

# REVISÃO DE APLICAÇÕES DE MACHINE LEARNING NO APRIMORAMENTO DE MÉTODOS DE MONITORAMENTO DE TURBINAS EÓLICAS COM FOCO EM CAIXAS DE ENGRENAGENS

**Rivanilso dos Santos Mangueira** (UFC) - rivanilso95@gmail.com

**João Gabriel Ramos Arraes de Alencar** (UFC) - jgarraes1@gmail.com

**João Victor Santos Fernandes** (UFC) - joaovictor.ti1611@gmail.com

**Gilderlanio Barbosa Palacio** (UFC) - palacioengmec@gmail.com

## **Resumo:**

*A caixa de engrenagens é um dos componentes mais importantes para o funcionamento de um aerogerador e um dos que merece maior atenção dos operadores no que concerne a manutenção, uma vez que está entre os cinco fatores que falham com maior frequência e é o que representa o maior tempo percentual total de inatividade da turbina. Nesse contexto, este trabalho visa expor como a tecnologia dos algoritmos de Machine Learning (ML) tem sido aplicada recentemente no melhoramento dos métodos de monitoramento de condições e performance do sistema, com foco na parte supracitada. Relacionado ao conceito de inteligência artificial, o ML consiste no aprendizado de uma máquina computadorizada a partir de um conjunto de dados previamente fornecidos de modo que o método possa produzir novos dados, tem se demonstrado útil no âmbito da manutenção, possibilitando, por meio de modelos como redes neurais e processos gaussianos, a previsão de falhas com antecedência, amplificando a ação de métodos tradicionais como de análise de dados de vibração, de temperatura ou de curva de potência, evitando custos e despesas associados com correções ao facilitar a prevenção. Os resultados desta revisão bibliográfica apontam caminhos promissores para o desenvolvimento de estudos na área, particularmente no que diz respeito ao monitoramento de temperatura.*

**Palavras-chave:** *Machine Learning, Energia Eólica, Caixas de Engrenagens*

**Área temática:** *Outras fontes renováveis de energia*

**Subárea temática:** *Simulação, análise, equipamentos e sistemas de conversão eólica para eletricidade*

# REVISÃO DE APLICAÇÕES DE MACHINE LEARNING NO APRIMORAMENTO DE MÉTODOS DE MONITORAMENTO DE TURBINAS EÓLICAS COM FOCO EM CAIXAS DE ENGRENAGENS

Rivanilso dos Santos Manguiera – [rivanilso95@gmail.com](mailto:rivanilso95@gmail.com)  
João Gabriel Ramos Arraes de Alencar – [jgarraes1@gmail.com](mailto:jgarraes1@gmail.com)  
João Victor Santos Fernandes – [joaovictor.ti1611@gmail.com](mailto:joaovictor.ti1611@gmail.com)  
Gilderlanio Barbosa Alves Palacio – [palacioengmec@alu.ufc.br](mailto:palacioengmec@alu.ufc.br)

**Resumo.** A caixa de engrenagens é um dos componentes mais importantes para o funcionamento de um aerogerador e um dos que merece maior atenção dos operadores no que concerne a manutenção, uma vez que está entre os cinco componentes que falham com maior frequência e é o que representa o maior tempo percentual total de inatividade da turbina. Nesse contexto, este trabalho visa expor como a tecnologia dos algoritmos de Machine Learning (ML) tem sido aplicada, recentemente, no melhoramento dos métodos de monitoramento de condições e performance do sistema, com foco na parte supracitada. Relacionado ao conceito de inteligência artificial, o ML consiste no aprendizado de uma máquina computadorizada a partir de um conjunto de dados previamente fornecidos, de modo que o método possa produzir novos dados. Tal conceito tem se demonstrado útil no âmbito da manutenção, possibilitando, por meio de modelos como redes neurais e processos gaussianos, a previsão de falhas com antecedência, amplificando a ação de métodos tradicionais como de análise de dados de vibração, de temperatura ou de curva de potência e evitando custos e despesas associados com correções ao facilitar a prevenção. Os resultados desta revisão bibliográfica apontam caminhos promissores para o desenvolvimento de estudos na área, particularmente no que diz respeito ao monitoramento de temperatura.

**Palavras-chave:** Machine Learning, Energia Eólica, Caixas de Engrenagens

## 1. INTRODUÇÃO

Segundo o Operador Nacional do Sistema Elétrico (ONS), o fator médio de capacidade de geração de energia eólica médio brasileiro em 2018 foi de 42%, superando o fator de capacidade médio mundial, 25%. Ainda em 2018, a energia eólica chegou a 14,71 GW e alcançou o segundo lugar em capacidade instalada na matriz elétrica brasileira, ultrapassando a geração por biomassa e ficando atrás da geração hidrelétrica, com 14,67 GW e 98,29 GW, respectivamente. A geração eólica está em um constante crescimento e a expectativa é que alcance, em 2022, a capacidade de 17,6 GW, representando, assim, um crescimento de 20%, como indicam dados da Associação Brasileira de Energia Eólica.

As turbinas eólicas convertem a energia cinética proveniente do vento em energia mecânica e, por fim, em elétrica. Esse processo inicia-se nas pás da turbina, as quais apresentam, ao longo de seu comprimento, seções com diferentes tamanhos e formas com perfis aerodinâmicos. As pás contêm aerofólios, que as fazem girar através do empuxo gerado do movimento do fluido (Anderson Jr, 1991). O movimento é transferido através de um eixo e passa pela caixa de engrenagens antes de chegar no gerador (Vitorino, 2012). Isso ocorre porque as pás normalmente giram a uma taxa baixa de rotações por minuto, devido à resistência mecânica, e, nessa velocidade, nenhuma frequência significativa de eletricidade pode ser produzida; por isso, utiliza-se a caixa de engrenagens para aumentar a rotação do sistema visando o melhor funcionamento do gerador. No entanto, a incidências de falhas é comum em turbinas eólicas, e isso acarreta em custos extras para a manutenção de campos eólicos. Eis a importância da pesquisa constante no campo de pesquisa na incidência de falhas.

A turbina opera sob um sistema de controle para monitorar remotamente seus componentes (Marques, 2004). Dentre os componentes, a caixa de engrenagens se destaca, uma vez que ela representa um subsistema composto por múltiplos equipamentos. Esse subsistema pode ser avaliado por meio de um método de análise que tem a capacidade de aprender por meio de dados fornecidos de modo a reconhecer padrões e prever possíveis falhas.

O objetivo deste trabalho é apresentar e analisar alguns métodos de monitoramento com *Machine Learning* (ML) para predição de falhas em caixas de engrenagem. Dessa forma, busca-se analisar três variáveis comumente monitoradas: vibração, temperatura e curva de potência (Ernesto, 2014). O diagnóstico do monitoramento com ML também busca possíveis correlações entre os métodos.

## 2. CAIXA DE ENGRENAGENS E ROLAMENTOS

Diferentes turbinas eólicas necessitam de diferentes tipos de caixas de engrenagens, sendo tal componente de grande importância para o exímio funcionamento do sistema. Há, nesse sentido, de acordo com uma norma da IEC (2012), dois tipos principais de configurações das engrenagens: a paralela (em que a coroa gira à mesma velocidade das pás, a qual é incrementada pelo pinhão) e a planetária (em que a engrenagem central gira à mesma velocidade das pás e as três ao redor a aumentam). Aquela permite um excelente controle da velocidade de rotação, enquanto estas são resistentes e estáveis e são, em geral, mais compactas. A mesma norma afirma que as caixas de engrenagens mais modernas apresentam os dois tipos trabalhando em conjunto, com um estágio planetário e dois estágios paralelos ou dois estágios planetários e um estágio paralelo. Como afirmou Harris (2001), em qualquer configuração, o giro das engrenagens é auxiliado por rolamentos, componentes lubrificadas que funcionam junto a elas garantindo sua rotação ideal e reduzindo o atrito.

Todas as caixas de engrenagens, independentemente do tipo de sua composição, enfrentam grandes adversidades em seu funcionamento, como cargas elevadas submetidas pela atuação de outros componentes (como gerador e eixo de transmissão, principalmente em paradas de emergência) e pelas condições de operação (ventos fortes, congelamento em regiões frias etc.), podendo levar à sobrecarga; variações súbitas de torque; contaminação do lubrificante dos rolamentos por água ou sujeira; e concentração de tensões devido à instalação errada de rolamentos. O impacto é, em geral, mais sentido em rolamentos: pela pesquisa de Sheng (2016), 76,2% das falhas ocorrem neles, enquanto 17,3% ocorrem nas engrenagens e 6,6% em outros componentes. Isso ocorre devido à sensibilidade dessa peça, que depende muito da qualidade do seu óleo lubrificante, o qual, ao longo do tempo de uso, sofre contaminação por partículas de, por exemplo, areia e ferrugem e se deteriorando, podendo isso resultar em ruptura axial, geralmente precedendo uma falha nas engrenagens, como afirmou Polak (2000). É importante notar que cada aerogerador apresenta entre 20 e 25 rolamentos em sua estrutura (Coulate e Hornemann, 2017) e que há dois tipos de avarias neles (Stack, Habetler e Harley, 2004): os defeitos de ponto único e localizado e as rugosidades generalizadas (de área maior e ocorrência mais gradual).

Um relatório técnico recente (GCube, 2015) apontou que há cerca de 1200 falhas em caixas de engrenagens reportadas por ano, isto é, uma por 145 turbinas em operação, cujo custo em reivindicações de seguro varia usualmente, nos Estados Unidos, entre US\$ 200.000 e US\$ 300.000. Além disso, levando em conta o sistema como um todo, esse é uma das cinco partes que mais falha: como consta em um trabalho de Ribrant (2006), 9,8% das avarias em uma turbina eólica ocorrem na caixa de engrenagens. Dados ainda mais alarmantes se referem ao tempo de inatividade que essas falhas causam: como apontaram Ribrant e Bertling (2007), elas representam 19,4% do tempo total de inatividade dos aerogeradores, o maior valor entre todos os componentes, com um tempo médio de parada de 256 horas por falha e 6057 horas por ano sem funcionar, e, como Chamberlain (2005) acrescentou, o tempo máximo de parada por falha chega a meses.

O problema supracitado ocorre, em grande parte, devido à demora na obtenção das peças substitutivas, o que indica que o conhecimento prévio do momento da falha colabora na redução do tempo de inatividade. Há um alto impacto financeiro, uma vez que, novamente segundo Chamberlain (2005), 13% do custo total de um aerogerador *onshore* é devido à caixa. A longo prazo, tipicamente, projeta-se esse componente para que ele funcione bem por 20 anos, mas a probabilidade de que, nesse período, um ou mais rolamentos quebrem é de 93%, e, em sete anos, é de 37% (Ribrant e Bertling, 2007). Há, então, como evidenciam todos esses números, uma necessidade de gerenciar as falhas para diminuir os custos operacionais.

## 3. SCADA

Os centros de controle dos campos eólicos precisam de informações que permitam que os operadores tenham a capacidade de monitorar e intervir, se necessário, nos dispositivos em questão. Nesse âmbito, esses sistemas são conhecidos como Sistemas de Supervisão e Aquisição de Dados - SCADA (Boyer, 1999). De forma simplificada, o SCADA funciona por meio de uma Unidade Terminal Remota (URT) que trabalha emitindo informações para uma Unidade Central (UC) em períodos de tempo predeterminados. À medida que aumenta a complexidade do dispositivo analisado, mais UCs e UTRs são adicionadas (Ackerman e Block, 1992). Conforme Salameh *et al.* (2018), quando aplicado nos campos eólicos, o sistema SCADA pode fornecer dados relacionados à velocidade do vento e do rotor e à potência e ao ângulo da pá, por exemplo, além de informações sobre lubrificação, temperatura, nível de vibração, entre outras informações relevantes acerca dos componentes da turbina eólica.

## 4. MACHINE LEARNING E REDES NEURAIS

Os dados fornecidos pelo SCADA compõem um banco de dados de um sistema que executa vários cenários possíveis, os quais são utilizados para o software gerar uma estimativa (Braga, 2000). O aprendizado mediante dados fornecidos ao longo de iterações feitas pelo programa é denominado de ML (Mitchell, 1997).

Existem várias maneiras de estimar os dados, como as redes neurais, que consistem em múltiplos estimadores analisando os dados simultaneamente, equivalendo aos neurônios de um cérebro humano processando os dados. Segundo Haykin (2007, p. 28), “Uma rede neural é um processador maciçamente e paralelamente distribuído constituído de

unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido”.

Os dados que percorrem as unidades de processamento são multiplicados por números inicialmente aleatórios, os pesos, e verificados por elas para a tomada de decisões. No entanto, diferentemente de um programa comum que trabalha sob padrões predeterminados, as redes neurais se adaptam ao ambiente em que estão inseridas (De Souto, 2003). Isso permite maior abrangência de processamento e maiores possibilidades de sistemas, uma vez que o programa é treinado pelos dados. A determinação dos pesos corretos é o objetivo, e, como existem inúmeras combinações, seria impossível para um ser humano analisar todas. Assim, a cada iteração que o programa executa, é testada uma nova combinação e são armazenados seus resultados. Ao longo dos ciclos, os padrões são analisados, e as decisões são tomadas de acordo com eles.

A capacidade de aprendizagem da rede neural consiste na sua concepção de resultados de acordo com os dados de entrada que variam ao longo da simulação, processando-os em uma rede paralela de informações semelhante aos neurônios do cérebro humano (Haykin, 2007). Assim, o objetivo a ser alcançado é subdividido em processos, os quais podem determinar ações durante a execução dos dados, atribuídos às redes.

As aplicações das técnicas de ML em sistemas aerogeradores são numerosas, sendo a predição da velocidade do vento, a otimização da geração de potência e o prognóstico e o diagnóstico de falhas exemplos delas (Pérez-Ortiz, 2016). Nesse aspecto, os métodos de detecção de falhas em turbinas eólicas são classificados em monitoramento de vibração, monitoramento do binário, monitoramento de temperatura, monitoramento do óleo, monitoramento de emissão acústica, monitoramento por fibra ótica e monitoramento por curva de potência.

O objetivo principal deste trabalho é, justamente, exibir como a inteligência artificial tem sido utilizada para aprimorar três dos métodos de monitoramento comumente utilizados para a caixa de engrenagem: vibração, temperatura e curva de potência. Vale ressaltar que esses três métodos de monitoramento foram escolhidos por questões de custo e usabilidade quando comparados aos outros métodos (Ernesto, 2014).

## 5. MONITORAMENTO DE VIBRAÇÃO

O monitoramento de vibração de caixas de engrenagem baseia-se em identificar as variações de frequência nelas. Um aumento na amplitude de vibração é um resultado direto de falha no elemento rotacional. Baseando-se na velocidade de rotação, são calculadas e comparadas medições para identificar o módulo de falha.

A análise, feita por meio de sensores como o acelerômetro, pode ser no domínio do tempo (*time waveform*), em que a amplitude de onda da vibração varia com ele, ou no domínio da frequência (FFT), em que se descrevem as amplitudes máximas correspondentes às frequências de vibração presentes (Hanly, 2016). A partir desse ponto, a análise dos gráficos é feita pelo engenheiro para determinar a causa da falha com o uso de métodos computacionais (Arco-Verde, 2008). No entanto, esse método analisa falhas em tempo real, impedindo que alguma prevenção seja realizada.

O uso de redes neurais possibilita a prevenção com antecedência de possíveis falhas. Um artigo (Carrol *et al.*, 2019) realizou o estudo de predição de falhas com o uso de ML. Através da arrecadação de dados para treinamento dos algoritmos, os autores centralizaram seus recursos na caixa de engrenagens (Lau *et al.*, 2012). O processo de aprendizagem ocorreu em uma rede neural treinada com vários dados coletados em caixas de engrenagens do mesmo modelo. O artigo dividiu seu escopo em etapas de obtenção, análise e treinamento de dados. A Fig. 1 apresenta a relação entre o número de entradas de dados e a porcentagem de acerto da predição.

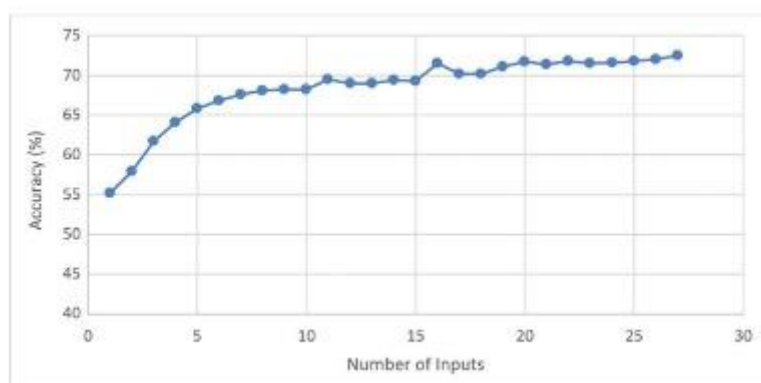


Figura 1 - Figura criada usando dados SCADA de um problema da engrenagem.

Fonte: Carrol *et al.*, 2019.

Formou-se uma rede neural com dados SCADA de dois períodos diferentes, treinada juntamente com dados de vibração (Jena e Samantaray, 2016) para predição de falhas de um rolamento de engrenagem planetário e de um dente de engrenagem (Carrol et al., 2019). Notou-se que a predição se fez mais eficiente para o dente do que para o rolamento, uma vez que os dados de vibração do dente de engrenagem são mais claros do que os de rolamento, conforme a Fig. 2.

Fault	Result	Based on SCADA Data	Based on Vibration Data
Gear bearing	Correct prediction	72.5%	63%
	Missed failure	20%	13%
	False positive	7.5%	25%
Gear tooth	Correct prediction	75%	100%
	Missed failure	13%	0%
	False positive	12%	0%

Figura 2 – Figura da tabela de resultados de predições de redes neurais de duas classes para dados SCADA e de vibração. Fonte: Carrol *et al.*, 2019.

Em outro artigo (Li *et al.*, 2019), a metodologia de extração de dados de vibração foi realizada mediante o uso de modelos de regressão (Kim *et al.*, 2008), uma vez que os sinais de vibração apurados podiam estar imbuídos de variações não condizentes com a vibração da peça estudada. Esse artigo difere do anterior por realizar essa união de métodos de regressão com a rede neural, visando uma melhor extração de dados. Com a eliminação de dados supérfluos (Heng, 2002), a equipe desenvolveu um modelo de rede neural avaliadora da vida restante útil do objeto estudado. A maior contribuição desse artigo consistiu na implementação de modelos de regressão para amplificar a capacidade de uso da rede neural.

Outros trabalhos (Zhao *et al.*, 2017) desenvolveram um método de aprendizado CNN (Lecun *et al.*, 1998) para captar dados e criar padrões para o diagnóstico de falhas em caixas de engrenagens. Assim, o uso de ML se fez útil na verificação do estado de saúde do componente.

Um artigo (Melo Junior *et al.*, 2019) salientou três métodos de análise de dados com aprendizado de máquina para o monitoramento da turbina eólica em geral, buscando possíveis falhas. Entre esses métodos, houve a rede neural artificial (RNA) (Haykin, 2007), o discriminador gaussiano (Webb, 2003) e a transformada de Karhunen-Loève (KLT) (Webb, 2003). Como resultado, na simulação que mais se aproximava às condições reais de trabalho de uma turbina, as técnicas apresentadas obtiveram 86,46%, 94,40% e 56,07%, respectivamente, de acerto durante esse teste. As conclusões foram satisfatórias e demonstraram real possibilidade de desenvolvimento de práticas de aprendizado de máquina nessa situação.

## 6. MONITORAMENTO DE TEMPERATURA

De acordo com a norma da IEE (1986), alguns componentes da turbina eólica apresentam variações de temperaturas de operação padronizadas; por exemplo, o aumento da temperatura de um rolamento na carga nominal não pode exceder os 45°C. Dessa forma, em condições normais de operação, um aumento repentino de temperatura pode indicar uma falha em algum dos componentes da turbina, como afirmado por Xinyan *et al.* (2008). É o caso da presença de contaminantes no óleo de lubrificação, como apresentado por Kusiak *et al.* (2013), uma vez que esses fatores podem reduzir sua eficiência, provocando desgaste nos rolamentos e na caixa de engrenagens, o qual é percebido por meio da mudança no calor.

As variações de temperatura são coletadas pelo sistema SCADA; porém, como grandes variações são detectadas quando a falha já é eminente, Rasmussen *et al.* (2006) propõem que esses dados sejam utilizados na formação de um histograma com a distribuição de frequência e as temperaturas como eixos, sendo modelados, desse modo, em uma distribuição gaussiana, buscando uma curva de menor erro possível. Com isso, são geradas variáveis aleatórias que são testadas a cada possível resultado, a fim de alcançar a distribuição de melhor ajuste. Já Herp *et al.* (2018) propõe que os dados passem por um processo de avaliação de hipóteses por meio da máxima verossimilhança, conhecido como inferência bayesiana, processo esse que tem como objetivo garantir o aprendizado do sistema; dessa forma, foi possível prever uma falha no rolamento com, em média, 33 dias de antecedência.

Por outro lado, o estudo de Maru *et al.* (1989) mostrou que outros fatores como: aumento da temperatura do ambiente, variações na velocidade de operação do motor e viscosidade do óleo podem afetar o monitoramento do aumento de temperatura nos rolamentos e caixas de engrenagens. Nesse âmbito, Wang *et al.* (2019) propõem utilizar uma estrutura integrada de diagnóstico e prognóstico de falhas, que consiste na incorporação de um processo de degradação de máquina como um modelo de estado e um modelo de mensuração por meio de uma estrutura bayesiana. Essa abordagem consegue reduzir medições ruidosas e assim, reduzir a taxa de alarmes falsos e melhorar a estratégia de manutenção.

## 7. MONITORAMENTO POR CURVA DE POTÊNCIA

O monitoramento por curva de potência analisa a performance de geração de energia de um aerogerador de forma geral, em função da velocidade do vento (Li *et al.*, 2001); entre a velocidade de partida e a nominal, onde, como afirmam

Cambron *et al.* (2016) a saída de potência não varia, tal curva é gerada pela Eq. (1), fornecida por Spera *et al.* (1994), em que  $P$  é a potência gerada,  $\rho$  é a densidade do ar,  $R$  é o tamanho da pá,  $C_p$  é um coeficiente que descreve a eficiência de conversão da turbina e  $V$  é a velocidade do vento. Para um aerogerador em funcionamento, todos esses fatores são tidos como constantes, exceto pela velocidade, sendo o resultado, como mostram Pandit e Infield (2018), uma distribuição de potência não linear.

$$P=0,5 \cdot \pi \cdot \rho \cdot R^2 \cdot C_p \cdot V^3 \quad (1)$$

As curvas de potência calculadas na prática não são iguais às fornecidas pelos fabricantes (elaboradas em condições de teste seguindo a norma IEC 61400-12-1) devido a fatores como a direção do vento, o desgaste provocado por ele e a turbulência (Ouyang *et al.*, 2017); entretanto, são parecidas, também apresentando formato de S (Clifton *et al.*, 2016). Uma falha em um componente como a caixa de engrenagens pode, então, ser detectada se houver um ponto fora da curva, isto é, uma diferença entre a saída de potência prevista para certa velocidade do vento e a obtida, motivando uma investigação mais a fundo por meio, por exemplo, dos métodos de monitoramento supracitados, como afirmam Janssens *et al.* (2016) É possível também estimar o tipo da falha de acordo com a posição do *outlier* no gráfico, como visto na Fig. 3, de Park *et al.* (2014).

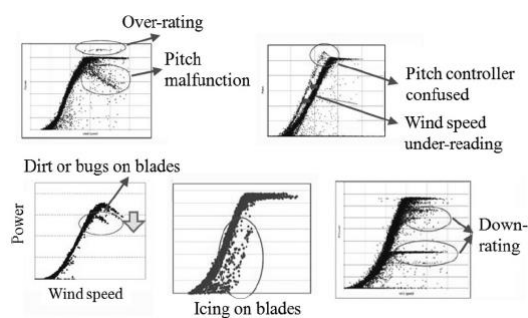


Figura 3 - Tipos de curvas de potência que surgem em diferentes casos de falha. Fonte: Park *et al.*, 2014.

O grande benefício do método é a simplicidade da medição dos dados, a qual leva à ausência da necessidade da instalação de sensores adicionais; entretanto, ele também representa um problema no sentido de que, geralmente, apenas um parâmetro (a velocidade do vento) é utilizado para traçar a curva, sendo ignorados os outros fenômenos que influenciam a curva de potência, que se torna menos exata e dificulta, com isso, o discernimento dos pontos de performance insatisfatória (Janssens *et al.*, 2016; Li, Liu e Shu, 2019). Além disso, a variação da velocidade faz com que as estatísticas de interesse da medição sejam não estacionárias, o que dificulta a detecção de evidências de falhas nos componentes, entre outros problemas, como discutido por Nova (2014).

Muito tem sido pesquisado acerca da detecção de avarias por meio da análise de curvas de potência com o auxílio de ML; Leahy *et al.* (2016), por exemplo, por meio de um algoritmo de *support vector machine*, obtiveram uma maior eficiência na detecção com antecedência de mais de meia hora de falhas mais comuns e sem muita gravidade, a qual não é muito explorada na literatura; isso foi efetivo no caso de superaquecimento do gerador, enquanto, nos outros, apesar de ótimas sensibilidade e da especificidade, houve problemas com a precisão. Adicionalmente, Gonzalez *et al.* (2019) analisaram a sensibilidade a danos na modelagem de curvas de potência em relação à complexidade do terreno, à sazonalidade e às variáveis escolhidas. Esse trabalho constatou que o algoritmo que menos erra devido a mudanças nessas condições é o da floresta aleatória, o que significa que ele é adequado para detectar anomalias em uma gama extensa de situações.

Nos artigos estudados para a realização desta seção do trabalho, o algoritmo do processo gaussiano se apresentou frequente; Pandit e Infield (2018), por exemplo, com a intenção de possibilitar o diagnóstico de problemas que a análise apenas da curva de potência poderia deixar de perceber, utilizaram-no para traçar, além dela, a curva da velocidade do rotor, a da potência do rotor e a do ângulo de inclinação da pá, tudo a partir de dados adquiridos pelo sistema SCADA em um determinado período de tempo; o menor coeficiente de determinação foi de 96,5%. Em outro trabalho, de 2019, acrescido de Carroll, os mesmos autores buscaram considerar a densidade do ar no algoritmo do mesmo modelo de ML para a elaboração da curva (quase sempre tida como constante na literatura), obtendo-a relativamente exata (coeficiente de determinação de 98,6%) e, no processo, fortalecendo o algoritmo para a tarefa de verificar anomalias. A regressão gaussiana também foi usada por Rogers, *et al.* (2019), desta vez visando a modelagem probabilística (e não determinística, como é de costume) heterocedástica da curva, capturando bem a variância dos dados e possibilitando a redução de alarmes falsos e o aumento da sensibilidade a danos.

A importância da ampla utilização dos dados registrados pelo sistema SCADA, que muitos dos trabalhos supracitados buscaram utilizar, não pode ser subestimada. Em um recente trabalho de Li, Liu e Shu (2019), ficou evidente a limitação da modelagem de curva de potência na descoberta de anomalias quando ela leva em conta apenas a velocidade do vento e a potência gerada, uma vez que muitos casos defeituosos, por ausência de dados adicionais esclarecedores, se posicionaram dentro da zona aceitável; isso é exibido na Fig. 4. Novamente, a solução aplicada utilizou o algoritmo

gaussiano, que foi capaz também de classificar os problemas significativamente mais preciso do que o modelo de *support vector machine*, acertando, por exemplo, 66,7% das vezes quando o erro era no sistema de condicionamento de ar, contra 40% do segundo método.

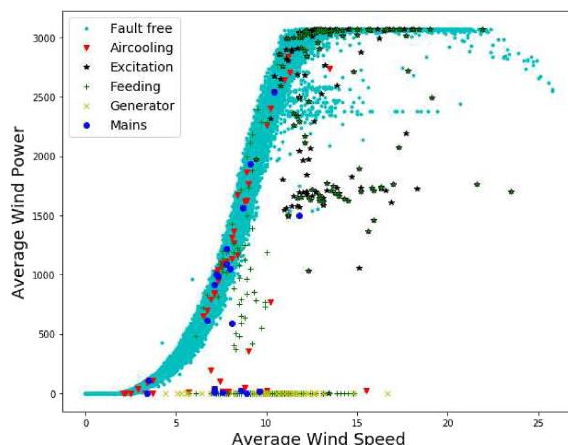


Figura 4 - Curva de potência usual. Fonte: Li, Liu e Shu, 2019.

## 8. CONCLUSÃO

O método de ML tem recebido cada vez mais atenção na área de estudos das energias renováveis devido à característica, dos seus modelos, de aprendizado rápido e que possibilitam previsões e diagnósticos em tempo hábil e com expressiva exatidão. Consequentemente, ele tem sido aplicado em conjunto com técnicas de monitoramento do funcionamento de aerogeradores com vista no seu aprimoramento, e foram essas utilizações, com foco no componente da caixa de engrenagens, que este trabalho procurou exibir, mostrando como o ML os auxilia na tarefa.

Três dos métodos de monitoramento das condições dos aerogeradores com os quais os algoritmos têm trabalhado foram analisados: o das vibrações, o da temperatura e o da curva de potência. O primeiro apresenta facilidade de obtenção de dados, é geralmente assertivo e é o mais utilizado, mas pode ser mais oneroso; o segundo facilita a detecção de falhas pelo fato de apresentar variações padronizadas, mas essas alterações podem ser facilmente provocadas por fatores benignos, além de ser um método que apresenta poucos estudos; e o terceiro é capaz de detectar numerosos tipos de falha e, por não necessitar de sensores, barato, mas costuma apresentar muito ruído e pouca especificidade. O monitoramento mais eficiente e efetivo para a caixa de engrenagens é feito com a união desses métodos, devendo o da curva de potência ser utilizado preliminarmente e os outros dois aplicados em investigações mais a fundo de modo a compreender qual exatamente é a falha.

Com os artigos pesquisados, foi possível entender o papel do ML no monitoramento. Aplicado com o estudo das vibrações, por exemplo, ele pôde prever com ótima antecedência a quebra de dentes de engrenagem e, em outro caso, por meio de uma rede neural, avaliar a vida útil restante do componente; utilizado na análise da temperatura, ele foi capaz de prever uma avaria em um rolamento com mais de um mês de antecedência; e, na tarefa da modelagem da curva de potência, constatou-se como os algoritmos são eficazes, obtendo expressiva exatidão e considerando múltiplos parâmetros, possibilitando até, em alguns casos, a detecção direta do componente em que há falha, sem necessidade da investigação mais criteriosa (e onerosa) dos outros métodos. Esses resultados são extremamente prósperos e deixam clara a necessidade de pesquisas cada vez mais frequentes, detalhadas e integradas nessa área, em especial no método de monitoramento por temperatura, uma vez que avaliamos como um método extremamente promissor, porém está aquém dos demais métodos quanto ao número de pesquisas desenvolvidas.

## REFERÊNCIAS

- A. Kusiak, Z. Zhang, A. Verma, 2013. Prediction, operations, and condition monitoring in wind energy, *Energy*, vol. 60, pp. 1-12.
- Anderson Jr, John D., 1991. *Fundamentals of Aerodynamics*, McGraw-Hill.
- Arco-Verde, Melquesedeque Melo, 2008. Identificação de Falhas em Sistemas Rotativos Empregando Técnicas Não-Lineares, Tese de Doutorado, UFRJ, Rio de Janeiro.
- Azevedo, Henrique Dias Machado de, 2015. Um método para Identificação de falhas em componentes e subcomponentes de turbinas eólicas através de monitoramento de Condição baseado em vibração, Dissertação de Mestrado, UFPE, Recife.
- B. Maru e Peter A. Zotos, 1989. Anti-friction bearing temperature rise for NEMA frame motors, *IEEE Trans. Industry Applications*, vol. 25, n. 5, p. 883–888.
- BOLETIM anual de Geração Eólica. Associação Brasileira de Energia Eólica, São Paulo - SP. Disponível em: <[http://abeeolica.org.br/wp-content/uploads/2019/05/Boletim-Anual\\_2018.pdf](http://abeeolica.org.br/wp-content/uploads/2019/05/Boletim-Anual_2018.pdf)>. Acesso em: 20 de março de 2019.
- BOLETIM mensal de Geração Eólica. Operador Nacional do Sistema Elétrico, Brasília - DF, Dezembro de 2018. Disponível em: <[http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/Boletim\\_Eolica\\_dez\\_2018.pdf](http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/Boletim_Eolica_dez_2018.pdf)>. Acesso em: 20 de março de 2019.
- Braga, A. de P., 2000. *Redes neurais artificiais: teoria e aplicações*, Livros Técnicos e Científicos.
- C.E. Rasmussen, C.K.I. Williams, 2006 *Gaussian Processes for Machine Learning (Adaptive Computation and Machine Learning)*, The MIT Press.
- Cambron, P. et al., 2016. Power curve monitoring using weighted moving average control charts. *Renewable energy*, vol. 94, pp. 126-135.
- Carroll J, Koukoura S, McDonald A, Charalambous A, Weiss S, McArthur S., 2019. Wind turbine gearbox failure and remaining useful life prediction using machine learning techniques, *Wind Energy*, vol. 22, n. 3, pp. 360–375.
- Chamberlain, K., 2015. *WEU Onshore Asset Optimization & Reliability Benchmarking Report: relatório técnico*. Londres (Inglaterra).
- Clifton, A. et al., 2013. Using machine learning to predict wind turbine power output. *Environmental research letters*, vol. 8, n. 2, pp. 024009.
- Coultate, J. K.; Hornemann, M., 2017. Why wind-turbine gearboxes fail to hit the 20-year mark, *Windpower Engineering & Development 2018 Renewable Energy Guidebook*, pp. 24-26.
- De Souto, M. C. P. et al., 2003. *Técnicas de aprendizado de máquina para problemas de biologia molecular*. Sociedade Brasileira de Computação.
- GCube Insurance Services, 2015. *Grinding Gearboxes: relatório técnico*. Newport Beach, CA (Estados Unidos).
- Gonzalez, E. et al., 2019. Using high-frequency SCADA data for wind turbine performance monitoring: A sensitivity study. *Renewable energy*, vol. 131, pp. 841-853.
- HANLY, Steve, 2016. *Vibration Analysis: FFT, PSD, and Spectrogram Basics*. Mide, <https://blog.mide.com/vibration-analysis-fft-psd-and-spectrogram>.
- Harris, T. A., 2001. *Rolling bearing analysis*, John Wiley & Sons.
- Haykin, Simon, 2007. *Redes neurais: princípios e prática*, Bookman Editora.
- Heng, R.B.W., Nor, M.J.M., 2002. Statistical analysis of sound and vibration signals for monitoring rolling element bearing condition, *Appl. Acoust.*, vol. 53, n. 1-3, pp. 211–226.
- IEEE Recommended Practice for Chemical Industry Severe Duty Squirrel-Cage Induction Motors, 600 V and Below, ANSIIIEEE Standard 84 I.
- IEEE Recommended Practice for Chemical Industry Severe Duty Squirrel-Cage Induction Motors, 600 V and Below, ANSIIIEEE Standard 84 I. 1986.
- INTERNATIONAL ELECTROTECHNICAL COMMISSION et al. IEC 61400-12-1: Wind turbines–Part 12-1: Power performance measurements of electricity producing wind turbines. **International Electrotechnical Commission: Geneva, Switzerland**, 2005.
- INTERNATIONAL ELECTROTECHNICAL COMMISSION et al. IEC 61400-4: Wind turbines–Part 4: Standard for design and specification of gearboxes. **International Electrotechnical Commission: Geneva, Switzerland**, 2012.
- J. Herp, M.H. Ramezani, M. Bach-Andersen, N.L. Pedersen, E.S. Nadimi, 2018. Bayesian state prediction of wind turbine bearing failure *Renew. Renewable Energy*, vol. 116, pp. 164-172.
- J.P. Salameh, S. Cauet, E. Etien, A. Sakout, L. Rambault, 2018. Gearbox condition monitoring in wind turbines: a review, *Mechanical Systems and Signal Processing*, vol. 111, pp. 251–264.
- Janssens, O. et al., 2016. Data-driven multivariate power curve modeling of offshore wind turbines. *Engineering Applications of Artificial Intelligence*, vol. 55, pp. 331-338.
- Jena M, Samantaray S., 2016. Data-mining-based intelligent differential relaying for transmission lines including UPFC and wind farms, *IEEE*, vol. 27, n. 1, pp. 8-17.
- MELO JUNIOR, Francisco Erivan de Abreu et al., 2019. Unbalance evaluation of a scaled wind turbine under different rotational regimes via detrended fluctuation analysis of vibration signals combined with pattern recognition techniques, *Energy*, vol. 171, pp. 556-565.
- Kim, H.-E., Andy, C.C., Mathew, J., Eric, Y.H., Choi, B.-K, 2008. Machine Prognostics Based on Health State Estimation Using Svm - Proceedings of the Third World Congress on Engineering Asset Management and Intelligent Maintenance Systems Conference, Beijing, China.



- Lau BCP, Ma EWM, Pecht M, 2012. Review of offshore wind turbine failures and fault prognostic methods - Proceedings of the IEEE Prognostics and System Health Management Conference, Beijing, China.
- LEAHY, Kevin et al. Diagnosing wind turbine faults using machine learning techniques applied to operational data. In: **2016 IEEE International Conference on Prognostics and Health Management (ICPHM)**. IEEE, 2016. p. 1-8.
- LECUN, Yann et al., 1998. Gradient-based learning applied to document recognition, Proceedings of the IEEE, vol. 86, n. 11, pp. 2278-2324.
- Li, S. et al., 2001. Comparative analysis of regression and artificial neural network models for wind turbine power curve estimation. *J. Sol. Energy Eng.*, vol. 123, n. 4, pp. 327-332.
- Li, X., Elasha, F., Shanbr, S., Mba, D., 2019. Remaining Useful Life Prediction of Rolling Element Bearings Using Supervised Machine Learning. *Energies*, vol. 12, n. 14, pp. 2705.
- Li, Y., Liu, S., Shu, L., 2019. Wind turbine fault diagnosis based on Gaussian process classifiers applied to operational data. *Renewable energy*, vol. 134, pp. 357-366.
- Marques, Jeferson, 2004. Turbinas eólicas: modelo, análise, e controle do gerador de indução com dupla alimentação, Dissertação de Mestrado, UFSM, Santa Maria.
- Mitchell, Tom M., 1997. *Machine learning*, McGraw Hill.
- Nova, E. D. C., 2014. Detecção de avarias na caixa de engrenagens de aerogeradores, Tese de Doutorado, ISEP, Porto.
- Ouyang, T., Kusiak, A., He, Y., 2017. Modeling wind-turbine power curve: A data partitioning and mining approach. *Renewable Energy*, vol. 102, pp. 1-8.
- Pandit, R. K., Infield, D., 2018. Gaussian process operational curves for wind turbine condition monitoring. *Energies*, vol. 7, pp. 1631.
- Pandit, R. K., Infield, D., Carroll, J., 2019. Incorporating air density into a Gaussian process wind turbine power curve model for improving fitting accuracy. *Wind Energy*, vol. 22, n. 2, pp. 302-315.
- Park, J. Y. et al., 2014. Development of a novel power curve monitoring method for wind turbines and its field tests. *IEEE Transactions on Energy Conversion*, vol. 29, n. 1, pp. 119-128.
- Pérez-Ortiz, María et al., 2016. A review of classification problems and algorithms in renewable energy applications, *Energies*, vol. 9, n. 8, pp. 607.
- Polak, S., 2000. Gearbox and gear system problems, *Gear Technology-Gaining a Competitive Edge*, vol. 2000, pp. 65-72.
- Ribrant, J., 2006. Reliability performance and maintenance—a survey of failures in wind power systems. *KTH school of Electrical Engineering*, pp. 59-72.
- RIBRANT, Johan; BERTLING, Lina. Survey of failures in wind power systems with focus on Swedish wind power plants during 1997-2005. In: **2007 IEEE power engineering society general meeting**. IEEE, 2007. p. 1-8.
- Rogers, T. J. et al, 2019. Probabilistic modelling of wind turbine power curves with application of heteroscedastic Gaussian Process regression. *Renewable Energy*.
- S.A. Boyer, 1999. SCADA: supervisory control and data acquisition, Instrument Society of America.
- SHENG, Shuangwen. **Wind turbine gearbox reliability database, condition monitoring, and operation and maintenance research update**. National Renewable Energy Lab.(NREL), Golden, CO (United States), 2016.
- Spera, D. A. et al., 1994. *Wind turbine technology: fundamental concepts of wind turbine engineering*, ASME press.
- Stack, J. R., Habetler, T. G., Harley, R. G., 2004. Fault classification and fault signature production for rolling element bearings in electric machines. *IEEE Transactions on Industry Applications*, vol. 40, n. 3, pp. 735-739.
- Vitorino, Cássia Resende Silva, 2012. Modelagem dinâmica de caixa multiplicadora de velocidades de aerogeradores, Monografia, UnB, Brasília.
- W. Ackerman, W. Block, 1992. Understanding supervisory systems, *IEEE*, vol. 5, n. 4, pp. 37-40.
- Wang, J., Liang, Y., Zheng, Y., Gao, R.X., Zhang, F, 2019. An integrated fault diagnosis and prognosis approach for predictive maintenance of wind turbine bearing with limited samples, *Renewable Energy*, vol. 145, pp. 642–650.
- WEBB, Andrew R., 2003. *Statistical pattern recognition*, John Wiley & Sons.
- Xinyan Zhang, Shan He, Peiyi Zho e Weiqing Wang, 2008. Summarization and study of fault diagnosis technology of the main components of wind turbine generator system, *Proc. IEEE International Conference on Sustainable Energy Technologies*, Singapura.
- ZHAO, Minghang et al., 2017. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes, *IEEE Transactions on Industrial Electronics*, vol. 65, n. 5, pp. 4290-4300.

## **MACHINE LEARNING APPLICATIONS FOR IMPROVEMENT OF WIND TURBINE MONITORING METHODS WITH FOCUS ON GEARBOXES**

**Abstract.** *The gearbox is one of the most important components in wind turbine operation and one of the ones which require the most attention from operators when it comes to maintenance, as it is among the five parts that fail most frequently, as well as being the one responsible for the largest total downtime. In this sense, this paper aims to display how the technology of machine learning (ML) algorithms has been applied recently with the aim of improving condition and system performance monitoring methods, focusing on the aforementioned part. Related to the concept of artificial intelligence, ML is the learning of a computerized machine from a previously provided data set so that it can produce new data. It has shown itself to be very useful in the field of maintenance, enabling, through models such as neural networks and Gaussian processes, the prediction of faults well in advance, amplifying the action of traditional methods such as vibration, temperature and power curve data analysis and avoiding costs and expenses associated with corrections through the facilitation of prevention. The results of this literature review indicate promising paths for the development of studies in the area, particularly with regard to temperature monitoring.*

**Key words:** *Machine Learning, Wind Energy, Gearboxes*