

PREVISÃO DE VELOCIDADE DOS VENTOS NAS TURBINAS EÓLICAS: UMA REVISÃO DE MODELOS EXISTENTES E SUAS APLICAÇÕES NA MANUTENÇÃO

Rafael da Mata Oliveira Souza (CREATION Research Group/ UFRN)

Mario Orestes Aguirre González (CREATION Research Group/ UFRN)

Luana Pereira Nogueira (CREATION Research Group/ UFRN)

Dayse da Mata Oliveira Souza (Universidade Federal do Rio Grande do Norte/ UFRN)



Entender o comportamento da velocidade dos ventos tem sido alvo de discussões na comunidade científica, a qual busca desenvolver modelos de previsão, a fim de obter resultados que possam apoiar o controle de operação e subsidiar o desenvolvimento de planos de otimização do setor. Dessa forma, surge o questionamento do quanto a comunidade científica avançou nessa temática e se há estudos sobre o planejamento de manutenção de parques eólicos com o uso de recursos digitais modernos. Com base nisso, este trabalho tem o objetivo de identificar quais modelos de previsão já foram desenvolvidos e como eles se aplicam aos planos de parada para manutenção de turbinas eólicas, com o uso de digital twin. Para isso, foi realizada uma Revisão Bibliográfica Sistemática, a qual identificou 123 artigos, em que modelos de Long Short-Term Memory, redes neurais e Numerical Weather Prediction foram métodos mais empregados em propostas de novos modelos híbridos com maior precisão nos resultados. Quanto à manutenção, um modelo de Auto Regressive Integrated Moving Average foi aplicado para previsão de vento que contou com dois algoritmos de decisão para parada de manutenção, sendo um probabilístico e um embasado na Teoria das Opções Reais. Além disso, foi identificada a aplicação do spatiotemporal com o digital twin, para o desenvolvimento de modelo de previsões simultâneo ao monitoramento dos dados em tempo real. Por fim, verificou-se que os modelos de curtíssimo e curto prazo utilizam métodos de inteligência artificial e estatísticos, enquanto os de médio e longo prazo são os físicos.

Palavras-chave: Energia Eólica, Manutenção de Parques Eólicos, Previsão de velocidade do Vento, Revisão Bibliográfica Sistemática.

1. Introdução

A progressiva necessidade global por energia na busca do desenvolvimento econômico tendo como objetivo uma melhor qualidade de vida, aliada à preocupação com o crescimento das emissões de gases poluentes na atmosfera, tem ocasionado a procura por opções de energia que possam ser abundantes, renováveis e limpas.

Nesse cenário, de acordo com o *Global Wind Energy Council* (GWEC), a energia eólica desponta, atualmente, como um dos setores industriais com rápido crescimento no mundo, se configurando como uma importante fonte de investimento que gerou entre 2015 e 2019, mais de US\$ 652 bilhões em investimentos. Expandir o potencial eólico instalado para 2 terawatts de capacidade até 2030 geraria um investimento anual adicional de aproximadamente US\$ 207 bilhões à US\$ 2 trilhões (GWEC, 2020).

Esse aumento da demanda pela fonte energética gera novos desafios tecnológicos e científicos. A previsão da velocidade do vento é um desses desafios, pois a velocidade é considerada um importante fator para a produção eólica, sendo uma variável que se altera por diferentes fatores (SILVA, 2017). Além disso, essa previsão, segundo Oliveira (2020), é relevante para a energia eólica na matriz elétrica brasileira para poupar dificuldades na operação em tempo real, como o controle de tensão, manuseio de equipamentos e economicidade da operação.

A previsão consiste em um método para estimar um valor futuro com o uso de dados históricos. Existem diversos métodos para essa simulação, os autores Kumar, Pal e Tripathi (2020) separaram a previsão em modelos baseados na escala temporal, em dados de observações históricas/meteorológicas e em técnicas/modelos físicos e matemáticos. Outros pesquisadores consideraram os métodos classificados em previsão numérica do tempo, estatísticos tradicionais, Inteligência Artificial (IA) e híbridos (LIU; TIAN; LI, 2012).

Apesar da existência de muitas pesquisas sobre métodos de previsão, envolvendo esses componentes digitais, uma dúvida permanece em evidência, quais são os métodos que esses modelos de previsão empregam em aplicações de planejamento de manutenção nos parques eólicos?

Nessa perspectiva, este trabalho se propôs em analisar os diferentes modelos de previsão de velocidade do vento desenvolvidos pela pesquisa acadêmica, com o objetivo principal de identificar quais modelos de previsão já foram desenvolvidos e como eles se aplicam aos planos de parada para manutenção de turbinas eólicas, especialmente com o uso de *digital twin*.

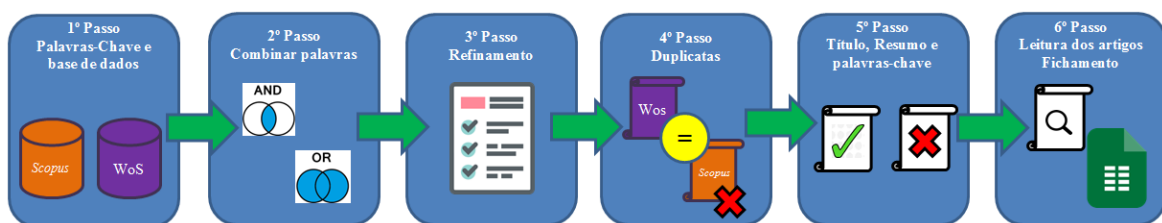
A pesquisa está dividida em 5 seções. Além dessa primeira parte que apresenta a introdução, a Seção 2 contém o método da pesquisa. A Seção 3 descreve a análise descritiva dos resultados obtidos na revisão bibliográfica. Na Seção 4 faz-se a discussão dos resultados da revisão com a classificação de modelos de previsão e suas aplicações à manutenção e *digital twin*. Por fim, Seção 5 trata das considerações finais e recomendações para pesquisas futuras.

2. Procedimentos metodológicos

O trabalho contou com uma pesquisa exploratória, apoiada na Revisão Bibliográfica Sistemática (RBS), um recurso que pode ser utilizado para estruturar trabalhos publicados sobre um conteúdo característico de pesquisa, possibilitando ao pesquisador desenvolver uma reunião do que existe sobre o tema (BIOLCHINI *et al.*, 2007).

O procedimento da RBS contemplou seis etapas. A primeira etapa resultou no planejamento da RBS com a identificação das palavras-chave por meio de uma pesquisa exploratória sobre o tema, buscando em dissertações e artigos científicos. Também nesta etapa, foram definidas as bases de dados de periódicos científicos, sendo a *Scopus* e *Web of Science* (WoS), as quais possuem uma ampla extensão de artigos publicados sobre diferentes trabalhos de pesquisa. A Figura 1 mostra o passo a passo do método da RBS feito neste estudo.

Figura 1 - Etapas da RBS deste trabalho



Fonte: Elaboração própria (2024)

A segunda etapa consistiu em definir uma combinação de palavras-chave, por meio do operador booleano “AND”, no sistema de busca das bases, resultando em uma concordância ao tema da pesquisa. Dessa forma, foram definidas: *wind speed AND probabilistic forecasting*; *wind speed AND artificial intelligence*; *wind speed AND internet of things*; e *wind speed AND digital twin*. Identificou-se um total de 3.816 publicações nas duas bases de pesquisa.

A terceira etapa envolveu um refinamento na seleção de periódicos científicos, de forma a priorizar publicações com características em comum. Nessa etapa, foram escolhidos trabalhos científicos publicados no período de 2019 a 2023, da área *energy* (energia); publicação do

tipo *article* (artigo), ou seja, artigos de periódicos; e linguagem *English* (inglês). Nessa etapa, foram identificados 459 artigos.

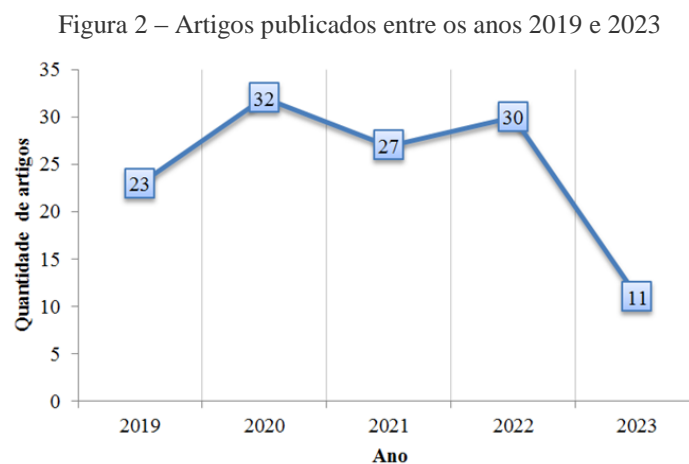
A quarta etapa correspondeu à remoção de artigos duplicados, pois devido ao fato de a coleta de dados aparecer em mais de uma base acadêmica, existiu a possibilidade de um ou mais artigos serem identificados em ambas as bases. Sendo assim, restaram 323 artigos.

A quinta etapa consistiu na leitura dos títulos e resumos dos artigos, considerado a parte preliminar do conteúdo que envolveu a pesquisa, apenas os artigos que apresentaram assuntos relevantes ao tema desta pesquisa foram considerados. Somente 219 artigos foram aceitos nessa etapa.

Para a sexta etapa, foi realizada a leitura completa dos artigos e o fichamento de dados e informações em uma planilha eletrônica, que fossem pertinentes a pesquisa deste trabalho. Ao mesmo tempo, caso existisse algum artigo com pouca informação relevante ao tema, ele seria também descartado nessa etapa. Assim, a amostra final foi constituída por 123 artigos.

3. Análise descritiva

Para uma análise preliminar dos 123 artigos analisados, tem-se a evolução da quantidade de artigos publicados nas bases da *WoS* e *Scopus*. A fim de conhecer a dimensão geral do quanto a pesquisa sobre o tema evoluiu ao longo dos anos, o Figura 2 demonstra o número de artigos publicados pelo período de 2019 até maio de 2023, data em que esta pesquisa foi realizada.



Fonte: Elaboração própria (2024)

Pode-se observar que no ano 2019 foram identificados 23 artigos científicos; já em 2020 essa quantidade aumentou para 32 artigos. No ano seguinte, 2021, uma leve queda para 27 publicações, entretanto a quantidade voltou a aumentar para 30 artigos em 2022. Até o dia 5

de maio de 2023, data em que foi feita a coleta de dados dessa pesquisa, 11 artigos foram publicados.

Outro dado a ser destacado são as publicações de artigos científicos por diferentes editoras, pois elas dão uma dimensão das áreas de interesse. O periódico com mais publicações foi a *Applied Energy*, seguida pela *Energy Conversion and Management* e *Renewable Energy*.

4. Resultados

Essa seção aborda a análise sobre a discussão dos resultados obtidos na leitura completa dos artigos, por meio do cruzamento das informações dessas pesquisas.

4.1. Escala temporal de previsão

Os modelos podem prever os resultados em diferentes intervalos de tempo. Sua classificação varia quanto à aplicação que a previsão se insere. O Quadro 1 mostra os diferentes períodos e suas aplicações, segundo Soman *et al.* (2010) e Hanifi *et al.* (2020).

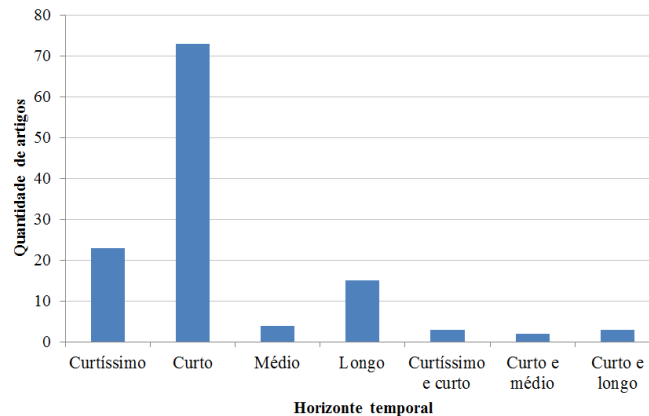
Quadro 1 - Escala temporal dos modelos de previsão de vento

Horizonte Temporal	Escala Temporal	Aplicações
Curtíssimo Prazo	Alguns segundos a 30 minutos	<ul style="list-style-type: none"> • Ações de operação e regulação, em tempo real, na rede.
Curto Prazo	Entre 30 minutos a 6 horas	<ul style="list-style-type: none"> • Planejamento sobre o estado das cargas de rede; • Tomada de decisão de ligar ou desligar os geradores com resposta rápida; • Decisões operacionais de segurança para o mercado energético.
Médio Prazo	Entre 6 horas a 1 dia	<ul style="list-style-type: none"> • Tomada de decisão de ligar ou desligar geradores; • Espaço de tempo de segurança para o mercado de energia do dia seguinte (<i>day-ahead market</i>); • Impactos na determinação do preço da energia.
Longo Prazo	Entre 1 dia a 1 semana ou mais	<ul style="list-style-type: none"> • Destinação de reservas de potência; • Planejamento de operações de manutenção e otimização de custos.

Fonte: Adaptado de Soman *et al.* (2010)

Percebe-se que para realização de planejamentos de manutenção em parques eólicos, é mais comum o uso de modelos com previsões de espaço temporal mais longo, ou seja, com um espaço de um dia a uma semana ou mais. Considerando esses conceitos, a Figura 3 mostra a quantidade de artigos da revisão que estudaram modelos de previsão de vento de acordo com essa classificação. A maioria das pesquisas desenvolveram previsões para curtíssimo e curto prazo.

Figura 3 - Quantidade de artigos na revisão classificados pelo horizonte temporal



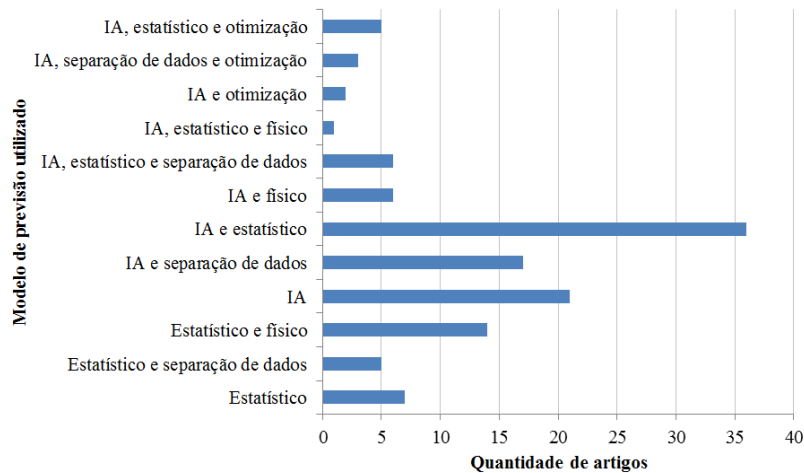
Fonte: Elaboração própria (2024)

4.2. Classificação dos modelos de previsão

Os modelos de previsão podem ser classificados em físico, estatístico e de IA. Os métodos físicos usam modelos numéricos como o *Numerical Weather Prediction* (NWP), que empregam fatores como pressão, umidade e temperatura em um modelo intuitivo (TIAN; CHEN, 2021). Os modelos estatísticos lidam com a série de dados históricos de velocidade dos ventos para estabelecer um modelo probabilístico que esteja relacionado a estes dados (TIAN; LI, H.; LI, F., 2021), um exemplo disso é o *Auto Regressive Integrated Moving Average* (ARIMA). Para os métodos de IA, suas previsões conseguem analisar dados históricos não lineares de maneira mais efetiva, por isso essa abordagem tem sido bastante usada para previsões de curtíssimo ou curto prazo (ZHAO *et al.*, 2019). Para essa categoria, existem os modelos *Recursive Neural Networks* (RNN) e o *Long Short-Term Memory* (LSTM) como exemplos.

Existem modelos que são uma combinação de dois ou mais métodos para previsão, chamados de híbridos. É comum também a presença de outros tipos de algoritmos, como o de separação de dados ou separação de sinais, em que a série de dados da velocidade do vento é dividida em sequências simples, de forma a evitar algum dado perdido (TIAN; LI, H.; LI, F., 2021). O *Empirical Mode Decomposition* (EMD) encontra-se nessa categoria. A Figura 4 mostra quais artigos na revisão se qualificaram com base nessas ideias, como pode-se observar a preferência pelos modelos híbridos.

Figura 4 - Tipos de modelos definidos pelos artigos na revisão



Fonte: Elaboração própria (2024)

4.3. Nomenclatura dos modelos

Para facilitar a leitura e identificação de alguns modelos de previsão nos seguintes tópicos, o Quadro 2 apresenta a nomenclatura de alguns modelos conhecidos e identificados nesta revisão, representados com suas respectivas abreviações.

Quadro 2 - Nomenclatura de alguns modelos de previsão

Físico	<i>Numerical Weather Prediction (NWP)</i>
Estatístico	<i>Kernel Density Estimation (KDE)</i> <i>Auto Regressive Moving Average (ARMA)</i> <i>Auto Regressive Integrated Moving Average (ARIMA)</i>
IA	<i>Long Short-Term Memory (LSTM)</i> <i>Gated Recurrent Unit (GRU)</i> <i>Support Vector Machine (SVM)</i> <i>Echo State Network (ESN)</i> <i>Deep Learning (DL)</i> <i>Extreme Learning Machine (ELM)</i>
Separação de dados	<i>Variational Mode Decomposition (VMD)</i> <i>Empirical Mode Decomposition (EMD)</i> <i>Local Mean Decomposition (LMD)</i>
Otimização	<i>Particle Swarm Optimization (PSO)</i> <i>Chicken Swarm Optimization (CSO)</i> <i>Moth Flame Optimization (MFO)</i>

Fonte: Elaboração própria (2024)

4.4. Os modelos de previsão mais usados no curtíssimo prazo

Os modelos de previsão de vento de curtíssimo prazo preveem os resultados em um período de alguns segundos a 30 minutos (SOMAN *et al.*, 2010; HANIFI *et al.*, 2020). Muitos autores propuseram novos modelos híbridos, de forma a obter resultados com melhores precisões, conforme está evidenciado no Quadro 3. Nessa categoria de pequeno espaço de tempo, os

modelos de IA representaram a preferência no desenvolvimento da maioria dos modelos híbridos. O LSTM foi o mais usado, com 10 artigos.

Quadro 3 – Pesquisas que desenvolveram modelos para **curtíssimo prazo**

Modelos mais usados	Autores	Aplicação
LSTM	Wang <i>et al.</i> (2020)	Modelo de LSTM com EMD e KDE para decompor dados da série temporal de velocidade do vento em diversas subséries para reduzir a influência não estacionária das informações.
VMD	Gendeel <i>et al.</i> (2021)	Modelo VMD para separar diferentes funções intrínsecas em combinação com a previsão determinística por meio do SVM.
Redes Neurais	Niu e Wang (2019)	Modelo que combina <i>Elmann Neural Network</i> (ENN) e <i>Back Propagation Neural Network</i> (BPNN).

Fonte: Elaboração própria (2024)

4.5. Os modelos de previsão mais usados no curto prazo

Os modelos de previsão de velocidade do vento de curto prazo costumam trabalhar em uma duração de 30 segundos a 6 horas (SOMAN *et al.*, 2010; HANIFI *et al.*, 2020). Conforme a maioria das pesquisas, muitos autores propuseram novos modelos híbridos, sendo a maioria de preferência a modelos de IA com algoritmos de separação de dados. O Quadro 4 destaca alguns dos trabalhos realizados.

Quadro 4 – Pesquisas que desenvolveram modelos para **curto prazo**

Modelos mais usados	Autores	Aplicação
Redes Neurais	Shang <i>et al.</i> (2022)	Modelo de <i>Convolutional Neural Network</i> (CNN) para extrair informação da série temporal da velocidade do vento.
LSTM	Wang <i>et al.</i> (2022)	Uso do LSTM bidirecional, uma extensão do modelo que usa informações das condições do passado e futuro para previsão das condições no presente.
ELM	Yin e Liu (2022)	Modelo de ELM com o ESN como bases de aprendizado para prever dados corrigidos de geração eólica.

Fonte: Elaboração própria (2024)

Os modelos de IA são capazes em lidar com dados não lineares complexos da velocidade do vento (CHEN; STAUPE-DELGADO, 2022) e permitem extrair problemas de alto-nível, graças a sua grande quantidade de camadas ocultas (LI; SHEN; ZHOU, 2023).

4.6. Os modelos de previsão mais usados no médio prazo

Nos modelos de previsão de velocidade do vento de médio prazo, os resultados são estimados em um tempo de 6 horas a 1 dia (SOMAN *et al.*, 2010; HANIFI *et al.*, 2020). Diversos modelos híbridos foram propostos, de forma a obter resultados com melhores precisões. O

modelo mais utilizado foi o NWP, com 4 artigos. O Quadro 5 fez menção a artigos com os modelos híbridos desenvolvidos.

Quadro 5 – Pesquisas que desenvolveram modelos para **médio prazo**

Modelos mais usados	Autores	Aplicação
NWP	Wen <i>et al.</i> (2020)	Modelo de NWP para previsões diárias em conjunto com o KDE para reduzir a dimensão de dados do NWP.
Fuzzy	Xing <i>et al.</i> (2022)	Modelo <i>Adaptive Neuro-Fuzzy Inference System</i> (ANFIS) para correção de previsões e melhoria da curva de potência.

Fonte: Elaboração própria (2024)

4.7. Os modelos de previsão mais usados no longo prazo

Os modelos de previsão de velocidade do vento de longo prazo preveem os resultados em um intervalo de 1 dia a 1 semana ou mais (SOMAN *et al.*, 2010; HANIFI *et al.*, 2020). Muitos artigos desenvolveram suas pesquisas propondo novos modelos híbridos, ou seja, combinando modelos físicos, com estatísticos, de IA, além de outros tipos algoritmos, o Quadro 6 ressalta alguns dos autores.

Quadro 6 – Pesquisas que desenvolveram modelos para **longo prazo**

Modelos mais usados	Autores	Aplicação
NWP	Salazar <i>et al.</i> (2022)	Abordou o uso do NWP com o algoritmo <i>Spatiotemporal encoding</i> .
Redes Neurais	Brahimi (2019)	Modelo <i>Artificial Neural Network</i> (ANN) para previsões diárias de velocidade do vento.
Fuzzy	Flores <i>et al.</i> (2019)	Modelo <i>Fuzzy</i> com ANN para análise de comparação entre modelos de IA com modelos estatísticos.

Fonte: Elaboração própria (2024)

Assim como foi visto no item anterior, o NWP está bem presente em previsões de médio e longo prazo. Como os modelos físicos contam com análise teórica do comportamento da velocidade do vento e representação por fórmulas matemáticas de computação numérica, esse tipo de modelo costuma ser usado em previsões com maior espaço de tempo (LI; SHEN; ZHOU, 2023). Como representação geral, a Figura 5 descreve os resultados dos modelos de previsão mais usados na revisão em relação a cada horizonte temporal.

Figura 5 - Os modelos mais usados em previsões pelo horizonte de tempo

CURTISSIMO PRAZO			CURTO PRAZO			MÉDIO PRAZO			LONGO PRAZO		
Modelo	Conceito	Artigos	Modelo	Conceito	Artigos	Modelo	Conceito	Artigos	Modelo	Conceito	Artigos
LSTM	IA	10	Redes Neurais	IA	27	NWP	Físico	4	NWP	Físico	5
VMD	Separação de dados	6	LSTM	IA	19	Fluzzy	IA	2	Redes Neurais	IA	5
Redes Neurais	IA	5	ELM	IA	9	LSTM	IA	1	Fluzzy	IA	3
EMD	Separação de dados	5	VMD	Separação de dados	8	ELM	IA	1	Weibull	Estatística	2
KDE	Estatística	5	EMD	Separação de dados	8	Gaussiana	Estatística	1	LSTM	IA	2
GRU	IA	4	KDE	Estatística	7	KDE	Estatística	1	Quantílico	Estatística	2
SVM	IA	3	PSO	Otimização	7	PSO	Otimização	1	VMD	Separação de dados	1
Gaussiana	Estatística	3	ESN	IA	6				MFO	Otimização	1
NWP	Físico	2	NWP	Físico	5				Gaussiana	Estatística	1
Fluzzy	IA	2	Fluzzy	IA	5				DL	IA	1
ESN	IA	2	ARIMA	Estatística	4				ARIMA	Estatística	1
ARIMA	Estatística	1	SVM	IA	2				EMD	Separação de dados	1
ARMA	Estatística	1	GRU	IA	2						
DL	IA	1	DL	IA	2						
CSO	Otimização	1	LMD	Separação de dados	1						

Fonte: Elaboração própria (2024)

4.8. O uso dos modelos na manutenção

Produtores e operadores dos parques eólicos procuram constantemente por propostas para reduzir custos de Operação & Manutenção (O&M), melhorar a confiabilidade e proteção, e aumentar o retorno financeiro (PANDIT; INFIELD, 2017). Nesta revisão, foram identificados dois artigos que trataram de modelos de previsão de vento aplicados para manutenção nos parques eólicos.

O modelo de previsão proposto por Pelajo *et al.* (2019) combina o uso do ARIMA, para uma previsão de velocidade em curto prazo, com modelos sazonais em um longo prazo. Para análise de custos, os autores usaram um modelo programado estocástico chamado Newave. Com os dados de previsão e de custos, a análise de decisão de parada para manutenção foi feita em dois modelos, um modelo probabilístico e um baseado na Teoria de Opções Reais americanas em uma simulação de mínimos quadrados de Monte Carlo. Numa janela de oportunidade de manutenção de 18 semanas, a cada 1 semana eram realizados as previsões e os cálculos das perdas de produção eólica futuras, caso a manutenção pudesse ser feita de imediata naquele tempo. A ideia era identificar o melhor momento para se aplicar a manutenção, com o prejuízo de geração mínima, dentro dessa janela de 18 semanas.

O trabalho de Pandit, Kolios e Infield (2020) envolveu modelos de Markov e LSTM para análise na precisão de dados de velocidade do vento e de altura das ondas do mar. Nesse caso, o modelo de Markov realizou as previsões de velocidade de maneira bem efetiva, enquanto o LSTM obteve resultados da altura das ondas com incertezas baixas. Esses fatores são preponderantes para o planejamento de manutenção de turbinas eólicas *offshore*, pois elas influenciam na economia de custos operacionais.

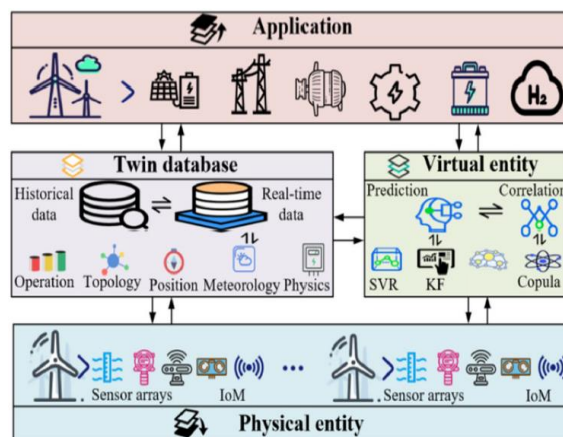
4.9. O uso dos modelos no *digital twin*

O trabalho de Li, Shen e Zhou (2023) aproveitou o *digital twin* como um mecanismo de feedback em tempo real para que o seu modelo de previsão de vento pudesse mudar os dados iniciais em tempo real, chamado de *framework* de correlação espacial de múltiplas turbinas (*Predictable Multi-turbines Spatiotemporal Correlations Framework – PMTSTCF*).

Esse novo modelo usa o *digital twin* para monitorar em tempo real o comportamento dos ventos na turbina principal, ou “alvo” conforme os autores nomearam, enquanto as previsões são feitas. Várias turbinas eólicas contendo sensores que captam dados físicos são usadas para análise e cálculo do modelo, esses dados estão interligados em uma vasta rede comunicação de fibra ótica para possibilitar um canal de compartilhamento chamado de Internet das Máquinas (*Internet of Machines – IoM*), uma variante da Internet das Coisas. São essas informações e o auxílio da tecnologia do *digital twin* que fundamentam a aquisição de dados em tempo real. Caso ocorresse alguma mudança nos dados dos ventos, as informações eram repassadas para os modelos de previsão. Os resultados mostraram previsões mais precisas em um tempo de 4 horas, permitindo análises no curto prazo.

A Figura 6 mostra uma representação esquemática do processo. Os modelos de previsão envolvidos na pesquisa foram o *Support Vector Regression* (SVR) e o *Kalman Filter* (KF).

Figura 6 - Modelo PMTSTCF baseado em *digital twin* para previsão em tempo real



Fonte: Adaptado de Li, Shen e Zhou (2023)

5. Considerações finais

Este trabalho teve como objetivo elencar os métodos e técnicas de previsão de velocidade do vento nos parques eólicos e suas aplicações no planejamento de manutenção e *digital twin*. Com a utilização da RBS, pôde-se identificar que modelos são classificados como: físico, estatístico e de IA. A combinação entre eles com outros algoritmos de otimização e separação

de dados pode ser considerada como modelo híbrido. Além disso, existem quatro categorias que levam em consideração o espaço temporal na previsão, sendo o de curtíssimo prazo, curto prazo, médio prazo e longo prazo.

Com relação aos modelos mais usados, no curtíssimo prazo e curto prazo, modelos de LSTM e de redes neurais convencionais como CNN, RNN e ANN. Além disso, algoritmos de separação de dados como EMD e VMD também foram destaque em muitos artigos. Para o caso de médio e longo prazo, muitos autores propuseram seus modelos híbridos utilizando o NWP com modelos de IA como LSTM, redes neurais convencionais e a lógica *Fuzzy*.

Com relação às pesquisas sobre planejamento de manutenção em parques eólicos com previsões de velocidade dos ventos, apenas dois artigos trataram sobre esse assunto. Um artigo usou modelo ARIMA em conjunto com ferramentas de cálculo de preço de mercado energético *spot*. Outra pesquisa utilizou os modelos LSTM e Markov para estimar dados de custo operacional em um parque eólico *offshore*. Para o uso de previsões com *digital twin*, esta ferramenta foi aplicada para monitoramento em tempo real e para correções de dados de previsão de vento.

Conclui-se que i) o período de previsão pode estar representado como curtíssimo, curto, médio e longo prazo; ii) a ferramenta de previsão a curtíssimo e curto prazo de maiores preferências são a LSTM e modelos de redes neurais. Para médio e longo prazo, métodos envolvendo NWP são a preferência nas pesquisas, assim como LSTM e redes neurais; iii) para planejamentos de manutenção, existem dois modelos de decisão para escolher o momento certo para parar a produção, sendo um probabilístico e um baseado na Teoria de Opções Reais, ambos os modelos dependem de dados de previsão da velocidade do vento, como é o caso do ARIMA; iv) o *digital twin* pode ser usado como uma ferramenta de monitoramento em tempo real para um modelo de previsão que usa o *spatiotemporal correlation*, além realizar ajustes e correções durante as previsões; e v) ainda é necessário mais pesquisas voltadas para planejamento de manutenção e de ferramentas de *digital twin*.

Sugere-se então a realização de mais pesquisas sobre os temas de previsão de velocidade do vento, planejamento de paradas para manutenção e *digital twin*.

6. Agradecimentos

Agradecimento a todos que contribuíram para o desenvolvimento do presente artigo e ao CNPq (Processo N.º 406746/2022-2PD-00553-0045/2016) pelo apoio na realização desse estudo.

REFERÊNCIAS

- BIOLCHINI, Jorge Calmon de Almeida *et al.* Scientific research ontology to support systematic review in software engineering. **Advanced Engineering Informatics**, [Reino Unido], v. 21, n. 2, p. 133-151, abr. 2007. DOI: <https://doi.org/10.1016/j.aei.2006.11.006>.
- BRAHIMI, Tayeb. Using artificial intelligence to predict wind speed for energy application in Saudi Arabia. **Energies**, Basileia, Suíça, v. 12, n. 24, 16 p., dez. 2019. DOI: <https://doi.org/10.3390/en12244669>.
- CHEN, Hao; STAUPE-DELGADO, Reidar. Exploiting more robust and efficacious deep learning techniques for modeling wind power with speed. **Energy Reports**, [Amesterdã, Países Baixos] v. 8, n. 1, p. 864-870, abr. 2022. DOI: <https://doi.org/10.1016/j.egyr.2021.11.151>.
- FLORES, Juan J. *et al.* Soft computing methods with phase space reconstruction for wind speed forecasting—a performance comparison. **Energies**, Basileia, Suíça, v. 12, n. 18, 19 p., set. 2019. DOI: <https://doi.org/10.3390/en12183545>.
- GENDEEL, Mohammed *et al.* Deterministic and probabilistic interval prediction for wind farm based on VMD and weighted LS-SVM. **Energy Sources**, [Estados Unidos], v. 43, n. 7, p. 800-814, 2021. DOI: <https://doi.org/10.1080/15567036.2019.1632980>.
- GLOBAL WIND ENERGY COUNCIL. **Energia eólica**: um pilar para a recuperação da economia global. Bélgica: GWEC, 2020. 5 p. Disponível em: <https://gwec.net/wp-content/uploads/2020/06/PT-Green-Recovery-Statement.pdf>. Acesso em: 2 maio 2021.
- HANIFI, S. *et al.* A critical review of wind power forecasting methods—past, present and future. **Energies**, Basileia, Suíça, v. 13, n. 15, 24 p., jul. 2020. DOI: <https://doi.org/10.3390/en13153764>.
- KUMAR, Vijay; PAL, Yash; TRIPATHI, M. M. PSO-tuned ANN-based prediction technique for penetration of wind power in grid. In: INTERNATIONAL CONFERENCE ON RECENT INNOVATIONS IN COMPUTING (ICRIC), 2., mar. 2019, Jamu e Caxemira, Índia. **Proceedings of [...]**. Jamu e Caxemira, Índia: Springer, 2020. p. 485-494. Lecture Notes in Electrical Engineering, v. 597 DOI: https://doi.org/10.1007/978-3-030-29407-6_35.
- LI, Yang; SHEN, Xiaojun; ZHOU, Chongcheng. Dynamic multi-turbines spatiotemporal correlation model enabled digital twin technology for real-time wind speed prediction. **Renewable Energy**, [Reino Unido], v. 203, p. 841-853, fev. 2023. DOI: <https://doi.org/10.1016/j.renene.2022.12.121>.
- LIU, Hui; TIAN, Hong-qi; LI, Yan-fei. Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. **Applied Energy**, [Reino Unido], v. 98, p. 415-424, out. 2012. DOI: <https://doi.org/10.1016/j.apenergy.2012.04.001>.

NIU, Xinsong; WANG, Jiyang. A combined model based on data preprocessing strategy and multi-objective optimization algorithm for short-term wind speed forecasting. **Applied Energy**, [Reino Unido], v. 241, p. 519-539, maio 2019. DOI: <https://doi.org/10.1016/j.apenergy.2019.03.097>.

OLIVEIRA, Felipe Maia Barbosa. **Previsão da velocidade do vento utilizando redes neurais artificiais e modelos autorregressivos**. 2020. 73 f. Dissertação (Mestrado em Sistemas de Energia) – Programa de Pós-Graduação em Sistemas de Energia, Universidade Tecnológica Federal do Paraná, Curitiba, 2020. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/23577>. Acesso em: 7 maio 2023.

PANDIT, Ravi Kumar; INFIELD, David. Using Gaussian process theory for wind turbine power curve analysis with emphasis on the confidence intervals. *In: 2017 INTERNATIONAL CONFERENCE ON CLEAN ELECTRICAL POWER (ICCEP)*, 6., jun. 2017, Santa Margherita Ligure, Itália. **Proceedings [...]**. Santa Margherita Ligure, Itália: IEEE, 2017. p. 744-749. DOI: <https://doi.org/10.1109/ICCEP.2017.8004774>.

PANDIT, Ravi Kumar; KOLIOS, Athanasios; INFIELD, David. Data-drive weather forecasting models performance comparison for improving offshore wind turbine availability and maintenance. **IET Renewable Power Generation**, [Reino Unido], v. 14, n. 13, p.2386-2394, 14 set. 2020. DOI: <https://doi.org/10.1049/iet-rpg.2019.0941>.

PELAJO, Jonas C. *et al.* Wind farm generation forecast and optimal maintenance schedule model. **Wind Energy**, [Reino Unido], v. 22, n. 12, p. 1872-1890, dez. 2019. DOI: <https://doi.org/10.1002/we.2405>.

SALAZAR, Andrés A. *et al.* Deep generative model for probabilistic wind speed and wind power estimation at a wind farm. **Energy Science & Engineering**, [Reino Unido], v. 10, n. 6, p. 1855-1873., fev. 2022. DOI: <https://doi.org/10.1002/ese3.1086>.

SHANG, Zhihao *et al.* Wind speed forecasting using attention-based causal convolutional network and wind energy conversion. **Energies**, Basileia, Suíça, v. 15, n. 8, 23 p., abr. 2022. DOI: <https://doi.org/10.3390/en15082881>.

SILVA, Pollyanna Kelly de Oliveira. **Análise e previsão de curto prazo do vento através de modelagem estatística em áreas de potencial eólico no Nordeste do Brasil**. 2017. 166 f. Tese (Doutorado em Meteorologia) – Programa de Pós-Graduação em Meteorologia, Universidade Federal de Campina Grande, Campina Grande, 2017. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/1414>. Acesso em: 6 maio 2021.

SOMAN, Saurabh S. *et al.* A review of wind power and wind speed forecasting methods with different time horizons. *In: NORTH AMERICAN POWER SYMPOSIUM 2010*, set. 2010, Arlington, Estados Unidos. **Proceedings [...]**. Arlington, Estados Unidos: IEEE, 2010. p. 1-8. DOI: <https://doi.org/10.1109/NAPS.2010.5619586>.

TIAN, Zhongda; CHEN, Hao. Multi-step short-term wind speed prediction based on integrated multi-model fusion. **Applied Energy**, [Reino Unido], v. 298, 15 p., 15 set. 2021. DOI: <https://doi.org/10.1016/j.apenergy.2021.117248>.

TIAN, Zhongda; LI, Hao; LI, Feihong. A combination forecasting model of wind speed based on decomposition. **Energy Reports**, [Amsterdã, Países Baixos], v. 7, p. 1217-1233, nov. 2021. DOI: <https://doi.org/10.1016/j.egy.2021.02.002>.

WANG, Kai *et al.* A compound framework for wind speed forecasting based on comprehensive feature selection, quantile regression incorporated into convolutional simplified long short-term memory network and residual error correction. **Energy Conversion and Management**, [Reino Unido], v. 222, 21 p., out. 2020. DOI: <https://doi.org/10.1016/j.enconman.2020.113234>.

WANG, Yun *et al.* A deep asymmetric laplace neural network for deterministic and probabilistic wind power forecasting. **Renewable Energy**, [Reino Unido], v. 196, p. 497-517, ago. 2022. DOI: <https://doi.org/10.1016/j.renene.2022.07.009>.

WEN, Peng *et al.* A novel method based on lower-upper bound approximation to predict the wind energy. **Journal of Cleaner Production**, [Reino Unido], v. 259, 17 p., jun. 2020. DOI: <https://doi.org/10.1016/j.jclepro.2020.120458>.

XING, Yitian *et al.* A multi-hour ahead wind power forecasting system based on a WRF-TOPSIS-ANFIS model. **Energies**, Basileia, Suíça, v. 15, n. 15, 35 p., jul. 2022. DOI: <https://doi.org/10.3390/en15155472>.

YIN, Shi; LIU, Hui. Wind power prediction based on outlier correction, ensemble reinforcement learning, and residual correction. **Energy**, [Reino Unido], v. 250, 15 p., jul. 2022. DOI: <https://doi.org/10.1016/j.energy.2022.123857>.

ZHAO, Xuejing *et al.* Research and application based on the swarm intelligence algorithm and artificial intelligence for wind farm decision system. **Renewable Energy**, [Reino Unido], v. 134, p. 681-697, abr. 2019. DOI: <https://doi.org/10.1016/j.renene.2018.11.061>.