionária de energia (REZENDE; SAMESIMA, 2012).

Ademais, outra definição para qualidade de energia advém da frequência e rigidez dos desvios na forma e amplitude das ondas de tensão e corrente. Portanto, a qualidade da energia de um sistema elétrico pode ser classificado de três maneiras: excelente, boa ou pobre. Assim, um sistema elétrico com qualidade dita excelente é qualificado pelo abastecimento de energia em tensão com forma de onda senoidal pura, livre de alterações na amplitude e frequência. Por outro lado, um sistema elétrico de boa qualidade é qualificado pelo baixo nível dos desvios em corrente e tensão, e não apresenta riscos aos equipamentos. Finalmente, um sistema elétrico com qualidade dita pobre é classificado pela onda de tensão ou onda de corrente elétrica com suficientes desvios ao ponto de causar prejuízo ao funcionamento ou levar à falha de equipamentos (ROCHA, 2016).

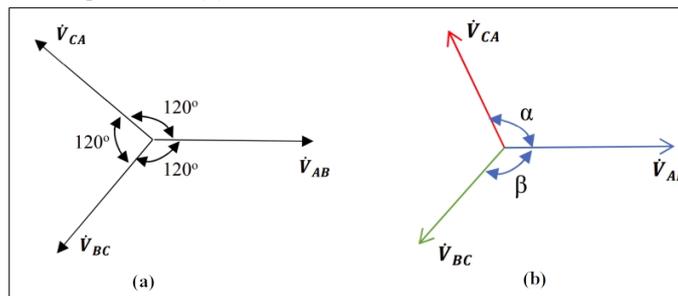
Os MITs são expostos aos problemas de qualidade de energia nas indústrias majoritariamente pelo uso intenso de cargas não lineares, que resultam no comprometimento do funcionamento ideal desses motores (LIMA, 2016). Além das cargas não lineares, também contribuem para redução da qualidade de energia em um sistema elétrico o crescente interesse pela racionalização e conservação da energia elétrica, que propicia o uso de equipamentos que até economizam no uso da energia mas podem aumentar os níveis de distorções harmônicas e levar o sistema a condições de ressonância (REZENDE; SAMESIMA, 2012).

Assim, para que os MITs possam operar em condições ideais, é necessária que sua alimentação seja de boa qualidade, pois do contrário, a máquina poderá apresentar diversos distúrbios, como o desequilíbrio de tensão, que reduz não só o rendimento como também a vida útil do motor.

### 3 DESEQUILÍBRIO DE TENSÃO

Para um sistema equilibrado e simétrico, os fasores de tensão possuem a mesma magnitude e são defasados entre si em  $120^\circ$ . Por outro lado, em sistemas desequilibrados e assimétricos, os módulos de cada fasor não serão iguais, ou os ângulos de defasamento irão diferir do valor de  $120^\circ$ , ou poderá ainda ocorrer as duas situações, concomitantemente (LIMA, 2016). Na Figura 1 (a) e (b) estão representados os diagramas fasoriais de tensão de linha de um sistema genérico equilibrado e desequilibrado, respectivamente.

Figura 1 – Diagrama fasorial de sistema equilibrado (a) e desequilibrado (b)



Fonte: LIMA, 2016.

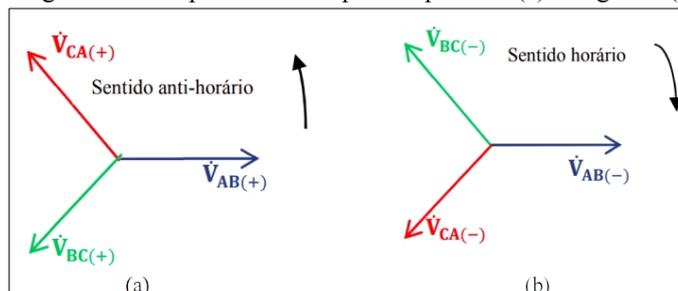
Em suma, um sistema elétrico é considerado desequilibrado quando a Equação (1) não for atendida (LIMA, 2016):

$$\dot{V}_{AB} = V \angle 0^\circ; \dot{V}_{BC} = V \angle -120^\circ; \dot{V}_{CA} = V \angle -240^\circ \quad (1)$$

Onde  $\dot{V}_{AB}$ ,  $\dot{V}_{BC}$  e  $\dot{V}_{CA}$  representam os fasores do sistema e  $V$  o módulo do respectivo fasor.

A análise dos efeitos de um sistema trifásico desequilibrado pode ser realizada a partir da decomposição do sistema desequilibrado em três sistemas de tensões equilibradas, usando o método das componentes simétricas. Nesse método, as tensões em desequilíbrio são descritas por até três tensões equilibradas, a saber: tensão de sequência positiva, tensão de sequência negativa e tensão de sequência zero. Outrossim, desconsidera-se a componente de sequência zero pelo fato dos MITs serem ligados em estrela sem neutro ou em triângulo, o que indica a inexistência desse elemento (LIMA, 2016). A Figura 2 (a) e (b), a seguir, representa as componentes de sequência positiva e negativa de um sistema trifásico genérico, respectivamente.

Figura 2 – Componente de sequência positiva (a) e negativa (b)



Fonte: LIMA, 2016.

### 3.1 Avaliação do desequilíbrio de tensão

Os principais métodos de medida de desequilíbrio de tensão, também chamado de fator K, são: o método NEMA, o método IEEE, o método das componentes simétricas e o método GIGRÉ (REZENDE; SAMESIMA, 2012). Os dados utilizados na simulação do presente trabalho classifica o fator K de acordo com o método NEMA, por esse motivo, omitir-se-á a descrição dos demais métodos.

O fator K é definido, segundo a norma (NEMA MG 14.34, 2016), como sendo a razão entre  $\Delta V$  e  $V_m$ . Onde  $\Delta V$  representa o desvio máximo das tensões de linha em relação ao seu valor médio, representado por  $V_m$ . A Equação (2), a seguir, representa o cálculo do fator K por esse método:

$$K = \left( \frac{\Delta V}{V_m} \right) \times 100 (\%) \quad (2)$$

### 3.2 Causas do desequilíbrio de tensão

As causas dos desequilíbrios de tensão podem ser classificadas em dois tipos: estruturais ou funcionais. As causas estruturais dizem respeito a desequilíbrios na rede elétrica, como transformadores ou banco de capacitores desbalanceados. Já as causas funcionais relacionam-se a distribuições desiguais de cargas nas três fases, provocadas pela presença de cargas desequilibradas, distribuição monofásica deficiente ou variação nos ciclos de demanda de cada fase (REZENDE; SAMESIMA, 2012).

### 3.3 Efeitos do desequilíbrio de tensão

Os danos decorrentes do desequilíbrio incluem, principalmente: (i) aumento de perdas internas com redução do rendimento do MIT; (ii) elevação da temperatura de operação e redução da vida útil; (iii) surgimento de torque eletromagnético oposto ao sentido de rotação do motor; e (iv) alterações no tempo de partida e diminuição do fator de potência (REZENDE; SAMESIMA, 2012).

## 4 ÁRVORE DE DECISÃO

As árvores de decisão são utilizadas para classificação ou regressão a partir de um conjunto de dados de entrada. Também, são empregadas no aprendizado de máquina para a mineração dos dados. Supondo a tarefa de classificação, a topologia da árvore é um tipo de fluxograma que a partir de sucessivas escolhas decide em qual classe um determinado dado pertencerá (FACELI *et al.*, 2011). A Figura 3, a seguir, representa um modelo genérico de árvore de decisão.

Figura 3 – Árvore de Decisão



Fonte: Os próprios autores.



A árvore é formada por um nó raiz, por nós de decisão e por nós folhas ou terminais que dependendo das escolhas feitas ou de intervalos em que a amostra se encontra é possível classificá-los. Para a construção de uma árvore de decisão, é necessário um conjunto de treinamento que contenha exemplos de classes previamente conhecidas (aprendizado supervisionado) (FACELI *et al.*, 2011).

Em uma árvore de decisão pode-se ter atributos com uma baixa interferência na classificação dos dados ou ruídos que podem ocasionar uma má classificação. Por isso é interessante realizar o processo chamado de poda para retirar partes da árvore que estão gerando problemas na classificação. A poda pode ser realizada de duas maneiras: a pré poda é realizada colocando no algoritmo critérios de parada para, dessa forma, retirar galhos que não interferem no desenvolvimento da árvore durante a sua construção, e temos a pós poda no qual a árvore é totalmente construída e depois são observados os níveis de confiabilidade de cada subárvore para que dessa forma possa se retirar os ramos ou galhos classificados como não confiáveis (LAURETTO, 2010).

Os Algoritmos de indução de árvores de decisão mais citados são: ID3 (QUINLAN, 1986), C4.5 (QUINLAN, 1993) e CART (BREIMAN *et al.*, 1984). O algoritmo utilizado neste trabalho é o CART (Classification and Regression Trees).

Para entendimento da escolha dos atributos corretos para a criação da árvore de decisão, é necessário o conhecimento de dois conceitos: entropia e ganho de informação. A entropia é o cálculo que demonstra a igualdade dos exemplos contidos em um conjunto de dados (OSÓRIO, 2000). A entropia para  $N$  casos pode ser dada pela Equação (3) :

$$ENTROPY(S) = \sum_{i=1}^N P_i \cdot \log_2 \cdot P_i \quad (3)$$

No qual  $P_i$  é a proporção dos dados da entropia ( $S$ ) que estão na classe  $i$

Para cada atributo, o ganho de informação realiza uma medição da redução na entropia nas partes obtidas de acordo com os dados dos atributos (FACELI *et al.*, 2011). O ganho de informação é dado pela seguinte Equação (4) (OSÓRIO, 2000) :

$$Gain(S, A) = entropia(S) - \sum_{v=1}^N \left( \frac{|S_v|}{|S|} \right) \times entropia(S_v) \quad (4)$$

### **CART**

O algoritmo CART foi descrito em (BREIMAN *et al.*, 1984 ). É um método que é capaz de induzir árvores de decisão e árvores de regressão, dependendo do tipo de atributo. Consegue induzir árvores de forma simples, possuindo um tipo poda diferente de outros algoritmos de árvores de decisão. Utiliza pós poda por meio da redução do fator custo de complexidade (BREIMAN *et al.*, 1984 ). Para utilizar este método deve-se ordenar cada regra de divisão com base no critério de qualidade de divisão. O critério utilizado para classificação é chamado de índice Gini, que se assemelha a entropia, como está representado na Equação (5).

$$\phi(p_1, \dots, p_2) = - \sum_j P_j \log(P_j) \quad (5)$$

Onde  $P$  é igual à frequência de cada classe  $j$  encontrada.

Existe também o processo de divisão da árvore de decisão que procura minimizar o valor esperado dos erros quadráticos de regressão  $R(T)$ , sendo  $t$  o identificador de cada nó da árvore. O  $R(T)$  é dado pela Equação (6) (SILVA, 2005):

$$R(T) = \frac{1}{N} \sum_{t \in T} \sum_{x \in T} (y - \bar{y}(t))^2 \quad (6)$$

Quando se encontra a melhor divisão, o processo é reiniciado para cada nó filho, até que chegue em um ponto que a divisão se torne impossível (SILVA, 2005).

#### 4.1 Validação Cruzada

A validação cruzada é uma técnica que consiste em avaliar a capacidade de generalização de um determinado modelo, a partir de um conjunto de dados.

Esse método consiste em utilizar todo espaço amostral tanto para a fase de teste quanto para a fase de treinamento. O espaço amostral é separado em  $k$  unidades distintas ( $k$ -folds) onde uma dessas unidades é separada para a fase de teste e as demais são separadas para a fase de treino. Após cada interação, a unidade separada para a fase de teste é trocada por outra. Por fim, a precisão ou acurácia da árvore é calculada pela média das interações realizadas (SANTANA, 2020). Seja um espaço amostral com  $n$  amostras. Em primeiro lugar, separa-se o espaço em  $k$  unidades distintas ( $d_1, d_2, \dots, d_k$ ) com tamanhos semelhantes entre si ( $m_1, m_2, \dots, m_k$ ), de forma que as Equações (7) e (8) sejam satisfeitas (CUNHA, 2019):

$$m_1 \cong m_2 \cong m_3 \cong \dots \cong m_k \quad (7)$$

$$\sum_{i=1}^k m_i = n \quad (8)$$

Em seguida realizam-se as interações. Na primeira interação a unidade  $d_i$  será separada para a fase de teste, enquanto as demais servirão para a fase de treino. Na interação seguinte, a unidade  $d_{i+1}$  torna-se a unidade de teste e  $d_i$  de treino. Esse processo é repetido até a  $k$ -ésima interação, onde a unidade  $d_k$  será a unidade de teste.

Finalmente, calcula-se a precisão do método a partir da média das acurácias das interações. Sejam  $A_1, A_2, A_3, \dots, A_k$  as acurácias de cada interação,  $A_n$  será denotada como a acurácia final da árvore e calculada a partir da Equação (9):

$$A_n = \frac{1}{k} \sum_{i=1}^k A_i \quad (9)$$

A principal vantagem da validação cruzada é a sua 'fuga da aleatoriedade', pois como todos os dados passam tanto pela fase quanto pela fase de treino, o modelo se torna mais robusto e obtém-se uma generalização mais eficiente em comparação com outras técnicas. Entretanto, caso o espaço amostral contenha uma grande quantidade de dados, essa técnica apresentará um custo computacional proporcionalmente alto.

## 5 RESULTADO DA UTILIZAÇÃO DA ÁRVORE DE DECISÃO

### 5.1 Organização dos dados

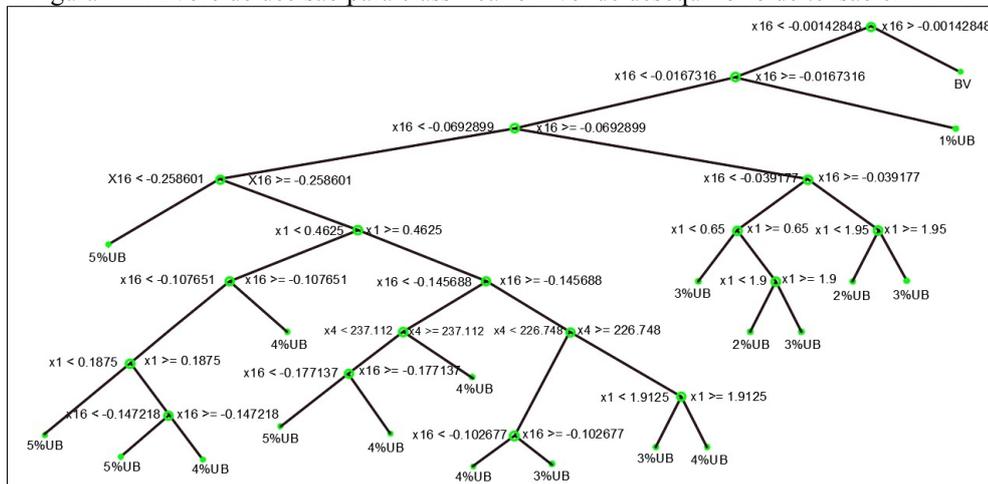
Os parâmetros operacionais analisados no MIT de teste estão separados por níveis de desbalanceamento de tensão que variam entre 0% a 5% de desbalanceamento, utilizando como referência o método NEMA. Para cada nível de desbalanceamento é colocado 120 amostras de atributos contendo os parâmetros operacionais do motor, o que gera no total 715 amostras em 17 variáveis. Para realizar a classificação colocou-se como entrada os parâmetros

operacionais do motor e como saída os níveis de desbalanceamento de tensão. O banco de dados para a elaboração desta pesquisa foi retirada de (ADEKITAN; SAMUEL; AMUTA, 2019). O banco de dados é composto pelas seguintes variáveis: escorregamento, três correntes das bobinas do rotor, três correntes das bobinas do estator, potência do rotor, potência do estator, potência de entrada, potência ativa, potência reativa, potência aparente, potência eletromecânica, torque de sequência positiva e negativa, e fator de potência.

### 5.2 Arquitetura da Árvore de Decisão

A árvore de decisão foi feita utilizando o método de CART. A árvore tem como objetivo representar de forma qualitativa os dados encontrados no banco de dados e realizar a classificação destes de forma correta. Ela foi criada empregando as 715 amostras com 17 entradas e o nível de desbalanceamento como saída. A técnica de validação cruzada é utilizada nesta árvore para avaliar a capacidade de generalização do modelo. A topologia encontrada para a árvore é representada na Figura 4.

Figura 4 – Árvore de decisão para classificar o nível de desequilíbrio de tensão em MIT



Fonte: Os próprios autores.

Partindo do nó raiz é realizado perguntas para ver se o atributo está em determinado intervalo. No final da construção da árvore, os atributos de entrada obtidos como os mais significativos para classificação foram o escorregamento, representado por x1, a corrente no rotor da fase C, representado por x4, e o torque de sequência negativo que é simbolizado por x16. Dependendo dos intervalos escolhidos, podemos chegar a classe correta para a classificação. A árvore foi podada para possuir 18 nós e dessa forma alcançar a maior capacidade de generalização em seus resultados.

### 5.3 Avaliação de Performance

A matriz de confusão é uma forma fácil de identificar os erros e acertos do classificador. Ela é composta por valores reais do banco de dados e por valores preditivos do classificador (FACELI *et al.*, 2011). Desta forma é feito uma tabela na qual é mostrada quantas das instâncias o classificador acertou e quantas errou. As 720 amostras foram classificadas de forma correta em 95,83% dos dados. O erro foi de 4,17%. A matriz de confusão é mostrado, a seguir, na Figura 5.

Figura 5 – Matriz de Confusão

	BV	1%UB	2%UB	3%UB	4%UB	5%UB
BV	119	1	0	0	0	0
1%UB	0	119	1	0	0	0
2%UB	0	3	117	0	0	0
3%UB	0	2	2	114	2	0
4%UB	0	2	0	2	110	6
5%UB	0	2	0	1	6	111

Fonte: Os próprios autores.

Como é visto na tabela a árvore fez uma classificação muito boa, errando apenas um atributo na classe balanceada (BV), errando um atributo também na classe com desbalanceamento de 1% (1%UB), e errando 3 atributos na classe de 2% (2%UB). Além disso, os resultados para a classe com nível de desbalanceamento de 3% foram de seis atributos classificados incorretamente.

Na classe de 4%, o erro foi superior, conseguindo errar dez atributos, mostrando que a árvore teve uma dificuldade maior em classificá-la. Na classe de 5% a árvore errou 9 atributos. A dificuldade de classificação se mostrou bem maior nas classes de 4% e de 5% isso se deve ao fatos que há um pouco de homogeneidade entre elas.

Para realizar a classificação a árvore utilizou de todo o conjunto de dados as variáveis de escorregamento, corrente do rotor da fase C e o torque de sequência negativa. Isso se deve ao fato que a medida que o desbalanceamento da tensão aumenta esses valores, menos o escorregamento, sofrem as maiores mudanças. O torque de sequência negativa é zero em um sistema balanceado, mas a medida que o desbalanceamento aumenta os valores desta variável aumentam. A árvore é muito dependente do torque de sequência negativa para realizar a classificação, desta forma, com um desbalanceamento de 4% a 5% este atributo tende a ficar com valores semelhantes, dificultando a classificação correta destes dados.

## 6 CONSIDERAÇÕES FINAIS

Portanto, a classificação das condições de tensão de alimentação balanceadas e desbalanceadas constitui uma importante ferramenta para a manutenção industrial, pois a identificação precoce de tais anomalias permite a correção imediata da máquina, que se reflete em maior economia energética e vida útil dos MITs. Além disso, a alta acurácia das árvores de decisão reforça a sua ampla aplicabilidade no monitoramento de dados deste tipo, sendo portanto, uma ferramenta eficaz e de baixo custo.

Como trabalhos futuros, espera-se empregar outras técnicas de *Machine Learning* no diagnóstico de falhas em máquinas elétricas, visando obter sistemas ainda mais seguros, eficazes e estáveis.

## REFERÊNCIAS

ADEKITAN, A. I.; SAMUEL, I.; AMUTA, Elizabeth. Dataset on the performance of a three phase induction motor under balanced and unbalanced supply voltage conditions. **Data in brief**, v.24, n.103947, 2019.

BREIMAN, Leo *et al.* **Classification and Regression Trees**. 1ª ed. Monterey: Wadsworth & Brooks/Cole Advanced Books & Software: 1984.

CUNHA, João Paulo Zanola Cunha. **Um estudo comparativo das técnicas de validação cruzada aplicadas a modelos mistos**. 2019. 59 f. Dissertação (Mestrado) – Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2019.

DIAZ, I. M. *et al.* Hybrid algorithmic approach oriented to incipient rotor fault diagnosis on induction motors. **ISA Transactions**, v.80, n.1, p. 427-438, 2018.

FACELI, Katti *et al.* **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. 1ª ed. Rio de Janeiro: LTC, 2011.

LAURETTO, M S. Árvores de Decisão. Disponível em:  
[https://edisciplinas.usp.br/pluginfile.php/4469825/mod\\_resource/content/1/ArvoresDecisao\\_normalsize.pdf](https://edisciplinas.usp.br/pluginfile.php/4469825/mod_resource/content/1/ArvoresDecisao_normalsize.pdf). Acesso em: 29 junho. 2020.

LIMA, E. C. de. **Diagnóstico de Motores de Indução Trifásicos Operando em Redes Desequilibradas e Distorcidas**. 2016. 150 f. Tese (Doutorado) - Universidade Federal de Itajubá, Itajubá, 2016.

NATIONAL ELECTRICAL MANUFACTURERS ASSOCIATION. **NEMA MG 14.34: Operation of General-Purpose Alternating-Current Polyphase, 2-, 4-, 6-, and 8-Pole, 60-Hertz Medium Induction Motors Operated on 50 Hertz**. Rosslyn, 2016.

POMORSKI, D; PERCHE, P. B. Inductive learning of decision trees: application to fault isolation of an induction motor. **Engineering Applications of Artificial Intelligence**, v. 14, n.1, p. 155-166, 2001.

QUINLAN, J. Ross. **C4.5: programs for machine learning**. 1ª ed. San Francisco: Morgan Kaufmann Publishers Inc., 1993.

QUINLAN, J.R. Induction of Decision Trees. **Machine Learning**. v.1, p. 81-106, 1986.

OSÓRIO, F. **Sistemas Adaptativos Inteligentes: Indução de Árvores de Decisão**. Disponível em: <http://osorio.wait4.org/oldsite/iajogos/ml/arvore-decisao.pdf>. Acesso em: 25 jun. 2020.

REZENDE, P. H. O.; SAMESIMA, M. I. Efeitos do Desequilíbrio de Tensões de Suprimentos nos Motores de Indução Trifásico. **Horizonte Científico**, Uberlândia, v.6, 2012.

ROCHA, J. E. **Qualidade da Energia Elétrica**. Disponível em:  
[http://paginapessoal.utfpr.edu.br/joaquimrocha/qualidade-da-energia-eletrica/Qualidade%20da%20Energia%20Eletrica%20\\_%20Apostila.pdf/at\\_download/file](http://paginapessoal.utfpr.edu.br/joaquimrocha/qualidade-da-energia-eletrica/Qualidade%20da%20Energia%20Eletrica%20_%20Apostila.pdf/at_download/file). Acesso em: 25 jun. 2020.

SANTANA, R. **Validação Cruzada: Aprenda de forma simples como usar essa técnica**. Disponível em: <https://minerandodados.com.br/validacao-cruzada-aprenda-de-forma-simples-como-usar-essa-tecnica/>. Acesso em: 22 jun. 2020.

SANTOS, V. S. *et al.* Procedure for Determining Induction Motor Efficiency Working Under Distorted Grid Voltages. **IEEE Transactions on Energy Conversion**, v.30, n.1, p. 331-339, 2015.

SILVA, Luiza Maria Oliveira da Silva. Uma aplicação de árvores de decisão, redes neurais e KNN para a identificação de modelos ARMA não sazonais e sazonais. 2005. 145f. Tese (Doutorado) - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005.

TRAN, V. T. *et al.* Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference. **Expert Systems with Applications**, v.36, n.2, p. 1840-1849, 2009.

## CLASSIFICATION OF VOLTAGE BALANCING CONDITIONS IN A THREE-PHASE INDUCTION ELECTRIC MOTOR

**Abstract:** *Three-phase Induction Motors (MITs) are fundamental parts, as they are primarily responsible for performing the mechanical work process in the industry. In Brazil, they are responsible for consuming more than half of all energy destined for the industrial sector. Thus, any failure of operation in motors of this type is reflected in energy, economic and environmental losses. Among the most common failures is the unbalance of the supply voltages, which can cause total loss of the machine depending on the magnitude of the unbalance. This article exposes a method of classifying balanced and unbalanced supply voltage conditions in a three-phase induction electric motor using a Decision Tree (DT). For this, a database was used with mechanical and electrical variables related to the balanced and unbalanced operation of the motor, divided into classes of different levels of unbalance according to the National Electrical Manufacturers Association (NEMA). Thus, simulations of the decision tree were carried out, where an accuracy greater than 95% was obtained, reinforcing the applicability of this Machine Learning (ML) technique in the classification of phenomena of this nature.*

**Keywords:** *Decision Tree, Machine Learning, Voltage imbalance, Three-phase induction motor.*