



# INTELIGÊNCIA ARTIFICIAL APLICADA NA OPERAÇÃO E MANUTENÇÃO DE AEROGERADORES: ESTUDO EXPLORATÓRIO

Mateus Guilherme Melo de Souza<sup>1</sup>, Brennda Louyse Conceição de Moura<sup>1</sup>, Mario Orestes Aguirre González<sup>1</sup>,  
David Cassimiro de Melo<sup>1</sup> e Rafael Monteiro de Vasconcelos<sup>1</sup>

<sup>1</sup> Programa de Pós-Graduação em Engenharia de Produção – UFRN  
Grupo de Pesquisa Cri-Ação: Renewable Energy

Avenida Senador Salgado Filho, 3000 - Lagoa Nova, Natal - RN, Brasil

[mateusguil.melo@gmail.com](mailto:mateusguil.melo@gmail.com), [mario@ct.ufrn.br](mailto:mario@ct.ufrn.br), [davidcassi@yahoo.com.br](mailto:davidcassi@yahoo.com.br); [rafaelmonteirov@yahoo.com.br](mailto:rafaelmonteirov@yahoo.com.br)

## Resumo

O aquecimento global proveniente do efeito estufa fez acender na comunidade internacional a necessidade de mudança na matriz energética mundial em direção ao maior uso de fontes renováveis para geração de energia elétrica. Nesse cenário, a energia eólica vem em expansão global. Como essa indústria depende de um equipamento central, o aerogerador, a operação e manutenção é fundamental para a obtenção de altos índices de fator de capacidade. A aplicação de novas tecnologias, como a Inteligência Artificial, na operação e manutenção de aerogeradores pode contribuir para esse objetivo. Este estudo tem como objetivo identificar como está sendo a aplicação de Inteligência Artificial na operação e manutenção de aerogeradores. Para tanto, foi realizada uma pesquisa exploratória utilizando o método de revisão bibliográfica sistemática com a análise de 51 artigos. Como resultado, foram encontradas aplicações tanto para o aerogerador completo, como para equipamentos específicos como *gearbox* e gerador. Os trabalhos também apresentaram resultados satisfatórios em termos de tempo de previsão antes da ocorrência da falha, acurácia na classificação de falhas e economia percentual nas atividades de manutenção.

## Abstract

The global warming made the international community aware of the necessity of changes in the global energy matrix towards sustainable energy generation. In this scenario, the wind energy industry has been growing globally. As this industry depends extensively on a single equipment, the wind turbine, the operations and maintenance activities are fundamental in the strive for a higher capacity factor index. The application of new technologies such as Artificial Intelligence may contribute to this



objective. Hence, this paper has the main goal of identify how is the application of artificial intelligence in the wind turbines operations and maintenance activities are being held. In order to do so, an exploratory research through the systematic literature review method was undertaken with the analysis of 51 papers. As a result, either applications for the wind turbine as a whole or for specific pieces of equipment such as gearbox and generator were found. The articles selected also demonstrated good results in terms of early fault identification, accuracy in fault identification and percentual savings in maintenance activities.

## 1. Introdução

A geração de energia elétrica é um tópico essencial para o desenvolvimento socioeconômico, sendo papel central na economia de alguns países (GONZÁLEZ; GONÇALVES; VASCONCELOS, 2017; LIMA; FERREIRA; VIEIRA, 2013). Considerando a geração da energia elétrica, há a preocupação na comunidade internacional no que tange a matriz energética mundial, principalmente na busca por uma matriz sustentável. Essa preocupação foi expressa no acordo de Paris em 2015 que, para mitigar os efeitos do aquecimento global, teve como discussão o direcionamento da matriz energética mundial em direção ao setor de energias renováveis.

A energia eólica tem papel fundamental nesse crescimento. De acordo com o IRENA (2018), a busca por uma matriz energética com maior participação de fontes renováveis vem crescendo e a prospecção até 2050 é que a energia eólica representará cerca de 36% de toda a produção de energia elétrica, sendo a fonte mais utilizada.

Diante desse cenário, o Brasil se destaca como maior e mais promissor mercado da América Latina (GONZÁLEZ; GONÇALVES; VASCONCELOS, 2017). Com mais de 14 GW de capacidade instalada, o país é o 8º do mundo em capacidade instalada de energia eólica (ABEEÓLICA, 2019). Além disso, só em 2017, a indústria de energia eólica atraiu cerca de 11,4 bilhões de reais em investimentos, gerando 30 mil empregos, além de ser estratégica na produção de energia principalmente para a região nordeste, que enfrenta longos anos de secas que prejudicam a produção de energia por meio das hidrelétricas (ABEEÓLICA, 2018). Dessa forma, o aumento de competitividade dessa indústria é importante não só por questões ambientais, como também econômicas para o Brasil.



Nesse contexto, as atividades de operação e manutenção (O&M) representam uma parcela importante nos custos relacionados a investimentos em energia eólica, e dessa forma, melhorias nessa área podem ter impacto direto na competitividade do setor. De acordo com VESELY (2017), os custos de O&M são responsáveis por cerca de 30% de *Levelized Cost Per KWh* (indicador que mede o custo do ciclo de vida do projeto pela sua produção de energia elétrica).

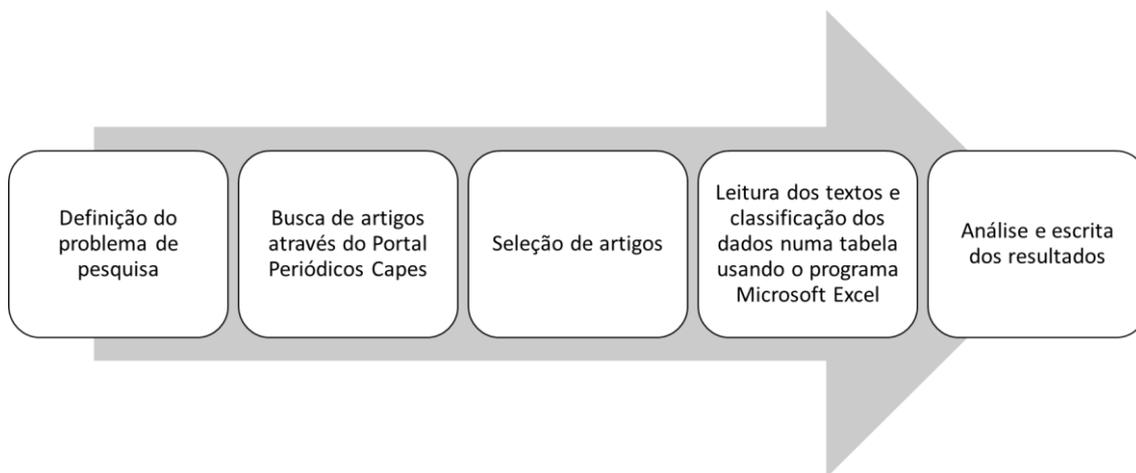
Na busca por aumento de competitividade, os adventos trazidos pela indústria 4.0, como a inteligência artificial, estão revolucionando vários setores, o que não poderia ser diferente na energia eólica. Empresas como GE, Siemens e SAP vêm investindo em pesquisa e desenvolvimento nessa área, com foco relacionado a prevenção de falhas utilizando *Machine Learning* (VESELY, 2017). Além disso, a fabricante MHI Vestas anunciou o uso de um sistema de aquisição de dados 600 vezes mais veloz do que o sistema SCADA tradicional em seu *MVOW Smart Turbine portfolio* (MHI VESTAS, 2018). O uso de técnicas de *Big-data* para exploração eficiente dessas grandes quantidades de dados é mais um motivo para acreditar que as ferramentas da indústria 4.0 estão vindo pra ficar na manutenção de aerogeradores. Diante desse contexto, a pesquisa traz a seguinte problemática: **Como está sendo a aplicação de inteligência artificial na O&M de aerogeradores?**

Dessa forma, esse trabalho tem como objetivo identificar as principais aplicações de inteligência artificial na O&M de aerogeradores. O artigo está dividido em 5 seções, sendo a primeira a introdução. A segunda descreve o método da pesquisa, mostrando o passo-a-passo realizado na revisão bibliográfica sistemática. A terceira sessão apresenta o Estado da Arte relacionando inteligência artificial na operação e manutenção de aerogeradores. Por fim, tem-se os resultados, na sessão 4, e as conclusões e recomendações, última sessão.

## 2. Método de pesquisa

O método de pesquisa ou procedimento técnico utilizado para esse trabalho é a revisão bibliográfica sistemática. A revisão bibliográfica sistemática é um método de pesquisa confiável que apresenta seus resultados através de conhecimento estruturado e não tendencioso sobre o tema escolhido (SAMPAIO; GONZÁLEZ, 2017). A pesquisa foi conduzida em 5 estágios, como mostrado na Figura 1.

Figura 1: Estágios da pesquisa.



O primeiro estágio teve como objetivo encontrar as palavras-chave associadas ao tema através da leitura de teses e dissertações, definindo a problemática de pesquisa como: “como está sendo a aplicação de inteligência artificial na operação e manutenção de aerogeradores?”. A partir de então, com o conhecimento inicial sobre as palavras-chave do tema, foi iniciado o segundo estágio, que consistiu na busca de artigos científicos através da base de dados do Portal Periódicos da Capes, portal que congrega 130 bases referenciais, incluindo *Scopus*, *Web of Science* e *Science Direct*, além de outros conteúdos como bases dedicadas ao estudo de patentes, livros, enciclopédias e normas técnicas. A busca foi realizada utilizando a combinação de palavras-chave relacionadas a inteligência artificial e energia eólica mostrada no Quadro 1. Foram buscados somente artigos no idioma inglês.

Quadro 1: Combinação de palavras-chave utilizadas para obtenção dos artigos.

Key Words		
AI	AND	WIND ENERGY
Artificial Intelligence		Wind Energy
Neural Networks		Wind Power
Deep Learning		Wind Turbines
Machine Learning		Wind Farms
Data Mining		Wind Park
IOT		

Na terceira fase, foram lidos os resumos dos trabalhos encontrados na busca, descartando os que não tinham relação com o tema e os artigos repetidos, chegando num total de 51 artigos, esses foram então lidos inteiramente e suas informações relevantes para análise de conteúdo foram coletadas e organizadas numa tabela usando o programa Microsoft Excel. Por fim, essas informações



foram analisadas e usadas para apresentação das principais aplicações de inteligência artificial na operação e manutenção de aerogeradores, de forma a responder a problemática de pesquisa.

### **3. Estado da arte em inteligência artificial na operação e manutenção de aerogeradores**

#### **3.1 Inteligência artificial**

A Inteligência artificial (IA) é a habilidade de uma máquina ou artefato de executar funções que caracterizam o pensamento humano. Em computação, esse termo é aplicado a programas e sistemas que podem efetuar tarefas mais complexas do que programação direta, ainda que distante do grau de complexidade do pensamento humano (KALOGIROU, 2002). Ela busca imitar o pensamento humano com o intuito de desenvolver sistemas inteligentes para a solução de problemas complicados. A capacidade de processamento do computador em executar cálculos matemáticos milhões de vezes mais rápido do que a capacidade humana, por vezes, faz algumas áreas da IA terem performance superior ao cérebro humano. A IA é aplicada em vários campos como no design de produtos, na contabilidade financeira, economia, medicina (JHA *et al.*, 2017).

O aprendizado de máquina (*machine learning*) vem crescendo bastante com as aplicações de inteligência artificial aliada a internet das coisas (*IoT*), impulsionando avanços significativos na indústria (VESELY, 2017). No contexto da energia eólica, as ferramentas de inteligência artificial vêm sendo utilizadas em diversas aplicações. Jha *et al.* (2017), ressaltam que a maioria das pesquisas relacionando IA e energia eólica focam na previsão de velocidade do vento e geração de energia, no entanto, outras áreas de conhecimento como projeto do sistema de geração de energia, otimização de riscos, e diagnóstico de falha também têm representação na pesquisa.

Os métodos de inteligência artificial que mais aparecem na literatura envolvendo a operação e manutenção de aerogeradores são:

- **Redes neurais:** De maneira geral, é uma máquina projetada para a modelagem de tarefas particulares exercidas pelo cérebro humano. De forma mais específica, é um processador constituído de unidades de processamento simples com propensão natural de armazenar conhecimento, após passar por um processo de aprendizagem, aonde as conexões entre os neurônios, conhecidas como pesos sinápticos, armazenam o conhecimento adquirido do ambiente (HAYKIN, 1999). Nos trabalhos selecionados por essa pesquisa, esses métodos são usados predominantemente em clusterização de dados, modelagem e classificação.

- Máquinas de vetores de suporte: É um método que mapeia um banco de dados em um espaço de várias dimensões e então o separa através de planos otimizados, permitindo assim uma classificação ótima dos dados (VAPKIN, 1998).
- Árvores de decisão: São métodos de aprendizado supervisionado que separam decisões complexas em uma série de decisões simples divididas em nós, com o objetivo de minimizar ao máximo o erro de previsão, dessa forma, em cada nó, a variável de entrada que mais minimiza o erro é a candidata selecionada a passar para o nó seguinte. Portanto, a previsão acontece ao caminhar do nó raiz até o nó folha, que entrega o output do método. (MAZIDI; TJERNBERG; BOBI, 2017).
- Lógica fuzzy: Em inteligência artificial, a lógica fuzzy tenta imitar o pensamento humano explorando modelos de raciocínio aproximados em vez de exatos, trabalhando com variáveis que variam entre 0 (totalmente falso) e 1 (totalmente verdadeiro) em vez de variáveis binárias (AZADEGAN *et al.*, 2011). Essa lógica é muitas vezes aplicada na construção de *Expert Systems*. Como esses tipos de sistemas se baseiam em regras de especialistas humanos, ele pode conter expressões vagas que muitas vezes são modeladas melhor pela lógica *fuzzy* do que pela lógica booleana (ZADEH, 1983).

### 3.2 Aplicações de IA para operação e manutenção de aerogeradores

De acordo com Liton Hossain, Abu-Siaba e Muyeen (2018), a inteligência artificial pode ser aplicada na operação e manutenção de aerogeradores em atividades de monitoramento da condição dos equipamentos, através de métodos como Redes Neurais (ANN), *expert systems*, *space vector modulations* e *fuzzy logic systems*. Alguns exemplos desses trabalhos são descritos a seguir:

- **Sistemas de monitoramento da condição e diagnóstico de falha:** São sistemas criados para monitorar a saúde do equipamento e, em alguns casos, realizar o diagnóstico da falha que eles podem apresentar antes que elas ocorram. Yang, Huang e Yang (2015), integram *Auto-associative Neural Networks* (AANN) com Gráficos de controle *Hotelling T<sup>2</sup>* para detecção de falhas em turbinas eólicas, estudando vários parâmetros de uma só vez. Bangalore *et al.* (2017) integrou o método *NARX Artificial Neural Network* e *Mahalanobis Distance* para construir um sistema de monitoramento da condição para *gearboxes* de turbinas eólicas.



Wang *et al.* (2017) usou *Deep Neural Networks (DNN)*, *EWMA control charts* e *Dropout algorithm* para identificar 5 falhas diferentes em *gearboxes* de turbinas eólicas baseado em dados de pressão do lubrificante.

Além de sistemas de monitoramento da condição e detecção de falha, outros tipos de aplicações também auxiliam na operação e manutenção de aerogeradores:

- **Sistemas de clusterização:** Sistemas que separam as turbinas em clusters de performance para auxiliar no planejamento da manutenção. Em seus trabalhos Hameed e Wang (2012) e Hameed e Wang (2013), utilizaram *Self-organizing Maps Neural Networks (SOMNN)* e *Back-programation Neural Networks (BPNN)* para separar as turbinas de um parque eólico em clusters de performance similar e previsão de potência das turbinas de forma a criar uma estratégia de manutenção ótima. Ao cruzar os dados reais de potência de saída com a sua previsão, é possível identificar as turbinas que estão operando abaixo da performance desejada, podendo assim criar estratégias de manutenção para todo o cluster que elas pertencem.
- **Estudo de indicadores:** Estudo de indicadores de manutenção que auxiliam na sua otimização e controle. Astolfi *et al.* (2015) utilizou *data-mining* para desenvolver dois índices de manutenção: *Global Malfunctioning Index* e o *Detail Malfunctioning Index*. Esses índices foram correlacionados consistentemente com *downtime* (tempo de inatividade), disponibilidade contratual, e disponibilidade de energia e podem ser exportados para qualquer turbina eólica, podendo ser utilizados como meio de avaliação das atividades de operação e manutenção;
- **Robos de inspeção:** Wang *et al.* (2013) usou *Redes Neurais* para criar um algoritmo de planejamento da trajetória para um robô de inspeção de pás, obtendo um caminho ótimo ao redor da pá.
- **Controle tolerante a falha:** Sistemas que ao prever a falha ativam redundâncias para evitar danos ou paradas no sistema. Amina *et al.* (2017), simularam uma turbina eólica, usam um algoritmo baseado em lógica fuzzy para prever a falha em disjuntores abertos no sistema ligado ao gerador (*Doubly Fed Induction Generator*) e ativar suas respectivas redundâncias antes da falha ocorrer. Chen,



Fu e Yang (2018) utilizaram *convolutional neural networks (deep learning)* aliados a internet das coisas (sensores) para criar um sistema tolerante a falha para sensores e o *phase break* e substituindo-os sem problemas em caso da falha ser detectada.

- **Sistemas de inspeção:** Sistemas que realizam inspeção de forma remota. Gantasala, Luneno e Aidanpää (2017), usaram *Back Programation Neural Network* (BPNN) e Método dos elementos finitos para simular o acúmulo de peso em pequenas vigas, ressaltando que isso poderia ser uma possível aplicação para detecção de peso extra em pás eólicas. Jiménez, Gomez Muñoz e García Márquez (2018) criaram uma abordagem para detecção e diagnóstico de delaminação em Pás eólicas usando técnicas de machine learning através de dados de ondas guiadas, obtendo melhores resultados com *Weighted K-nearest neighbours* (WKNN) e Redes Neurais (ANN). Jiménez *et al.* (2019) também usaram técnicas de machine learning em pás, porém o estudo foi dedicado a detecção de acúmulo de gelo, atingindo melhores resultados com *Support Vector Machine* (SVM) e *K-Nearest Neighbours* (KNN).

#### 4. Resultados

Dentre os estudos considerados para essa pesquisa, 2 deles são trabalhos informativos ou de revisão bibliográfica (MARUGÁN *et al.*, 2018; VESELY, 2017). Nos trabalhos de natureza aplicada a utilização de métodos de inteligência artificial na operação e manutenção de aerogeradores, foram abordados tanto equipamentos pontuais das turbinas eólicas, como também toda a turbina como um único equipamento. O Quadro 2 associa os autores aos equipamentos que foram objetivo de estudo em seus trabalhos. É importante ressaltar que alguns autores focaram em mais de um equipamento.

Quadro 2: Relação de equipamentos abordados e os autores dos trabalhos.

Equipamentos	Autores
Pás	Wang <i>et al.</i> (2013); Gantasala, Luneno e Aidanpää (2017); Regan, Beale e Inalpolat (2017) ; Lu <i>et al.</i> (2018); Jiménez, Gómez Muñoz e García Márquez (2018); Jiménez <i>et al.</i> (2019)
<i>Gearbox</i>	Elhor <i>et al.</i> (1999); Wang (2013); Wu e Song (2016); Str e Barszcz (2016); Yang, Wang e Zhong (2016); Bangalore <i>et al.</i> (2017); Wang <i>et al.</i> (2017); Mana, Piccioni e Terzi (2017); Wu <i>et al.</i> (2017); Hongshan <i>et al.</i> (2018); Lu <i>et al.</i> (2018); Jiang <i>et al.</i> (2018); Bach-Andersen, Romer-Odgaard e Winther (2018); Guo, Fu e Yang (2018); Yu, Huang e Xiao (2018)
Gerador e parte elétrica	Schlechtingen e Ferreira Santos (2011); Kusiak e Verma (2012b); Verma e Kusiak (2012); Chen e Ye (2014); Amina, Tayeb e Mouloud (2016); Adouni <i>et al.</i> (2016); Amina <i>et al.</i> (2017); Hongshan <i>et al.</i> (2018); Lu <i>et al.</i> (2018); Bem Ali <i>et al.</i> (2018)
Sistema <i>Pitch</i>	Talebi, Sadrnia e Darabi (2014); Talebi, Sadrnia e Darabi (2015); Lu <i>et al.</i> (2018)
Sensores	Wang <i>et al.</i> (2014); Talebi, Sadrnia e Darabi (2015); Talebi, Sadrnia e Darabi (2014); Chen, Fu e Yang (2018); Kavaz e Barutcu (2018)
Eixo	Ren e Qu (2014)
Aerogerador	Kusiak e Verma (2011); Liu <i>et al.</i> (2011); Hameed e Wang (2012); Kusiak e Verma (2012a); Hameed e Wang (2013); Yang, Huang e Yang (2015); Astolfi <i>et al.</i> (2015); Yang, Huang e Huang (2016); Malik e Mishra (2017); Lind <i>et al.</i> (2017); Mazidi, Bertling Tjernberg e Sanz Bobi (2017); Su e Hu (2018); Yang <i>et al.</i> (2018); Huang <i>et al.</i> (2018); Sun e Sun (2018)

Com as informações projetadas no Quadro 2, tem-se que 15 artigos abordaram o aerogerador como um único equipamento, enquanto que os equipamentos mais trabalhados de forma pontual são a *gearbox* e o gerador, com 15 e 10 trabalhos publicados sobre eles, respectivamente. O foco nesses equipamentos pode ser explicado pelo seu valor monetário e pela frequência de falha que eles apresentam. De acordo com Chen e Ye (2014), o gerador é o componente da turbina eólica com custo



mais elevado. Wang *et al.* (2017) e Yang *et al.* (2014) afirmam que as falhas na *gearbox* representam mais de 50% das falhas nos aerogeradores. Essas afirmativas mostram que a *gearbox* e o gerador são os equipamentos mais críticos dos aerogeradores, explicando a preocupação maior com eles na literatura.

Após a *gearbox* e o gerador, tem-se as pás abordadas em 6 estudos, os sensores em 5, o sistema de *pitch* em 3 e por último o eixo principal, com um estudo apenas.

#### 4.1 Aplicações desenvolvidas

Os artigos estudados abordaram diferentes aplicações para cada equipamento. É importante destacar que, mesmo as aplicações tendo uma abordagem semelhante, elas podem variar quanto ao seu objetivo final.

Para as pás, foram desenvolvidos sistemas de auxílio a inspeção e robôs de inspeção. (WANG, BINRUI *et al.*, 2013) utilizou redes neurais na otimização do caminho de robôs utilizando um modelo 3D de uma pá eólica. (GANTASALA; LUNENO; AIDANPÄÄ, 2017) criou um sistema capaz de identificar desbalanceamento em vigas com o uso de redes neurais que, segundo eles, pode ser replicado para pás eólicas. Sistemas foram desenvolvidos para usar dados de ondas guiadas na identificação de falhas diversas (REGAN; BEALE; INALPOLAT, 2017), delaminação (JIMÉNEZ; GÓMEZ MUÑOZ; GARCÍA MÁRQUEZ, 2018) e acúmulo de gelo (JIMÉNEZ *et al.*, 2019).

No caso da *gearbox*, todos os trabalhos selecionados tiveram aplicações de sistema de monitoramento da condição, porém, alguns diferenciaram no objetivo final.

Seis trabalhos apresentaram sistemas de monitoramento da condição geral do equipamento. O trabalho realizado por Bangalore *et al.* (2017), usou redes neurais para o monitoramento da condição de *gearbox*, teve o melhor resultado, com previsão de falha 3 meses antes da sua ocorrência. Cinco estudos desenvolveram aplicações de previsão e diagnóstico de falha, dentre eles, a o trabalho desenvolvido por (YU; HUANG; XIAO, 2018) obteve melhor resultado com 100% de acurácia na classificação de falhas. Outros trabalhos focaram em componentes específicos da *gearbox*, um trabalho de previsão de falha em engrenagens (STR; BARSZCZ, 2016), e dois trabalhos de previsão de falha em rolamentos (BACH-ANDERSEN; RØMER-ODGAARD; WINTHER, 2018; GUO; FU; YANG, 2018).

Para o gerador, todos os trabalhos apresentaram sistemas de monitoramento da condição, com a exceção do estudo realizado por Amina *et al.* (2017) que apresentou um sistema de controle tolerante

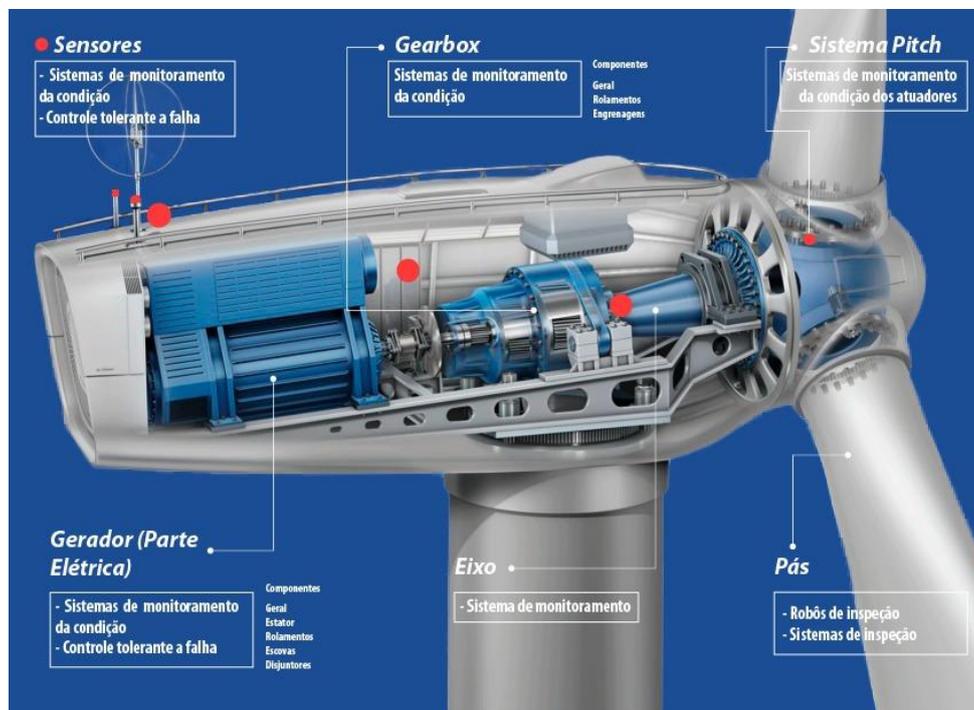


a falha para previsão de falha em disjuntores e ativação de redundâncias. Como no caso da *gearbox*, os trabalhos de sistema de monitoramento da condição para geradores tiveram objetivos distintos. Hongshan et al. (2018) utilizou redes neurais para previsão de comportamento geral do equipamento, tendo como resultado a previsão de falha horas antes da ocorrência. Ocorreram também sistemas com previsão de falhas em rolamentos (KUSIAK; VERMA, 2012b; SCHLECHTINGEN; FERREIRA SANTOS, 2011), escovas (VERMA; KUSIAK, 2012), disjuntores (AMINA; TAYEB; MOULOUD, 2016) e falhas específicas de queda de tensão em geradores DFIG (ADOUNI et al., 2016).

Os dois trabalhos que abordaram o sistema *pitch*, utilizaram redes neurais na detecção de falha dos atuadores, e além disso também abordaram a detecção de falhas em sensores de ângulo *pitch* e velocidade angular (TALEBI, N; SADRNIA; DARABI, 2015; TALEBI, NASSER; SADRNIA; DARABI, 2014). Os demais trabalhos que também abordaram os sensores, apresentaram soluções para identificação de falha em sensores de temperatura (KAVAZ; BARUTCU, 2018; WANG, QING et al., 2014) e controle tolerante a falha (CHEN, FEI; FU; YANG, 2018), todos eles utilizaram redes neurais como método de inteligência artificial. O único trabalho que abordou o eixo principal utilizou redes neurais para identificação de falha de alinhamento no eixo das turbinas (REN; QU, 2014).

A Figura 3 apresenta as aplicações desenvolvidas para cada equipamento pontual dentre os artigos selecionados para a revisão bibliográfica sistemática. Nota-se que os componentes mais importantes do sistema do aerogerador foram abordados pelos artigos.

Figura 3: Aplicações desenvolvidas para cada componente dos aerogeradores.



Fonte: Adaptado de (PRUFTECHNIK, [S.d.])

Dos quinze trabalhos que abordaram o aerogerador como sistema, sete desenvolveram aplicações com o objetivo de identificação de falhas gerais, tendo melhores resultados como 16 horas de tempo de aviso antes da ocorrência de falhas direcionadas a *gearbox* (HUANG *et al.*, 2018) e 98% de acurácia na identificação de falhas (LIU *et al.*, 2011). Dois trabalhos foram mais específicos, com identificação de falhas de balanceamento (MALIK; MISHRA, 2017) e monitoramento da vibração do aerogerador (LIND *et al.*, 2017).

Outros dois trabalhos dedicaram-se ao estudo de indicadores, sendo um voltado para a criação de indicadores que auxiliam no planejamento e avaliação da manutenção (ASTOLFI *et al.*, 2015) e o outro dedicado ao estudo de indicadores de manutenção de turbinas eólicas chinesas, fazendo uma crítica geral sobre o desempenho delas (SU; HU, 2018).

Três trabalhos desenvolveram aplicações para a otimização da estratégia de manutenção de parques eólicos. Dois deles desenvolveram sistemas de separação de turbinas em clusters utilizando dados de potência de saída, para dessa forma otimizar a manutenção na execução de atividades de manutenção no cluster inteiro (HAMEED; WANG, 2013, 2012). Outro estudo utilizou redes neurais na otimização do planejamento de manutenção avaliando os componentes principais do aerogerador



(segundo o estudo, pás, *pitch*, *gearbox* e gerador) como equipamentos pontuais e trazendo métricas de redução do custo de manutenção de 46% para parques *offshore* e 38% para parques *onshore* (LU *et al.*, 2018).

## 5. Conclusões e recomendações

A produção de energia elétrica é de fundamental importância para o desenvolvimento da sociedade e no momento atual de preocupação com o aquecimento global, a atenção da comunidade internacional volta-se para a geração de energia por fontes sustentáveis, como a energia eólica.

O ponto chave desse tipo de geração de energia elétrica é o aerogerador, e o desenvolvimento das atividades de operação e manutenção deles têm impacto direto no aumento de competitividade do setor, dessa forma, a adoção de tecnologias da indústria 4.0 como a inteligência artificial na operação e manutenção de aerogeradores pode trazer avanços para essa indústria.

Quanto a questão levantada no início do estudo sobre “como está sendo a aplicação de inteligência artificial na operação e manutenção de aerogeradores?” foi respondida detalhadamente nas sessões 3 e 4 desse trabalho. Considera-se que essas aplicações são desenvolvidas principalmente para sistemas de monitoramento da condição, sistemas de inspeção (incluindo robôs), sistemas de controle tolerante a falha, estudo de indicadores, sistemas que auxiliam no planejamento de manutenção.

Quanto os métodos de inteligência artificial utilizados, a maioria dos trabalhos utilizou redes neurais, árvores de decisão, máquinas de vetores de suporte e lógica *fuzzy* em suas aplicações, tendo como objetivo principalmente a classificação de dados, clusterização, modelagem e seleção de parâmetros.

Pode-se destacar que os componentes mais importantes dos aerogeradores foram contemplados nos artigos, e que vários dos trabalhos tiveram resultados satisfatórios em termos de tempo de previsão antes da ocorrência da falha e acurácia de classificação de falhas, além de resultados qualitativos de melhoria da estratégia de manutenção.

Nota-se, como lacuna no estado da arte, a ausência de valores monetários nos resultados, com apenas um trabalho apresentando resultados de redução percentual de custos de manutenção. Trabalhos futuros que apresentem seus resultados em termos de economia para a indústria podem



trazer a atenção ainda maior de grandes players em relação à pesquisa e desenvolvimento em inteligência artificial na operação e manutenção de aerogeradores.

### Referências

ABEEÓLICA. **Boletim Anual de Geração Eólica 2017**. 2018.

ABEEÓLICA. **Energia eólica chega a 14,71 GW de capacidade instalada**. Disponível em: <<http://abeeolica.org.br/noticias/energia-eolica-chega-a-1471-gw-de-capacidade-instalada/>>. Acesso em: 28 fev. 2019.

ADOUNI, A. et al. FDI based on Artificial Neural Network for Low-Voltage-Ride-Through in DFIG-based Wind Turbine. **ISA Transactions**, v. 64, p. 353–364, 2016.

AMINA, B. et al. Artificial intelligence-based fault tolerant control strategy in wind turbine systems. **International Journal of Renewable Energy Research**, v. 7, n. 2, 2017.

AMINA, B.; TAYEB, A.; MOULOUD, D. Intelligent Open Switch Fault Detection for Power Converter in Wind Energy System. **Applied Artificial Intelligence**, v. 30, n. 9, p. 886–898, 2016.

ASTOLFI, D. et al. Data mining techniques for performance analysis of onshore wind farms. **Applied Energy**, v. 148, p. 220–233, 2015.

AZADEGAN, A. et al. Fuzzy logic in manufacturing: A review of literature and a specialized application. **International Journal of Production Economics**, v. 132, n. 2, p. 258–270, 2011.

BACH-ANDERSEN, M.; RØMER-ODGAARD, B.; WINTHER, O. Deep learning for automated drivetrain fault detection. **Wind Energy**, v. 21, n. 1, p. 29–41, 2018.

BANGALORE, P. et al. An artificial neural network-based condition monitoring method for wind turbines, with application to the monitoring of the gearbox. **Wind Energy**, v. 20, n. 8, p. 1421–1438, ago. 2017.

BEN ALI, J. et al. Online automatic diagnosis of wind turbine bearings progressive degradations under real experimental conditions based on unsupervised machine learning. **Applied Acoustics**, v. 132, n. April 2017, p. 167–181, 2018.

CHEN, F.; FU, Z.; YANG, Z. Wind power generation fault diagnosis based on deep learning model in internet of things (IoT) with clusters. **Cluster Computing**, v. 6, p. 1–13, 2018.

CHEN, Q.; YE, M. Analysis of the Fault Diagnosis Method for Wind Turbine Generator Bearing Based on Improved Wavelet Packet-BP Neural Network. **Intelligent Computing in Smart Grid and Electrical Vehicles**, p. 13–20, 2014.

ELHOR, N. et al. Neural networks for wind turbine supervision. **e&i Elektrotechnik und Informationstechnik**, p. 366–369, 1999.

GANTASALA, S.; LUNENO, J. C.; AIDANPÄÄ, J. O. Investigating how an artificial neural network model can be used to detect added mass on a non-rotating beam using its natural frequencies: A possible application for wind turbine blade ice detection. **Energies**, v. 10, n. 2, p. 1–21, 2017.



- GONZÁLEZ, M. O. A.; GONÇALVES, J. S.; VASCONCELOS, R. M. Sustainable development: Case study in the implementation of renewable energy in Brazil. **Journal of Cleaner Production**, v. 142, p. 461–475, 2017.
- GUO, P.; FU, J.; YANG, X. Condition monitoring and fault diagnosis of wind turbines gearbox bearing temperature based on kolmogorov-smirnov test and convolutional neural network model. **Energies**, v. 11, n. 9, 2018.
- HAMEED, Z.; WANG, K. Clustering Analysis to Improve the Reliability and Maintainability of Wind Turbines with Self-Organizing Map Neural Network. **International Journal of Performability Engineering**, v. 9, n. 3, p. 245–260, 2013.
- HAMEED, Z.; WANG, K. Development of Optimal Maintenance Strategies for Offshore Wind Turbine by Using Artificial Neural Network. **Wind Engineering**, v. 36, n. 3, p. 353–364, 2012.
- HONGSHAN, Z. et al. Anomaly Detection and Fault Analysis of Wind Turbine Components Based on Deep Learning Network. **Renewable Energy**, v. 127, p. 825–834, 2018.
- HUANG, Z. et al. Condition Monitoring of Wind Turbine Based on Copula Function and Autoregressive Neural Network. **MATEC Web of Conferences**. v. 04008, p. 1–5, 2018.
- IRENA. **Global Energy Transformation: A Roadmap to 2050**. 2018.
- JHA, S. K. et al. Renewable energy: Present research and future scope of Artificial Intelligence. **Renewable and Sustainable Energy Reviews**, v. 77, n. April, p. 297–317, 2017.
- JIANG, G. et al. Multiscale Convolutional Neural Networks for Fault Diagnosis of Wind Turbine Gearbox. **IEEE Transactions on Industrial Electronics**, v. PP, n. c, p. 1, 2018.
- JIMÉNEZ, A. A. et al. Linear and nonlinear features and machine learning for wind turbine blade ice detection and diagnosis. **Renewable Energy**, v. 132, p. 1034–1048, 2019.
- JIMÉNEZ, A. A.; GÓMEZ MUÑOZ, C. Q.; GARCÍA MÁRQUEZ, F. P. Machine learning for wind turbine blades maintenance management. **Energies**, v. 11, n. 1, p. 1–16, 2018.
- KALOGIROU, S. A. Artificial Intelligence in Renewable Energy Systems Modelling and Prediction. **World Renewable Energy Congress VII**. 2002.
- KAVAZ, A. G.; BARUTCU, B. Fault detection of wind turbine system using neural networks. **Journal of Sensors**, v. 2018–Janua, p. 103–108, 2018.
- KUSIAK, A.; VERMA, A. A data-mining approach to monitoring wind turbines. Sustainable Energy, **IEEE Transactions on sustainable energy**, v. 3, n. 1, p. 150–157, 2012a.
- KUSIAK, A.; VERMA, A. Analyzing bearing faults in wind turbines: A data-mining approach. **Renewable Energy**, v. 48, p. 110–116, 2012b.
- KUSIAK, A.; VERMA, A. Prediction of Status Patterns of Wind Turbines: A Data-Mining Approach. **Journal of Solar Energy Engineering**, v. 133, n. 1, p. 011008, 2011.
- LIMA, F.; FERREIRA, P.; VIEIRA, F. Strategic impact management of wind power projects Fátima. **Renewable and Sustainable Energy Reviews**, v. 25, p. 277–290, 2013.



- LIND, P. et al. Normal Behaviour Models for Wind Turbine Vibrations: Comparison of Neural Networks and a Stochastic Approach. **Energies**, v. 10, n. 12, p. 1944, 2017.
- LITON HOSSAIN, M.; ABU-SIADA, A.; MUYEEN, S. M. Methods for advanced wind turbine condition monitoring and early diagnosis: A literature review. **Energies**, v. 11, n. 5, 2018.
- LIU, Y. et al. Automatic Fault Detection for Wind Turbines Using Single-Class Machine Learning Methods. **Applied Mechanics and Materials**, v. 58–60, p. 2602–2607, 2011.
- LU, Y. et al. Condition based maintenance optimization for offshore wind turbine considering opportunities based on neural network approach. **Applied Ocean Research**, v. 74, p. 69–79, 2018.
- MALIK, H.; MISHRA, S. Artificial neural network and empirical mode decomposition based imbalance fault diagnosis of wind turbine using TurbSim, FAST and Simulink. **IET Renewable Power Generation**, v. 11, n. 6, p. 889–902, 2017.
- MANA, M.; PICCIONI, E.; TERZI, L. Wind turbine fault diagnosis through temperature analysis: An Artificial Neural Network approach. **Diagnostyka**, v. 18, n. 1, p. 9–16, 2017.
- MARUGÁN, A. P. et al. A survey of artificial neural network in wind energy systems. **Applied Energy**, v. 228, n. April, p. 1822–1836, 2018.
- MAZIDI, P.; TJERNBERG, L. B.; BOBI, M. A. S. Wind turbine prognostics and maintenance management based on a hybrid approach of neural networks and a proportional hazards model. **Journal of Risk and Reliability**, v. 231, n. 2, p. 121–129, 2017.
- MHI VESTAS. **MHI Vestas Unveils Pioneering MVOW SMART Turbine Product Portfolio**. Disponível em: <<http://www.mhivestasoffshore.com/mhi-vestas-and-ramboll-collaborate-on-industry-first/>>. Acesso em: 5 dez. 2018. , 2018
- PRUFTECHNIK. **Align wind turbines**. Disponível em: <<https://www.pruftechnik.com/br/top/press/success-stories/rotalign-optalign-align-wind-turbines>>. Acesso em: 28 fev. 2019.
- REGAN, T.; BEALE, C.; INALPOLAT, M. Wind Turbine Blade Damage Detection Using Supervised Machine Learning Algorithms. **Journal of Vibration and Acoustics**, v. 139, n. 6, p. 061010, 2017.
- REN, K.; QU, J. Identification of shaft centerline orbit for wind power units based on hopfield neural network improved by simulated annealing. **Mathematical Problems in Engineering**, v. 2014, 2014.
- SAMPAIO, P. G. V.; GONZÁLEZ, M. O. A. Photovoltaic solar energy: Conceptual framework. **Renewable and Sustainable Energy Reviews**, v. 74, n. June 2016, p. 590–601, 2017.
- SCHLECHTINGEN, M.; FERREIRA SANTOS, I. Comparative analysis of neural network and regression based condition monitoring approaches for wind turbine fault detection. **Mechanical Systems and Signal Processing**. 2011
- STR, M.; BARSZCZ, T. Application of Artificial Neural Network for Damage Detection in Planetary Gearbox of Wind Turbine. **Shock and Vibration**, v. 2016, p. 1–13, 2016.
- SU, C.; HU, Z. Reliability assessment for Chinese domestic wind turbines based on data mining techniques. **Wind Energy**, v. 21, n. 3, p. 198–209, 2018.



SUN, Z.; SUN, H. Health Status Assessment for Wind Turbine. **Mathematical Problems in Engineering**, v. 2018, n. 2, p. 16, 2018.

TALEBI, N.; SADRNIA, M. A.; DARABI, A. Fault detection of wind energy conversion systems using recurrent neural networks. **International Journal of Sustainable Energy**, v. 34, n. 1, p. 52–70, 2015.

TALEBI, N.; SADRNIA, M. A.; DARABI, A. Robust fault detection of wind energy conversion systems using dynamic neural networks. **International Journal of Sustainable Energy**, v. 2014, n. September 2014, p. 1–19, 2014.

VERMA, A.; KUSIAK, A. Fault Monitoring of Wind Turbine Generator Brushes: A Data-Mining Approach. **Journal of Solar Energy Engineering**, v. 134, n. 2, p. 021001, 2012.

VESELY, E. Consider automated machine learning for wind turbine asset maintenance. **Power**, v. 161, n. 9, p. 1–15, 2017.

WANG, B. et al. Path planning for detection robot climbing on rotor blade surfaces of wind turbine based on neural network. **Advances in Mechanical Engineering**, v. 2013, 2013.

WANG, L. et al. Wind Turbine Gearbox Failure Identification with Deep Neural Networks. **IEEE Transactions on Industrial Informatics**, v. 13, n. 3, p. 1360–1368, 2017.

WANG, Q. et al. A Sensor Network Modeling and Fault Detection Method for Large Wind Farms by Using Neural Networks. **IEEE International Conference on Control & Automation**. 2014.

WANG, X. Fault Diagnosis on Transmission System of Wind Turbines Based on Wavelet Packet Transform and RBF Neural Networks. **Applied Mechanics and Materials**. v. 375, p. 1102–1105, 2013.

WU, B. et al. Fault diagnosis for wind turbine based on improved extreme learning machine. **Journal of Shanghai Jiaotong University (Science)**, v. 22, n. 4, p. 466–473, 2017.

WU, C. M.; SONG, Q. H. Fault diagnosis of wind turbine vibration based on wavelet transform and neural network. **Journal of Information Hiding and Multimedia Signal Processing**, v. 7, n. 4, p. 898–905, 2016.

YANG, H. H.; HUANG, M. L.; HUANG, P. C. Detection of Wind Turbine Faults Using a Data Mining Approach. **Journal of Energy Engineering**, v. 142, n. 3, p. 04015021, 2016.

YANG, H. H. et al. An approach combining data mining and control charts-based model for fault detection in wind turbines. **Renewable Energy**, v. 115, p. 808–816, 2018.

YANG, H. H.; HUANG, M. L.; YANG, S. W. Integrating auto-associative neural networks with hotelling T2 control charts for wind turbine fault detection. **Energies**, v. 8, n. 10, p. 12100–12115, 2015.

YANG, W. et al. Wind turbine condition monitoring: technical and commercial challenges. **Wind Energy**, p. 673–693, 2014.

YANG, Z. X.; WANG, X. B.; ZHONG, J. H. Representational learning for fault diagnosis of wind turbine equipment: A multi-layered extreme learning machines approach. **Energies**, v. 9, n. 6, p. 1–17, 2016.



YU, W.; HUANG, S.; XIAO, W. Fault Diagnosis Based on an Approach Combining a Spectrogram and a Convolutional Neural Network with Application to a Wind Turbine System. **Energies**, v. 11, n. 10, 2018.

ZADEH. The role of fuzzy logic in the management of uncertainty in expert systems. **Fuzzy sets and systems**. v. 11, p. 199–227, 1983.