


UMA PEQUENA ANÁLISE DE MODELOS MATEMÁTICOS PARA PREVISÃO DE SÉRIES TEMPORAIS

Emanuel Abdalla Pinheiro



Emanuel Abdalla Pinheiro

UMA PEQUENA ANÁLISE DE MODELOS MATEMÁTICOS PARA PREVISÃO DE SÉRIES
TEMPORAIS

1ª ed.

Piracanjuba-GO
Editora Conhecimento Livre
Piracanjuba-GO

1ª ed.

Dados Internacionais de Catalogação na Publicação (CIP)

Pinheiro, Emanuel Abdalla
P626U UMA PEQUENA ANÁLISE DE MODELOS MATEMÁTICOS PARA PREVISÃO DE
SÉRIES TEMPORAIS / Emanuel Abdalla Pinheiro. – Piracanjuba-GO

Editora Conhecimento Livre, 2025

24 f.: il

DOI: 10.37423/2025.edcl1198

ISBN: 978-65-989015-0-9

Modo de acesso: World Wide Web

Incluir Bibliografia

1. previsão 2. modelagem 3. matematica 4. energia 5. eolica I. Pinheiro, Emanuel Abdalla II. Título

CDU: 310

<https://doi.org/10.37423/2025.edcl1198>

O conteúdo dos artigos e sua correção ortográfica são de responsabilidade exclusiva dos seus respectivos autores.

EDITORIA CONHECIMENTO LIVRE

Corpo Editorial

MSc Edson Ribeiro de Britto de Almeida Junior

MSc Humberto Costa

MSc Thays Merçon

MSc Adalberto Zorzo

MSc Taiane Aparecida Ribeiro Nepomoceno

PHD Willian Douglas Guilherme

MSc Andrea Carla Agnes e Silva Pinto

Dr. Walmir Fernandes Pereira

MSc Edisio Alves de Aguiar Junior

MSc Rodrigo Sanchotene Silva

MSc Adriano Pereira da Silva

MSc Frederico Celestino Barbosa

MSc Guilherme Fernando Ribeiro

MSc. Plínio Ferreira Pires

MSc Fabricio Vieira Cavalcante

PHD Marcus Fernando da Silva Praxedes

MSc Simone Buchignani Maigret

Dr. Adilson Tadeu Basquerote

Dra. Thays Zigante Furlan

MSc Camila Concato

PHD Miguel Adriano Inácio

Dra. Anelisa Mota Gregoleti

PHD Jesus Rodrigues Lemos

MSc Gabriela Cristina Borborema Bozzo

MSc Karine Moreira Gomes Sales

Dr. Saulo Cerqueira de Aguiar Soares

MSc Pedro Panhoca da Silva

MSc Helton Rangel Coutinho Junior

MSc Carlos Augusto Zilli

MSc Euvaldo de Sousa Costa Junior

Dra. Suely Lopes de Azevedo

Dr. Francisco Odecio Sales

MSc Ezequiel Martins Ferreira

MSc Eliane Avelina de Azevedo Sampaio

MSc Carlos Eduardo De Oliveira Gontijo

Dr. Rodrigo Couto Santos

Dra. Milena Gaion Malosso

PHD Marcos Pereira Dos Santos



10.37423/2025.edcl1198



Sumário

CAPÍTULO I – INTRODUÇÃO	5
CAPÍTULO II - ESTADO DA ARTE NA PREVISÃO DOS VENTOS.....	7
CAPÍTULO III - DISPONIBILIDADE DE DADOS	13
CAPÍTULO IV - HORIZONTE DE PREVISÃO.....	16
CAPÍTULO V - CONCLUSÃO.....	17
REFERÊNCIAS	18
SOBRE OS AUTOR	20

APRESENTAÇÃO

A energia eólica consolidou-se, nas últimas décadas, como uma das mais promissoras alternativas para diversificação da matriz energética mundial e, em especial, da brasileira. Sua força motriz — o vento — é abundante, limpa e renovável. Entretanto, justamente por depender de um fenômeno natural de difícil controle, a previsão da potência gerada por usinas eólicas é um dos maiores desafios enfrentados pelo setor elétrico.

Antecipar o comportamento dos ventos requer o desenvolvimento de modelos de previsão robustos, que combinem fundamentos matemáticos, estatísticos e computacionais. Nesse contexto, o estudo de ****séries temporais**** assume papel central, já que permite analisar padrões de variáveis observadas ao longo do tempo e, a partir deles, projetar cenários futuros.

O campo da previsão de séries temporais é vasto e contempla desde métodos determinísticos, baseados em equações físicas bem definidas, até métodos estocásticos, nos quais não há fórmulas explícitas que descrevam o fenômeno, mas sim a identificação de padrões históricos e sua aplicação a instantes futuros. Nessa segunda vertente, técnicas como redes neurais artificiais (RNA), algoritmos híbridos, filtros de Kalman, suavização de séries e até modelos inspirados na lógica fuzzy têm se mostrado ferramentas poderosas para a análise da velocidade do vento e a estimativa de sua variabilidade.

O presente trabalho se insere nesse cenário como uma contribuição significativa, ao explorar diferentes metodologias, comparar desempenhos e propor soluções que conciliam rigor técnico com aplicabilidade prática. Trata-se de uma leitura essencial para estudantes, pesquisadores e profissionais que desejam compreender os desafios e as possibilidades que permeiam a previsão de séries temporais aplicadas à energia eólica.

Que este livro seja não apenas uma referência acadêmica, mas também um convite à reflexão sobre a importância de integrar ciência, inovação e sustentabilidade no caminho para um futuro energético mais seguro e limpo.

CAPÍTULO I – INTRODUÇÃO

A energia eólica tem se destacado como uma das principais alternativas sustentáveis para a geração de eletricidade nas últimas décadas, especialmente no Brasil, cuja geografia favorece a exploração dos ventos. No entanto, prever com precisão a potência gerada por usinas eólicas continua sendo um desafio técnico considerável, sobretudo devido à natureza instável e difícil de controlar dos ventos. Neste cenário, o estudo de séries temporais surge como uma ferramenta essencial, permitindo analisar e modelar o comportamento do vento ao longo do tempo.

Este trabalho tem como objetivo investigar e comparar diferentes metodologias de previsão de séries temporais aplicadas à energia eólica, com foco em técnicas modernas como redes neurais artificiais, modelos híbridos, filtros de Kalman, lógica fuzzy, entre outros. A obra está dividida em três capítulos principais, organizados de forma a apresentar, primeiro, os fundamentos teóricos e metodológicos e, em seguida, aspectos práticos que impactam diretamente a qualidade das previsões.

No Capítulo II – Estado da Arte na Previsão dos Ventos, é apresentado um panorama abrangente sobre os modelos utilizados na previsão da velocidade do vento, abordando tanto métodos determinísticos quanto estocásticos. O capítulo discute o papel das séries temporais na modelagem de fenômenos naturais e explora diferentes técnicas de previsão, desde modelagens lineares, como o modelo ARMA, até abordagens não lineares e híbridas, incluindo redes neurais artificiais e algoritmos baseados em aprendizado de máquina.

O Capítulo III – Disponibilidade de Dados destaca a importância da quantidade e qualidade dos dados disponíveis para a construção de modelos de previsão eficazes. São discutidas diferentes abordagens de engenharia do conhecimento com base na presença ou ausência de teoria explícita sobre o fenômeno analisado. O capítulo também apresenta uma tabela comparativa de estudos anteriores que utilizaram modelos ARIMA e RNA, evidenciando a relação entre volume de dados e desempenho dos modelos.

O Capítulo IV – Horizonte de Previsão trata de um aspecto fundamental na análise de séries temporais: o intervalo de tempo para o qual se deseja realizar a previsão. O capítulo categoriza os horizontes em quatro grupos (muito curto, curto, médio e longo prazo), discute suas aplicações práticas no setor eólico e apresenta tabelas que ilustram como diferentes horizontes afetam a escolha e desempenho dos modelos.

Por fim, o Capítulo V - Conclusão faz uma breve síntese do trabalho apresentado, levantando os principais aspectos abordados, deixando uma reflexão do estudo apresentado.

Este trabalho destina-se a pesquisadores, estudantes e profissionais interessados em previsão de energia eólica, oferecendo uma base sólida para compreensão dos métodos disponíveis e suas respectivas aplicações, ao mesmo tempo em que propõe reflexões sobre os desafios e oportunidades da integração entre ciência, tecnologia e sustentabilidade no setor energético.

CAPÍTULO II - ESTADO DA ARTE NA PREVISÃO DOS VENTOS

Previsão é uma ferramenta vital para o planejamento no ambiente competitivo dos dias atuais, assim como a utilização de fontes alternativas para diversificação da matriz energética brasileira. A principal fonte alternativa em crescimento é a que utiliza a energia proveniente do vento. Todavia, a usina eólica é a que apresenta as maiores dificuldades de previsão de potência gerada devido às características dos ventos. Para minimizar estas dificuldades, faz-se necessário criar modelos de previsão de vento que sejam compatíveis com as necessidades do setor elétrico. Para tanto é necessário o estudo das séries temporais das velocidades dos ventos.

Uma definição concisa sobre séries temporais é dada por Morettin e Toloí (2006).

Os autores mencionam que uma série temporal é qualquer conjunto de observações ordenadas no tempo, tais como:

- (i) valores diários de temperatura de uma determinada localidade;
- (ii) índices diários de bolsas de valores;
- (iii) quantidade mensal de chuva de uma região;
- (iv) valores mensais de vendas de automóveis no país.

As séries temporais são formadas por conjuntos de observações sequenciais ordenadas em relação ao tempo, sendo possível classificá-las quanto ao seu processo gerador dos dados, como estocásticas ou determinísticas (SOARES, 2008).

As séries classificadas como determinísticas possuem seu comportamento descrito por equações conhecidas, sendo que a predição consiste na mera aplicação das equações que descrevem a série. Dentre esses modelos tem destaque os métodos físicos de previsão (SON et al. 2019) os quais preveem a energia eólica usando modelagem matemática, considerando os dados climáticos e as características ambientais: temperatura, umidade, topografia, uso da terra (SARWAT et al., 2016).

Esses métodos requerem uma grande quantidade de dados porque a construção do modelo de previsão é complicada devido à modelagem matemática de muitas variáveis e a precisão da previsão aumenta em proporção à quantidade de dados. Portanto, a estrutura matemática do modelo preditivo é muito difícil de alcançar, o processo de cálculo é complicado, e o tempo de cálculo é demorado. O método mais utilizado é a previsão numérica do tempo, PNT (CHEN et al., 2014). A PNT é adequada para previsão de longo prazo, em vez de curto e médio prazo devido à grande quantidade de cálculos

computacionais. Por outro lado, os modelos de PNT regionais disponíveis operacionalmente foram desenvolvidos tendo como principal objetivo a previsão dos fenômenos físicos em escalas maiores, como o deslocamento de massas de ar e o avanço de frentes, e possuem uma resolução espacial da ordem de 10 km, desprezando ou simplificando através de parametrizações alguns fenômenos micrometeorológicos, o que resulta em um desempenho degradado dentro da Camada Limite Atmosférica (CLA), onde estão os aerogeradores (SILVA, 2014).


Entretanto, a maioria dos problemas que envolvem séries temporais possui comportamento estocástico, e o modelo matemático que descreve o comportamento da série não existe ou não é conhecido. Como alternativa ao uso de modelos matemáticos, técnicas baseadas em reconhecimento de padrões como regressão e Redes Neurais Artificiais (RNA) podem ser utilizadas no problema de predição de valores futuros de séries temporais de comportamento estocástico. Tais técnicas fazem uso da identificação de padrões históricos recorrentes, isto é, identificação de padrões de oscilação na série temporal que aconteceram em instantes de tempo passados $t-1, t-2, \dots, t-n$ para então prever os valores nos instantes futuros $t+1, t+2, \dots, t+p$ (SOARES, 2008).

A escolha do modelo de previsão depende de três fatores:

- a) Disponibilidade de dados;
- b) Horizonte de previsão;
- c) Aplicação

A Figura 1 representa os principais modelos de previsão de series temporais estocásticas disponíveis na literatura. Nesse diagrama, há a divisão em 2 tipos de modelagens: linear e não-linear. No primeiro caso, a relação entre as variáveis observadas, velocidade do vento, e as variáveis independentes, tempo, se dá por funções lineares, equação (1). Enquanto que no segundo grupo não é possível estabelecer essa relação, equação (2).

Figura 1 – Características das séries temporais estocásticas e alguns modelos de previsão.



Fonte: Próprio autor, 2020.

A equação (1) representa uma modelagem linear do tipo ARMA (Autoregressivo com Médias Móveis) a qual será analisada na próxima seção da dissertação. Por outro lado, a equação (2) mostra um modelo bilinear o qual é derivado do modelo linear ARMA, equação (1).

$$Y_t = E_t + \sum_{i=1}^p c_i E_{t-i} + \sum_{i=1}^q a_i Y_{t-i} \quad (1)$$

$$Y_t = E_t + \sum_{i=1}^p b_i u_{t-i} + \sum_{i=1}^q a_i Y_{t-i} + \sum_{j=1}^p \sum_{i=1}^q f_{ij} Y_{t-i} u_{t-j} \quad (2)$$


Em que c_i , a_i e b_i são parâmetros lineares já os parâmetros f_{ij} são não-lineares. O elemento E_t é o ruído aleatório assumido independente e identicamente distribuído com média zero e variância constante σ^2 .

A presença da não linearidade na equação (2) está expressa no produto das duas variáveis Y_{t-i} e u_{t-j} , pois elas representam a variável de saída e a variável exógena de entrada, respectivamente, gerando um termo de segunda ordem, equivalente a um termo quadrático (SANTOS, 2007). A estrutura bilinear

pode ser classificada como um caso particular de modelagem NARIMA (Não-linear Autoregressivo Integrado com Média Móvel).

Ainda há a possibilidade de unir duas ou mais metodologias gerando uma nova modelagem designada de híbrida ou mista, Figura 2. O foco destes sistemas está em obter um sistema mais poderoso e com menos deficiências. Dependendo da forma básica de construção, uma técnica pode ser aplicada para melhorar as deficiências do outro, em maior ou menor grau (SANCHEZ, 2009).

Figura 2 – Diagrama de blocos entrada/ saída para metodologia híbrida.



Fonte: Próprio autor, 2020.

Em relação as modelagens lineares, o filtro de Kalman (KALMAN, 1960) é um filtro linear ótimo, que modela processos estocásticos baseando-se na transição de estados e executando previsões em dados ruidosos. É muito empregada em modelagens híbridas na previsão de séries temporais, como em Liu, Tian e Li (2012) propuseram uma comparação entre o modelo híbrido modelos ARIMA e RNA e um outro que leva em consideração a combinação entre filtro de Kalman com RNA para previsão de velocidade do vento em fazendas eólicas de regiões da China. No modelo híbrido ARIMA-RNA, o modelo ARIMA é usado para decidir a estrutura de um modelo RNA; e no modelo ARIMA-Kalman, o modelo ARIMA é empregado para inicializar as equações de medição Kalman. Ambos os casos retratam bons desempenhos (por exemplo, com medida estatística de erro médio percentual de aproximadamente 3,45%) que podem, portanto, ser aplicados à previsão não estacionária da velocidade do vento em sistemas de energia eólica.

Modelos de suavização são uma grande classe de métodos de previsão que se baseiam na ideia de que observações passadas contêm informações sobre o padrão da série temporal. O propósito dos métodos é distinguir um padrão de comportamento de qualquer outro ruído que possa estar contido

nas observações da série e então usar esse padrão para prever valores futuros da série. No caso de séries que apresentam um comportamento um pouco mais complexo, como sazonalidade, utilizamos outras formas de suavização como o método de Holt-Winters. Leal Junior et al. (2018) propuseram metodologia híbrida RNA e Holt-Winters com excelentes resultados com erro percentual de aproximadamente 5,0%, e também com o valor do coeficiente de eficiência de Nash-Sutcliffe (NSE), que é análogo ao coeficiente de determinação (R^2), no valor de aproximadamente de 0,96, nas cidades de Fortaleza, São Luís e Natal.

Em trabalhos anteriores, Catalão et al. (2011) propôs uma abordagem das redes neurais artificiais para previsão de energia eólica a curto prazo, em Portugal. O algoritmo de aprendizagem utilizado foi o de retropropagação possuindo uma estrutura de três camadas. O MAPE obtido foi de 7,26 %, enquanto o tempo médio computacional foi de menos de 5 segundos. A proposta abordada apresentou um bom desempenho, segundo os autores.

Silva (2014) obteve bons resultados aplicando RNA com arquitetura feedforward do tipo Perceptron de multicamada (PMC) na previsão de velocidades dos ventos de localidades de Paracuru e Camocim, durante período de 630 dias, modificando as funções de ativação das camadas ocultas e obtendo valores de coeficientes de correlação da ordem de 0,95 e valores de coeficiente de determinação de 91% da variabilidade dos dados observados e valores de erros relativos na ordem de 0,07% para localidade de Paracuru. No mesmo caminho, Camelo (2017) utiliza modelagem híbrida RNA e ARIMA, conseguindo reduções significativas nas taxas de erros na previsão mensal dos ventos nas cidades de Fortaleza, São Luís e Natal.

Ao passo que Sampaio (2020) utiliza uma modelagem híbrida Auto-Regressiva Integrada de Médias Móveis (ARIMA) e Redes Neurais Artificiais (RNA), para realizar previsão de velocidade do vento de curto prazo (Mensal e Horário), visando aplicar ao estudo do potencial eólico na região metropolitana de Fortaleza, Aeroporto Internacional Pinto Martins. Os dados de velocidade do vento foram oriundos de uma estação meteorológica localizada no Aeroporto Internacional Pinto Martins com anemômetro com altura a 10 m em relação ao solo. A eficiência do modelo híbrido apresentou um percentual de 82% para a série temporal horária e um percentual de 84% para a série temporal mensal, sendo uma eficiência maior em relação ao modelo ARIMA.

No que concerne a outros métodos citados na Figura 1, Grus (2016) comenta o SVM (Máquinas de vetores de suporte) é um modelo de caráter classificatório em que é realizado o treinamento de dados a partir da separação dos mesmos por um hiperplano, que irá maximizar a distância para o ponto mais

perto em cada classe. Andrade (2011) emprega redes neurais recorrentes de ELMAN¹, que são sistemas dinâmicos com propriedades sensitivas a sequências temporais, na previsão de series temporais de demanda de energia elétrica no curtíssimo prazo, obtendo reduções em índices MAPE de 0,11% em relação a redes PMC de modelos ARIMA+RNA nas regiões de Cordeirópolis e Mogi-Guaçu, cidades localizadas no estado em São Paulo.


CAPÍTULO III - DISPONIBILIDADE DE DADOS

Um dos maiores desafios do mundo de hoje é satisfazer a crescente demanda de energia, priorizando as fontes energéticas renováveis e, ao mesmo tempo, combatendo urgentemente os problemas ligados às mudanças climáticas.

De acordo com a disponibilidade de dados e/ou teoria de análise do fenômeno, diferentes métodos de engenharia do conhecimento são indicados para modelagem do processo envolvido que, nesse caso, trata-se de uma série temporal curta de velocidade dos ventos. A Figura 3 apresenta os principais métodos que envolvem engenharia do conhecimento de dados.

Quando existem apenas exemplos (amostras representativas) de um dado processo, sem regras que expliquem a sua geração, então os métodos estatísticos permitem obter os melhores resultados. No extremo oposto do gráfico estão os métodos de Inteligência Artificial Simbólicos, como por exemplo os sistemas especialistas. Neste caso, o importante são as regras e o processo de inferência que permite resolver um certo problema. A teoria - lógica clássica baseada em axiomas - é muito bem estabelecida e prescinde de exemplos para a implementação do sistema especialista (BAUCHSPIESS, 2008).

Figura 3 – Métodos de engenharia do conhecimento.



Fonte: BAUCHSPIESS, 2008.

Os algoritmos genéticos, uma das vertentes da computação evolucionária, por ser justificada exclusivamente pela heurística, está no canto inferior esquerdo do gráfico. Não existe muita base

teórica para a sua utilização e tampouco têm-se garantias de que um conjunto de amostras rico em informações sobre o processo, leve à solução do problema. Estes métodos tiveram origem na esperança de que os processos de transmissão de material genético entre gerações de populações, levando eventualmente a indivíduos mais aptos, pudesse ser mimetizado em um programa de computador. Dado um conjunto inicial de possíveis soluções sub-ótimas estas podem ser combinadas (“cruzamento de material genético”) sucessivamente (“gerações”) até obter-se a solução ótima do problema (BAUCHSPIESS, 2008).

Os sistemas difusos, fundamentados pela lógica fuzzy, têm uma boa base teórica. Podem ser construídos a partir de regras formuladas por especialistas da aplicação em particular (SILVA, 2014). Amostras do processo não são necessárias. Estes sistemas utilizam uma lógica multivalorada que permite “graus de pertinência” e não verdades ou falsidades absolutas. A dificuldade de sua aplicação está muitas vezes justamente na escolha dos novos graus de liberdade obtidos.

Os sistemas baseados em Redes Neurais Artificiais (RNA) ocupam uma região intermediária em relação ao gráfico Teoria x Dados. Estes sistemas exploram razoavelmente bem as amostras do processo. De fato, uma das grandes vantagens desta abordagem é a possibilidade de treinamento da RNA a partir dos dados. Não são necessárias regras ou uma teoria que descreva o processo, a RNA simplesmente “aprende” com os exemplos (PINHEIRO et al. 2020). Estes exemplos são apresentados sucessivamente à RNA, que se adapta um pouco a cada exemplo. O comportamento desejado é reforçado e o comportamento indesejado é reprimido até que o sistema realize a tarefa almejada. Tarefas típicas para RNA são a classificação de padrões e a aproximação de funções não lineares.

Tabela 1 – Listagem dos trabalhos com metodologia ARIMA e RNA com relação a quantidade de dados processados.

PESQUISA (ANO)	DADOS TOTAIS	FASE DE TREINAMENTO (%)
PINHEIRO (2020)	226 dias	100 dias (44,2%)
SAMPAIO (2020)	365 dias	364 dias (99,7%)
NOMAN (2020)	730 dias	365 dias (50%)
CAMELO (2017)	24 meses	17meses (70%)
LEAL JUNIOR (2017)	366 dias	365 dias (99,7%)
AHMED (2017)	365 dias	292 dias (80%)
SILVA (2014)	560 dias	360 dias (64%)
JARDIM (2014)	365 dias	255 dias (70%)
LIU (2012)	500 horas	300 horas (60%)
GOUVEIA (2011)	8784 dias	5270 dias (60%)
OLIVEIRA (2008)	609 dias	365 dias (60%)

Fonte: Próprio autor, 2020.

A Tabela 1 lista alguns trabalhos dos últimos anos com metodologia ARIMA e RNA em relação a quantidade de dados totais e na fase de treinamento.

CAPÍTULO IV - HORIZONTE DE PREVISÃO

Um conceito importantíssimo no estudo de séries temporais é o de horizonte de previsão. Ele representa o número de instantes à frente para o qual é feita a previsão. Se é conhecido o valor da série até o instante de tempo t , e se deseje conhecer a estimativa da série no instante $t + k$, então k é o horizonte de previsão (AHMED et al., 2017). Portanto, a série prevista está k passos à frente do instante atual observado.

Os horizontes de previsão são diferentes para cada tipo de série temporal. No caso das séries de velocidades dos ventos, o sistema de previsão é dividido em 4 categorias de acordo com os horizontes de tempo - muito curto prazo, curto prazo, médio prazo ou longo prazo. O intervalo de tempo é diferente em várias descrições da literatura. (SOMAN et al. 2010) e (ZHAO, WANG e LI, 2011). Vários horizontes de tempo têm alcance e finalidade de aplicação diferentes. A Tabela 2 apresenta um resumo dos horizontes de previsão para aplicação no setor eólico.

Tabela 2 - Características do horizonte de previsão da velocidade do vento e suas possíveis aplicações no setor eólico.

Escala de tempo	Intervalo	Aplicações no setor eólico
Curtíssimo prazo	Poucos minutos a 1 hora à frente	Ações de regulação; Compensação do mercado de eletricidade; Operações de rede em tempo real.
Curto prazo	1 hora a várias horas à frente	Planejamento econômico de despacho de carga; Decisões razoáveis de carga (incremento/distribuição); Segurança operacional no mercado de eletricidade.
Médio prazo	Várias horas a 1 semana à frente	Geração de decisões on-line/off-line; Decisões de unidade de reserva.
Longo prazo	1 semana a 1 ano ou mais à frente	Programação de manutenção para obter o custo operacional ideal; Estudo de Viabilidade para Projeto do Parque Eólico.

Fonte: ZHAO adaptado, 2011.

CAPÍTULO V - CONCLUSÃO

A previsão de energia eólica é um campo complexo e estratégico para o setor energético, especialmente em países como o Brasil, onde o potencial eólico é elevado. A utilização de séries temporais mostra-se essencial para lidar com a variabilidade dos ventos, sendo aplicada em diferentes modelos, desde lineares e determinísticos até técnicas modernas não lineares, híbridas e de inteligência artificial. Além disso, fatores como a disponibilidade e a qualidade dos dados, assim como a definição do horizonte de previsão, desempenham papel decisivo no desempenho dos modelos. Dessa forma, o trabalho oferece uma base sólida de conhecimento, apresentando avanços, desafios e oportunidades para tornar as previsões mais precisas e, conseqüentemente, contribuir para a eficiência e sustentabilidade da matriz energética.

Nesse contexto, observa-se que os métodos híbridos e baseados em aprendizado de máquina vêm ganhando destaque por sua capacidade de capturar padrões complexos e lidar com a natureza estocástica dos ventos. O cruzamento entre abordagens matemáticas tradicionais e técnicas modernas possibilita uma maior robustez nos modelos de previsão, ampliando sua aplicabilidade em diferentes horizontes de tempo e cenários de disponibilidade de dados. Assim, a integração entre ciência de dados, inteligência artificial e engenharia energética constitui um caminho promissor para a consolidação da energia eólica como uma alternativa cada vez mais confiável e competitiva.

Por fim, fica evidente que a previsão de séries temporais aplicada à energia eólica não é apenas um desafio técnico, mas também uma oportunidade estratégica para fortalecer a matriz energética renovável e reduzir a dependência de fontes poluentes. Ao investir em metodologias mais precisas, o setor não apenas otimiza a gestão e operação das usinas, como também contribui diretamente para os objetivos globais de sustentabilidade e mitigação das mudanças climáticas. Portanto, o avanço contínuo nessa área representa um passo fundamental para a construção de um futuro energético mais limpo, seguro e eficiente.

REFERÊNCIAS

- AHMED, A.; KHALID, M. Multi-step ahead wind forecasting using nonlinear autoregressive neural networks. *Energy Procedia*, v. 134, p. 192-204, 2017.
- ANDRADE, L. C. M. de; SILVA, I. N. da. Redes neurais recorrentes de Elman para previsão de demanda de energia elétrica no curtíssimo prazo. In: *Anais do X Simpósio Brasileiro de Automação Inteligente*, São João del-Rei, MG, Brasil, set. 2011. p. 375-380. Disponível em: https://fei.edu.br/sbai/SBAI2011/anais_busca.html. Acesso em: 22 dez. 2020.
- BAUCHSPIESS, A. Introdução aos sistemas inteligentes. Curso de Engenharia Elétrica da Universidade de Brasília, Brasília, 2008. Disponível em: <http://www.ene.unb.br/adolfo/Lectures/ICIN/isi.pdf>. Acesso em: 12 nov. 2020.
- CAMELO, H. N.; CARVALHO, P. C. M.; LEAL JUNIOR, J. B. V. Métodos de previsão de séries temporais e modelagem híbrida aplicados em médias mensais de velocidade do vento para regiões do Nordeste do Brasil. *Revista Brasileira de Meteorologia*, v. 32, n. 4, p. 565-574, 2017.
- CATALÃO, J. P. S.; POUSINHO, H. M. I.; MENDES, V. M. F. Short-term wind power forecasting in Portugal by neural networks and wavelet transform. *Renewable Energy*, v. 36, n. 4, p. 1245-1251, abr. 2011.
- CHEN, N.; QIAN, Z.; NABNEY, I. T.; MENG, X. Wind power forecasts using Gaussian processes and numerical weather prediction. *IEEE Transactions on Power Systems*, v. 29, p. 656-665, 2014.
- GRUS, J. *Data Science do Zero: primeiras regras com o Python*. 215 p. Rio de Janeiro: Alta Books, 2016.
- KALMAN, R. E. A new approach to linear filtering and prediction problems. *Transactions of the Journal of Basic Engineering, ASME, [s.l.]*, v. 82, série D, p. 35-44, 1960.
- LEAL JUNIOR, J. B. V.; CAMELO, H. N.; CARVALHO, P. C. M. Modelo híbrido de previsão de séries temporais para possíveis aplicações no setor de geração eólica. *Revista do Centro de Ciências Natureza e Exatas*, v. 40, p. 1-6, 2018.
- LIU, H.; TIAN, H. Q.; LI, Y. F. Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. *Applied Energy*, v. 98, p. 415-424, 2012. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261912002875>. Acesso em: 01 dez. 2020.
- PINHEIRO, E. A.; LEAL JUNIOR, J. B. V.; DE LIMA, L. C.; PINHEIRO, F. G. de M. Nonlinear autoregressive neural networks for forecasting wind speed time series. *International Journal of Development Research*, v. 10, n. 9, p. 40336-40343, 2020. Disponível em: <http://www.journalijdr.com/sites/default/files/issue-pdf/19845.pdf>. Acesso em: 09 nov. 2020.
- SAMPAIO, A. F. Modelo híbrido com ARIMA e RNA aplicado para a previsão de curto prazo de velocidade do vento direcionado ao estudo de potencial eólico em região do estado do Ceará. 57 f. Dissertação (Mestrado em Ciências Físicas Aplicadas) — Centro de Ciência e Tecnologia, Universidade Estadual do Ceará, Fortaleza, 2020.
- SANCHEZ, E. C. M. Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência. Dissertação (Mestrado em Engenharia Mecânica). Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.

SANTOS, J. E. S. dos. Controle preditivo não-linear para sistemas de Hammerstein. Tese (Doutorado em Engenharia Elétrica). 139 f. Universidade Federal de Santa Catarina, Florianópolis, 2007.

SARWAT, A.; AMINI, M.; DOMIJAN, A.; DAMNJANOVIC, A.; KALEEM, F. Weather-based interruption prediction in the smart grid utilizing chronological data. *Journal of Modern Power Systems and Clean Energy*, v. 4, p. 308–315, 2016.

SILVA, S. C. da. Utilização de redes neurais na previsão de vento do litoral do Ceará. 105 f. Dissertação (Mestrado em Ciências Físicas Aplicadas) — Centro de Ciência e Tecnologia, Universidade Estadual do Ceará, Fortaleza, 2014.

SOARES, A. da S. Predição de séries temporais econômicas por meio de redes neurais artificiais e transformada wavelet: combinando modelo técnico e fundamentalista. 92 f. Dissertação (Mestrado em Engenharia Elétrica) — Escola de Engenharia da Universidade de São Paulo, São Carlos, 2008.

SOMAN, S. S.; ZAREIPOUR, H.; ALIK, O.; MANDAL, P. A review of wind power and wind speed forecasting methods with different time horizons. In: *North American Power Symposium (NAPS)*, 2010. p. 1-8, set. 2010.

SON, N.; YANG, S.; NA, J. Hybrid forecasting model for short-term wind power prediction using modified long short-term memory. *Energies*, v. 12, n. 20, out. 2019. Disponível em: <https://www.mdpi.com/1996-1073/12/20/3901/pdf>. Acesso em: 12 ago. 2020.

ZHAO, X.; WANG, S.; LI, T. Review of evaluation criteria and main methods of wind power forecasting. *Energy Procedia*, n. 12, p. 761-769, 2011.

SOBRE OS AUTORES

O presente autor é graduado no curso de Bacharelado em Engenharia Elétrica pela Universidade Federal do Ceará, mestre em Ciências Físicas Aplicadas ao Desenvolvimento do Semiárido pela Universidade Estadual do Ceará. É professor de graduação e pós-graduação de cursos de engenharia e matemática.

UMA PEQUENA ANÁLISE DE MODELOS MATEMÁTICOS PARA PREVISÃO DE SÉRIES TEMPORAIS

Emanuel Abdalla Pinheiro



conhecimentolivre.org/home



contato@conhecimentolivre.org



[editoraconhecimentolivre](https://www.instagram.com/editoraconhecimentolivre)

