

# Multi-Layer Perceptron para Detecção de Falhas em Aerogeradores Baseados na Máquina de Indução com Rotor em Gaiola

Anderson Egberto Cavalcante Salles\* Marcio Eduardo Kreutz\*\*  
Luciano Sales Barros\*\*\*

\* Departamento de Informática e Matemática Aplicada, Universidade Federal do Rio Grande do Norte, RN, (e-mail: andersoncavalcantesalles@gmail.com).

\*\* Departamento de Informática e Matemática Aplicada, Universidade Federal do Rio Grande do Norte, RN, (e-mail: kreutz@dimap.ufrn.br).

\*\*\* Departamento de Sistemas de Computação, Universidade Federal da Paraíba, PB, (e-mail: lsalesbarros@ci.ufpb.br).

---

**Abstract:** In this study a application proposal to develop a classifier using an artificial neural network (ANN) for the problem of detecting internal faults in a wind turbine generator based on an induction machine with a caged rotor, a problem for which there is still no optimal solution. The classifier evaluates a given instance and returns whether the instance comes from a healthy machine or a machine that has a stator coil fault. Synthetic data obtained by simulation was used for training the ANN. The results obtained demonstrate that a simple network with a single intermediate layer already achieves good performance with low computational cost as the memory to store the ANN.

**Resumo:** Nesse estudo é proposto uma aplicação para desenvolver um classificador utilizando uma rede neural artificial para o problema de detecção de falhas internas no gerador de uma turbina eólica baseado na máquina de indução com rotor em gaiola, problema para o qual ainda não existe uma solução otimizada. O classificador avalia uma dada instância e retorna se a instância é proveniente de uma máquina saudável ou de uma máquina que apresenta uma falta em uma dada bobina do estator. Foi utilizado dados sintéticos obtidos por simulação para o treinamento da rede deste modo não foi necessário a utilização de uma máquina real com sensores para extrair os dados de treinamento. Os resultados obtidos demonstram que uma rede simples de uma única camada intermediária já consegue bom desempenho com baixo custo computacional quanto a memória para armazenar a rede.

**Keywords:** Multi-Layer perceptron; Wind turbine; Smart grid; Turn-to-ground fault; Turn-to-turn fault.

**Palavras-chaves:** Redes neurais artificiais; Turbina eólica; Redes elétricas inteligentes; falta espira-espira; falta espira-terra .

---

## 1. INTRODUÇÃO

O gerador de indução com rotor em gaiola de esquilo (SCIG, do inglês *squirrel cage induction generator*) é amplamente aceito em sistemas eólicos, é uma máquina confiável, simples e necessita de pouca manutenção (Royo and Arcega, 2007), no entanto, como todo o sistema real pode apresentar falhas durante a operação.

Percentualmente as falhas mais comuns nas máquinas elétricas podem ser divididas basicamente em: 40% falhas de rolamento, 38% falhas no estator, 10% falhas no rotor e 12% todas as outras falhas (Nandi et al., 2005). (Kia et al., 2013). As falhas no estator estão entre as mais comuns e podem ser subdivididas em cinco categorias, as quais são: espira-espira, entre bobinas, circuito aberto, fase-fase

e espira-terra. Diferentes condições podem contribuir com o aumento dessas falhas, algumas delas são: temperatura, envelhecimento de componentes, umidade e contaminação química (Bonnett and Soukup, 1991). Uma característica importante das falhas no estator é a rápida degradação das condições de operação da máquina, na ordem de alguns minutos, devido à evolução de pontos quentes (Thomson and Fenger, 2001), os quais podem iniciar um ciclo potencialmente destrutivo ao núcleo do estator. Esses danos acarretam prejuízos financeiros importantes tanto pelo tempo de interrupção para a manutenção do gerador como pela necessidade, em alguns casos, da substituição devido ao grave desgaste.

Na tentativa de minimizar custos operacionais muitas vezes é utilizada a manutenção baseada em condições a qual busca aumentar a disponibilidade dos sistemas, porém muitas vezes a avaliação correta das condições de

---

\* Os autores agradecem ao suporte financeiro da CAPES e Salles, A.E.C. agradece a CAPES pela bolsa de mestrado.

operação é uma tarefa complexa, por exemplo, no caso das faltas no estator elas podem partir de um pequeno número de espiras em curto, porém devido ao aquecimento a falta rapidamente pode se estender e afetar mais espiras, logo, a evolução de uma falta inicial para uma moderada e depois uma grave pode ocorrer em um intervalo de alguns minutos. Nesse sentido surge a necessidade do desenvolvimento de melhorias em sistemas de diagnóstico automático para aumentar a confiabilidade da operação, preservar a máquina e diminuir custos de manutenção se torna cada vez mais importante. Para o caso de diagnóstico de faltas em máquinas de indução existem três estratégias bem demarcadas na literatura: i) abordagem baseada em assinatura, a qual tenta obter o estado da máquina observando diferentes sinais no domínio do tempo ou da frequência; ii) abordagem baseada em modelo, essa utiliza modelagem matemática para prever o comportamento das máquinas; iii) abordagem baseada em conhecimento, a qual utiliza técnicas de inteligência artificial para avaliar as condições da máquina tanto em aplicações *on-line* quanto *off-line* (Ali et al., 2019).

Este trabalho propõe utilizar dados das correntes do estator de um SCIG obtidas a partir de simulações do modelo matemático no domínio do tempo o qual permite utilizar parâmetros de diferentes modelos de gerador, gerar uma grande quantidade de dados, ter um controle fino do percentual de dano a bobina, desenvolver com facilidade um conjunto simétrico de instâncias com falta e sem falta para desenvolver a base de dados e utilizando uma rede neural artificial obter um classificador binário que avalie se uma instância é de um gerador saudável ou de uma máquina que apresenta as faltas espira-espira ou espira-terra.

O restante desse artigo está organizando da seguinte forma: Na seção 2 são apresentados estudos no estado-da-arte sobre a detecção de faltas na máquina de indução utilizando aprendizado de máquina. A seção 3 discute as etapas do projeto da rede neural desse trabalho. Já a Seção 4 apresenta a metodologia de avaliação dos resultados obtidos. Finalmente, a Seção 5 apresenta a conclusão do trabalho, discutindo as principais contribuições e as possibilidades de estudos futuros.

## 2. TRABALHOS RELACIONADOS

Na abordagem baseada em conhecimento os algoritmos de inteligência artificial necessitam de uma grande base de dados para poderem treinar e obter um bom desempenho nos seus resultados. Diferentes sinais podem ser utilizados para avaliar as condições da máquina, alguns estudos utilizam o sinal de vibração (Rad et al., 2011), mas nesse caso existe a necessidade da adição de sensores de vibração, outras estratégias usam a análise da assinatura de corrente do motor (MCSA, do inglês *Motor current Signature Analysis*) a qual examina o espectro de frequência das correntes, visto que algumas componentes frequenciais se alteram quando ocorre uma falha, no entanto, o diagnóstico utilizando essa técnica apresenta algumas limitações para cargas baixas, pois não existem novas componentes de frequência relacionadas as faltas e sim alteração de componentes que normalmente já existem, logo, pode ocorrer problemas relacionados a falso positivo, pois a variação de carga perturbar as mesmas componentes relacionadas as

faltas (Royo and Arcega, 2007). (Joksimovic and Penman, 2000). Também existem métodos que observam mais de um sinal para concluir o diagnóstico, os sinais mais utilizados são a corrente do estator e a vibração da máquina, mas outros sinais podem ser analisados como: tensão, potência, temperatura e emissão acústica (Ali et al., 2019).

Além dos diferentes tipos de sinais que podem ser utilizados também são aplicadas diferentes técnicas de inteligência artificial em análise de faltas como: Máquinas de vetores de suporte, máquina de vetores de suporte por mínimos quadrados, redes neurais convolucionais, métodos híbridos de redes neurais artificiais combinadas com lógica Fuzzy, técnicas associando processamento de sinais com Transformada Wavelet Packet Estacionária Otimizada (Op-SWPT, do inglês *Optimized Stationary Wavelet Packet Transform*), entre outras (Vieira et al., 2016). (Ali et al., 2019). Mostrando a grande variedade de possibilidades na área dado que ainda possui bastante espaço para evoluir em diversas frentes, desde as técnicas de aprendizado utilizadas até os tipos de sinais para caracterizar as faltas e a severidade.

As redes neurais artificiais são uma das abordagens de aprendizado de máquina mais conhecidas, são capazes de reconhecer características dos sinais, identificar e diagnosticar falhas. Na identificação de faltas no estator da máquina de indução as redes neurais apresentam robustez ao ruído (Chow and Yee, 1991), (Ghate and Dudul, 2010), podem utilizar diferentes tipos de sinais (Ali et al., 2019), podem ser associadas a outras técnicas de aprendizado de máquina (Santos et al., 2012) e possuem uma implementação simples.

Esse estudo propõe desenvolver um classificador utilizando redes neurais artificiais para avaliar faltas no estator dos geradores eólicos baseados na máquina de indução com rotor em gaiola. O classificador deve identificar se as correntes do estator são de um gerador com o estator em falta ou de um gerador saudável. Os dados utilizados para treinar a rede são obtidos por meio de simulação, a qual permite gerar dados com grande quantidade e diversidade. Por fim, os resultados da rede são avaliados.

## 3. PROJETO DE MULTI-LAYER PERCEPTRON

Nessa seção é comentado com mais detalhes as etapas do projeto do perceptron multicamadas (MLP, do inglês *Multi-Layer perceptron*) desde a obtenção dos sinais até a seleção dos hiperparâmetros.

### 3.1 Aquisição dos dados

Neste trabalho os dados utilizados para treinar o perceptron multicamadas são obtidos por meio de simulações no Matlab/Simulink. Os sinais utilizados para o treinamento são as correntes do estator, os quais já são habitualmente mensurados em aplicações reais não necessitando de novos sensores para obtê-los, essa abordagem também não necessita de medições invasivas e possibilita o monitoramento remoto. A simulação é composta pelo SCIG, que pode apresentar faltas com duas origens, a falta espira-espira, a qual ocorre quando as espiras de uma mesma bobina estão em curto, e a falta espira-terra, a qual ocorre entre as espiras e a carcaça do gerador.

As Figuras 1 e 2 ilustram as faltas espira-espira e espira-terra, respectivamente. Em cada caso a bobina é subdividida em dois trechos distintos, um primeiro em que o curto foi estabelecido e um segundo ainda saudável, essas partes interagem entre si e com as outras bobinas presentes na máquina e cada trecho possui a sua força contraeletromotriz correspondente. As figuras também apresentam as correntes em cada subdivisão. A corrente  $i_{pc}$  é a corrente de fase da bobina. Já a corrente  $i_{cs}$  é a corrente que circula no condutor. Por último, a corrente  $i_{fc}$  é a corrente de falta, a qual é associada a uma resistência de falta ( $R_{cc}$ ). O banco de dados é composto pelas correntes  $i_{pc}$  de cada fase.




Figura 1. Falta espira-espira.




Figura 2. Falta espira-terra.

A simulação também apresenta a turbina eólica, o controle do lado da rede, o controle do lado do gerador e os conversores que também contribuem para o desgaste das espiras do estator, pois o baixo tempo de comutação, na ordem de microssegundos, leva a distribuições não lineares de tensão resultando em um estresse até dez vezes maior comparado a alimentação de linha (Joksimovic and Penman, 2000). Mais detalhes sobre a simulação são apresentados em Salles et al. (2019).

A escolha de um modelo de aprendizado de máquina se faz necessário, pois desenvolver um algoritmo tradicional para inferir se um dado sinal apresenta uma falta é demasiadamente complexo, uma vez que é necessário observar diferentes cenários operacionais e identificar todas as condições que diferenciam um sinal de uma máquina saudável de outra em falta, com esses aspectos certamente o algoritmo ficaria muito extenso dificultando o entendimento e a manutenção em aplicações reais, já modelos de aprendizado de máquina aprendem com os dados e retornam um classificador o qual pode ser facilmente embarcado em um sistema digital. Devido aos problemas relacionados ao desenvolvimento tradicional esse trabalho concentra-se em usar uma MLP para desenvolver um modelo que capture as características das variações nas correntes elétricas do estator quando o gerador é submetido as faltas e assim inferir com boa precisão se um dado sinal é de uma máquina em falta ou não.

Para gerar as instâncias foram utilizados dois métodos, o primeiro foi mudar diferentes parâmetros da simulação, por exemplo, a resistência associada à falta ( $R_{cc}$ ), quando a  $R_{cc}$  é infinita significa que o curto não foi estabelecido, ou seja, máquina é saudável e quando a  $R_{cc}$  é igual a zero indica que a isolamento foi completamente degradada,

nos casos simulados a  $R_{cc}$  variou de  $0,1 \Omega$  até  $1,5 \Omega$ . Também foi avaliado diferentes níveis de dano na bobina, em casos de falha o intervalo percentual de dano a bobina variou entre 1% e 10%. A velocidade do vento variou entre 70% até 100% da plena carga. A frequência dos conversores variou em uma faixa de 1kHz até 10kHz. Por último, foram utilizados dois conjuntos de parâmetros para caracterizar o gerador elétrico, tendo as resistências e indutâncias diferentes. A base tem um total de quinhentas instâncias em que duzentas e cinquenta são de instâncias da classe sem falha e duzentas e cinquenta são da classe com falha. A classe com falha é composta de cento e vinte e cinco instâncias com a falta espira-espira e cento e vinte e cinco instâncias com a falta espira-terra. O projeto é voltando a manutenção dos geradores, sendo assim o classificador deve identificar se existe a falha, ou seja, esse classificador não distingue se a falha é espira-espira ou espira-terra, apenas se a instância é proveniente de uma máquina saudável ou não.

O segundo método utilizado para gerar as instâncias foi variar o instante em que a falta ocorre, assim é possível detectar faltas já na janela de tempo em que elas ocorrerem. A Figura 3 apresenta o sinal de um gerador saudável. A Figura 4 apresenta uma instância na qual a falta ocorreu no início da janela de tempo. Já na Figura 5 a falta inicia em um quarto do tempo total da amostra. Na Figura 6 a falta ocorre na metade do intervalo de tempo. Por último, Figura 7 a falta inicia em três quartos da janela de tempo. O intervalo de tempo total de cada amostra é de 0,2 segundos.




Figura 3. Instância de uma máquina saudável.




Figura 4. Falta no instante inicial da janela de tempo.




Figura 5. Falta iniciada em um quarto da janela de tempo.




Figura 6. Falta iniciada na metade da janela de tempo.




Figura 7. Falta iniciada na metade da janela de tempo.

### 3.2 Multi-Layer Perceptron

As MLP consistem em um método baseado em otimização, com inspiração biológica, o algoritmo mais comum de treinamento na busca pela hipótese que descreve os dados recorre ao gradiente descendente na otimização do erro entre a resposta da rede e o rótulo de uma dada instância de treinamento correspondente. Uma MLP é formada por um conjunto de camadas de perceptrons, organizadas em uma camada de entrada, camada intermediária, que pode conter várias camadas no seu interior e uma cama de saída. Uma dada camada é sempre totalmente conectada com a camada subsequente e, em geral, todas as camadas costumam ter um neurônio especial chamada de neurônio de viés, com exceção da camada de entrada, o qual permite alterar o limiar de disparo do perceptron. A Figura 8

apresenta uma ilustração de uma MLP genérica, omitindo os pesos.




Figura 8. Ilustração da arquitetura de uma *multi-Layer perceptron*.

Uma das vantagens do uso da MLP vem da prova que com apenas uma camada oculta é possível, apresentando o número suficiente de neurônios, aproximar qualquer função contínua com dada precisão (Hornik et al., 1989). Uma outra vantagem é a capacidade de generalização para dados nunca vistos. Quando se pensa em uma aplicação real a MLP é considerada de bom custo-benefício quanto a utilização de *hardware*, apresenta boas taxas de acerto e pequeno tempo de resposta (Vieira et al., 2016), (Kavana and Neethi, 2018). Pode ser facilmente embarcada em sistemas digitais como os conversores, já muito utilizados na indústria, conferindo a eles uma proteção adicional (de Oliveira et al., 2013).

### 3.3 Pré-processamento

Na primeira etapa do pré-processamento os dados passaram por um processo de amostragem o qual visa aproximar os dados da simulação de dados reais que também passam por processos de amostragem para serem armazenados e utilizados em sistemas digitais. O processo de amostragem também é importante para diminuir redundâncias e auxiliar no armazenamento dos dados.




Figura 9. Sinal após o processo de amostragem.

Na segunda etapa do pré-processamento dos dados foi utilizada a análise de componentes principais (PCA, do inglês *Principal Component Analysis*), que busca projetar

os dados em um espaço de dimensionalidade menor. Ao reduzir a dimensionalidade dos dados é possível evitar problemas relacionados a maldição da dimensionalidade, auxiliar no desenvolvimento de um classificador mais simples e acelerando o processo de treinamento. Como boa prática é aconselhado selecionar uma dimensão que apresente por volta de 95% de variância. A Figura 10 demonstra que as doze primeiras componentes principais das amostras guardam 95% da informação da variância dos dados.

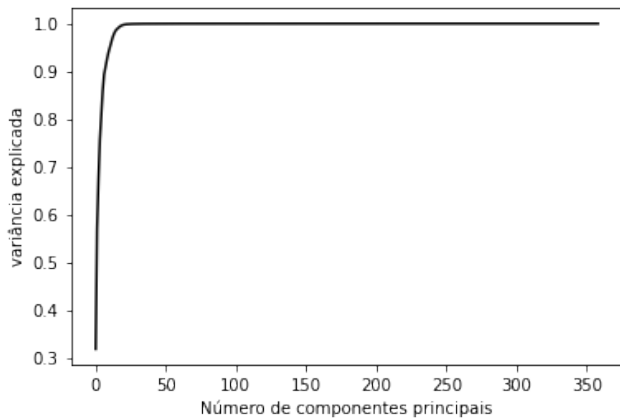


Figura 10. Curva da variância explicada em relação a dimensão.

### 3.4 Hiperparâmetros

Um ponto desfavorável no projeto da MLP é a escolha dos hiperparâmetros, uma vez que existe um espaço de busca muito grande para os hiperparâmetros e a escolha desses influenciam de modo muito diferente no resultado final da rede. Na busca de contornar esse obstáculo, esse trabalho, utilizou da função GridSearchCV do Scikit-Learn o qual a partir de uma lista pré-definida pelo usuário faz uma busca exaustiva dos melhores hiperparâmetros para a rede. Depois desse estágio houve pequenos ajustes manuais.

Hiperparâmetros utilizados:

- (1) Número de camadas: Foi utilizada uma camada oculta contendo 8 neurônios.
- (2) Função de ativação: A função de ativação utilizada foi a Elu (Clevert et al., 2015). Outras funções foram avaliadas como: tangente hiperbólica, unidade linear retificada (ReLU) e Sigmoid. A função Elu é uma função de ativação não saturada o que também evita problemas dos gradientes *vanishing/exploding*.
- (3) Otimizador: O otimizador escolhido foi o Adam (Kingma and Ba, 2014), um método baseado no gradiente descendente estocástico.
- (4) Taxa de aprendizado: A taxa de aprendizado limita a atualização dos pesos na rede, foi definida com um valor igual a 0.001.
- (5) Épocas: Foi utilizado para o treinamento 350 épocas.

A camada de saída é construída por uma função *softmax*, a saída de cada neurônio dessa camada corresponde a probabilidade estimada de cada classe.

## 4. RESULTADOS

Nessa seção são apresentados os resultados e a avaliação do desempenho da MLP para classificar as faltas.

### 4.1 Validação do modelo

Para validar o modelo foi utilizada a técnica de validação cruzada *k-fold*, um método bastante utilizado na área de aprendizado de máquina. Nessa estratégia o banco de dados é subdividido aleatoriamente em  $k$  partes de tamanhos iguais, quando possível, os subconjuntos de dados apresentam instâncias de cada classe na proporção do conjunto original. Durante o procedimento é selecionado um subconjunto  $k_i$  e o mesmo é retirado para a validação do modelo, e os  $k-1$  outros subconjunto são utilizados para o treinamento, o processo de selecionar  $k_i$  para etapa de validação e treinar os outros  $k-1$  subconjuntos é repetido  $k$  vezes até completar todos os dados e ao final de todas as etapas é calculada a acurácia. Este método é bastante utilizado em estatística, uma vez que garante que a organização dos dados não influencia nos resultados obtidos (Sá et al., 2019).

Essa técnica foi utilizado em três casos. No primeiro caso foi utilizada a base completa, já no segundo foi utilizada apenas instâncias sem falta e com falta espira-espira, por fim, no terceiro caso foi utilizado as instâncias sem falta e com falta espira-terra. Nesse trabalho foi utilizado  $k = 25$  em todos os casos. Dos resultados obtidos pela validação cruzada foi calculado a média amostral, o desvio padrão amostral e o intervalo de confiança ao nível de confiança de 95% para a acurácia dos resultados.

Tabela 1. Resultados.

Base de dados	Média	Desvio Padrão	Intervalo de Confiança
Primeiro Caso	81,33%	3,69%	[82,85%; 79,80%]
Segundo Caso	83,47%	3,19%	[84,78%; 82,15%]
Terceiro Caso	77,18%	5,24%	[79,34%; 75,01%]

### 4.2 Análise de resultados

Os resultados estão na casa dos 80% de acurácia. Isto pode ser caracterizado como um bom desempenho observando a simplicidade do modelo, que a rede não observa outros sinais além da corrente do estator, logo, não é utilizado sensores adicionais, não foram necessárias muitas épocas de treinamento, ou seja, não apresenta um custo computacional elevado para o treinamento e ainda com uma base na qual a classe com falta possui instâncias em que em parte da janela de tempo não estão afetadas pela falta, por exemplo, a instância da Figura 7. Também pela simplicidade e boa acurácia o modelo pode ser embarcado em aplicações reais sem a necessidade de *hardware* de alto custo.

## 5. CONCLUSÃO

Este estudo apresenta dois tópicos de discussão, primeiro o desenvolvimento de modelos matemáticos para simular faltas em um SCIG, pois várias estratégias de aprendizado de máquina necessitam de uma boa quantidade de dados e com boa diversidade para poderem ser representativos

das diferentes condições de operação. Na primeira etapa do projeto da rede é tratado a obtenção de dados via simulação e a diversidade que esses dados sintéticos podem apresentar. O aumento do poder computacional proporciona simulações cada vez mais próximas de sinais reais, assim existe a possibilidade de no futuro existir grandes bases de dados para classificar diferentes faltas em sistemas de elétricos de potência havendo também a possibilidade de utilizar bases de dados mistas contendo dados reais e dados sintéticos.

O segundo ponto é apresentar as características de utilização da MLP como classificador de faltas. O projeto da rede é relativamente simples comparado a desenvolver um algoritmo tradicional que possa fazer a mesma classificação. A MLP também apresenta a capacidade de generalizar seus resultados para dados nunca vistos, o que é importante ao pensar em aplicações reais, também possui baixo custo computacional para armazenar a rede e apresenta uma acurácia relativamente boa. Nesse trabalho o classificador utilizando MLP obteve uma acurácia na casa de 80%.

Como trabalhos futuros é possível evoluir em algumas linhas como a classificação do quanto a bobina está degradada, a comparação com outros modelos de aprendizado de máquina, a inclusão de dados reais na base, incluir dados que possuem perturbações, mas que não apresenta falta, são algumas das possibilidades.

#### AGRADECIMENTOS

Os autores agradecem o apoio do DIMAP/UFRN.

#### REFERÊNCIAS

- Ali, M.Z., Shabbir, M.N.S.K., Liang, X., Zhang, Y., and Hu, T. (2019). Machine learning-based fault diagnosis for single-and multi-faults in induction motors using measured stator currents and vibration signals. *IEEE Transactions on Industry Applications*, 55(3), 2378–2391.
- Bonnett, A. and Soukup, G.C. (1991). Cause and analysis of stator and rotor failures in 3-phase squirrel cage induction motors. In *Conference Record of 1991 Annual Pulp and Paper Industry Technical Conference*, 22–42. IEEE.
- Chow, M.y. and Yee, S.O. (1991). Methodology for on-line incipient fault detection in single-phase squirrel-cage induction motors using artificial neural networks. *IEEE Transactions on Energy Conversion*, 6(3), 536–545.
- Clevert, D.A., Unterthiner, T., and Hochreiter, S. (2015). Fast and accurate deep network learning by exponential linear units (elus). *arXiv preprint arXiv:1511.07289*.
- de Oliveira, Á.G., Pontes, R.S.T., and de Sá Medeiros, C.M. (2013). Neural network used to stator winding interturn short-circuit fault detection in an induction motor driven by frequency converter. In *2013 BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence*, 459–464. IEEE.
- Ghate, V.N. and Dudul, S.V. (2010). Optimal mlp neural network classifier for fault detection of three phase induction motor. *Expert Systems with Applications*, 37(4), 3468–3481.
- Hornik, K., Stinchcombe, M., and White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359–366.
- Joksimovic, G.M. and Penman, J. (2000). The detection of inter-turn short circuits in the stator windings of operating motors. *IEEE Transactions on Industrial Electronics*, 47(5), 1078–1084.
- Kavana, V. and Neethi, M. (2018). Fault analysis and predictive maintenance of induction motor using machine learning. In *2018 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT)*, 963–966. IEEE.
- Kia, M.Y., Khedri, M., Najafi, H.R., and Nejad, M.A.S. (2013). Hybrid modelling of doubly fed induction generators with inter-turn stator fault and its detection method using wavelet analysis. *IET Generation, Transmission & Distribution*, 7(9), 982–990.
- Kingma, D.P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Nandi, S., Toliyat, H.A., and Li, X. (2005). Condition monitoring and fault diagnosis of electrical motors—a review. *IEEE transactions on energy conversion*, 20(4), 719–729.
- Rad, M.K., Torabizadeh, M., and Noshadi, A. (2011). Artificial neural network-based fault diagnostics of an electric motor using vibration monitoring. In *Proceedings 2011 International Conference on Transportation, Mechanical, and Electrical Engineering (TMEE)*, 1512–1516. IEEE.
- Royo, J. and Arcega, F. (2007). Machine current signature analysis as a way for fault detection in squirrel cage wind generators. 383–387.
- Sá, B.A., Barros, C.M., Siebra, C.A., and Barros, L.S. (2019). A multilayer perceptron-based approach for stator fault detection in permanent magnet wind generators. In *2019 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America)*, 1–6. IEEE.
- Salles, A.E.C., Barros, L.S., de Oliveira, G.P., Barbosa, D., and Barros, C.M.V. (2019). Internal fault analysis of squirrel cage induction machine-based wind turbines. In *2019 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America)*, 1–6. IEEE.
- Santos, F.M.d.C., Silva, I.N.d., and Suetake, M. (2012). Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução-uma visão geral. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, 23, 553–569.
- Thomson, W.T. and Fenger, M. (2001). Current signature analysis to detect induction motor faults. *IEEE Industry Applications Magazine*, 7(4), 26–34.
- Vieira, R.G., Medeiros, C.M., and Silva, E.T. (2016). Classification and sensitivity analysis to detect fault in induction motors using an mlp network. In *2016 International Joint Conference on Neural Networks (IJCNN)*, 796–802. IEEE.