



Universidade Federal de Pernambuco

Centro Acadêmico do Agreste - CAA

Programa de Pós-graduação em Engenharia de Produção - PPGE

**ESTUDOS SOBRE INTELIGÊNCIA ARTIFICIAL NA
PREVISÃO DE ENERGIA EÓLICA: Aplicação Prática de
Redes Neurais MLP em Pernambuco**

Maria Luiza Xavier de Holanda Cavalcanti

Orientador: Lúcio Camara e Silva

Caruaru

2026

Maria Luiza Xavier de Holanda Cavalcanti

**ESTUDOS SOBRE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE
ENERGIA EÓLICA: Aplicação Prática de Redes Neurais MLP em
Pernambuco**

Dissertação apresentada no Mestrado em Engenharia de Produção, como um requisito parcial para obter o Título de Mestre em Engenharia de Produção, no Centro Acadêmico do Agreste - CAA da Universidade Federal de Pernambuco.

Orientador: Lúcio Camara e Silva

Caruaru

2026

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Cavalcanti, Maria Luiza Xavier de Holanda.

Estudos sobre Inteligência Artificial na previsão de Energia Eólica: aplicação prática de Redes Neurais MLP em Pernambuco / Maria Luiza Xavier de Holanda Cavalcanti. - Caruaru, 2026. 131f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro Acadêmico do Agreste, Programa de Pós-Graduação em Engenharia de Produção, 2026.

Orientação: Lúcio Câmara e Silva.

Inclui Referências e Apêndices.

1. Energia Eólica; 2. Inteligência Artificial; 3. Revisão Sistemática; 4. Multilayer Perceptron (MLP); 5. Pernambuco. I. Silva, Lúcio Câmara e. II. Título.

UFPE-Biblioteca Central

MARIA LUIZA XAVIER DE HOLANDA CAVALCANTI

**ESTUDOS SOBRE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE
ENERGIA EÓLICA: Aplicação Prática de Redes Neurais MLP em
Pernambuco**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção. Área de concentração: Otimização e Gestão da Produção.

Aprovada em: 12 de fevereiro de 2026.

BANCA EXAMINADORA

Prof. Dr. Lúcio Câmara e Silva (Orientador)

Universidade Federal de Pernambuco – UFPE

Prof. Dr. Flavio Trojan (Examinador)

Universidade Tecnológica Federal do Paraná – UTFPR

Prof. Dr. Luciano Carlos Azevedo da Costa (Examinador)

Universidade Federal da Paraíba – UFPB

Caruaru

2026

AGRADECIMENTOS

A conclusão desta etapa não é um mérito individual, mas o resultado do apoio, carinho e ensinamentos de pessoas que caminharam ao meu lado.

A Deus, fonte de toda sabedoria e sustento da minha vida. Agradeço por ser o meu alicerce inabalável quando as forças pareciam findar e pela luz divina que dissipou as incertezas do caminho. Sua graça me permitiu transformar o cansaço em perseverança e os desafios em degraus de fé, conduzindo-me com amor e resiliência até a concretização de mais um sonho. A Ele toda honra e gratidão, hoje e sempre.

Aos meus pais, Charles e Silveklia Cavalcanti, meus primeiros mestres. Obrigada pelo amor incondicional, pelo sacrifício e por acreditarem nos meus sonhos, muitas vezes mais do que eu mesma. Tudo o que sou devo ao exemplo e aos valores que recebi de vocês.

Ao meu noivo e futuro esposo, Victor Porto, meu porto seguro. Obrigada por estar ao meu lado diariamente desde o início da graduação e ser o meu alicerce em cada etapa. Todo seu apoio, compreensão, conselhos e companheirismo foram fundamentais para que eu nunca pensasse em desistir nas horas difíceis e para que as dificuldades fossem lidadas da melhor forma. Obrigada por embarcar comigo em todos os desafios, tornando a jornada mais leve, e por ser meu maior incentivador. Sou eternamente grata por sempre acreditar em mim, meu grande amor.

Aos meus irmãos, Gabriel, Maria Clara e Maria Gabriela, por tornarem meus dias mais felizes. Obrigada pelo companheirismo silencioso, pelas risadas que curam qualquer cansaço e por tornarem minha caminhada muito mais leve e feliz. Ter vocês ao meu lado é o presente mais precioso que a vida me deu, e sigo com o coração transbordando gratidão por dividirmos essa história.

Ao meu orientador, Lúcio Camara, por me guiar neste processo com sabedoria e por acreditar no meu potencial em cada desafio deste estudo. Minha gratidão pelas oportunidades concedidas e por seu exemplo inspirador de profissionalismo, que foi a bússola essencial para o pleno amadurecimento deste trabalho.

Ao Professor Leão, que me acompanha desde os meus primeiros passos na vida acadêmica. Minha eterna gratidão por ter sido quem abriu as portas do mundo acadêmico para mim quando tudo ainda era novo e acreditou no meu potencial, fazendo-me amadurecer como profissional. Obrigada por ser essa referência de mestre que transborda

generosidade. O senhor é uma inspiração que faço questão de levar comigo em toda minha trajetória.

Aos professores Fábio Santos e Luciano Costa, por compartilharem seus vastos conhecimentos e pela dedicação ao ensino que tanto enriqueceu minha formação e este trabalho. Meu agradecimento se estende a todos os membros que participaram do desenvolvimento deste trabalho, onde a contribuição e o suporte de cada um de vocês foram fundamentais para o amadurecimento das ideias aqui apresentadas.

À minha família, tias, tios, primos e primas, e, aos meus sogros, Sandro e Andrea Porto: meu sincero agradecimento por cada palavra de incentivo e por toda a torcida silenciosa ao longo deste percurso. Sou profundamente grata pelo carinho e por saber que nunca estive sozinha nessa caminhada; a presença e o apoio de vocês foram fundamentais para que eu chegasse até aqui.

Ao meu filhinho de quatro patas, Zack (*in memoriam*). Obrigada por ter sido minha companhia diária e por trazer leveza aos meus dias de estudo. Mesmo não estando mais aqui, sinto que sua alegria me ajudou a concluir esta jornada. Você faz muita falta, meu pequeno, obrigada por tudo.

RESUMO

Este trabalho distingue-se pela integração entre o rigor metodológico de uma revisão sistemática da literatura e a validação experimental em uma fronteira estratégica para a matriz energética brasileira. Inicialmente, conduziu-se um mapeamento do estado da arte no período de 2014 a 2024, estruturado pelos protocolos PRISMA e *Methodi Ordinatio*. Diferentemente de revisões narrativas convencionais, essa abordagem permitiu filtrar o vasto volume de publicações globais para identificar as arquiteturas de Inteligência Artificial predominantes e as lacunas na modelagem eólica em regiões semiáridas.

Fundamentado nesta análise, o estudo aplicou uma rede neural *Multilayer Perceptron* (MLP) na região de Petrolina-PE, um polo vital para a geração no Nordeste. O diferencial técnico da proposta reside na utilização de um vetor de entrada expandido com 15 variáveis meteorológicas — cuja relevância foi validada estatisticamente por análise de correlação — superando abordagens tradicionais limitadas a poucos parâmetros. Os resultados experimentais destacaram a superioridade da função de ativação ELU, obtendo um Erro Percentual Absoluto Médio Simétrico (SMAPE) de 16,99% e um Coeficiente de Determinação (R^2) de 0,80. Tais indicadores corroboram a eficácia do modelo como uma solução robusta para previsões de curto prazo, capaz de explicar a maior parte da variabilidade dos ventos locais com baixo custo computacional. Conclui-se que, embora o MLP apresente desempenho satisfatório para a operação diária, a contínua evolução da fronteira do conhecimento aponta para a hibridização de modelos como o próximo passo para superar os limites da estocasticidade atmosférica.

Palavras-chave: Energia Eólica; Inteligência Artificial; Revisão Sistemática; *Multilayer Perceptron* (MLP); Pernambuco.

ABSTRACT

This work distinguishes itself by the integration between the methodological rigor of a systematic literature review and experimental validation at a strategic frontier for the Brazilian energy matrix. Initially, a mapping of the state-of-the-art was conducted for the period from 2014 to 2024, structured by the PRISMA and *Methodi Ordinatio* protocols. Unlike conventional narrative reviews, this approach allowed filtering the vast volume of global publications to identify the predominant Artificial Intelligence architectures and the gaps in wind modeling in semi-arid regions.

Grounded in this analysis, the study applied a *Multilayer Perceptron* (MLP) neural network in the region of Petrolina-PE, a vital hub for generation in the Northeast. The technical differentiator of the proposal lies in the use of an expanded input vector with 15 meteorological variables — whose relevance was statistically validated by correlation analysis — surpassing traditional approaches limited to a few parameters. The experimental results highlighted the superiority of the ELU activation function, achieving a Symmetric Mean Absolute Percentage Error (SMAPE) of 16.99 percent and a Coefficient of Determination (R^2) of 0.80. These indicators corroborate the effectiveness of the model as a robust solution for short-term forecasting, capable of explaining the majority of local wind variability with low computational cost. It is concluded that, although the MLP presents satisfactory performance for daily operation, the continuous evolution of the knowledge frontier points to the hybridization of models as the next step to overcome the limits of atmospheric stochasticity.

Keywords: Wind Energy; Artificial Intelligence; Literature Review; Multilayer Perceptron (MLP); Pernambuco.

LISTA DE FIGURAS

Figura 1 – Fluxograma do processo de seleção PRISMA adaptado com <i>Methodi Ordinatio</i>	35
Figura 2 – Fluxo das nove etapas do <i>Methodi Ordinatio</i>	36
Figura 3 – Evolução da produção científica anual no portfólio selecionado.	45
Figura 4 – Distribuição dos periódicos segundo a Lei de Bradford (Core Sources).	46
Figura 5 – Ranking dos periódicos mais relevantes por número de publicações.	48
Figura 6 – Classificação das 10 principais fontes baseada no Índice H.	49
Figura 7 – Dinâmica de crescimento da produção científica por periódico (2014–2024).	50
Figura 8 – Crescimento acumulado da produção por periódico (2014–2024).	51
Figura 9 – Distribuição de frequência de autores (Lei de Lotka).	53
Figura 10 – Evolução da produtividade e impacto dos autores (2015–2024).	54
Figura 11 – Instituições mais relevantes por número de artigos publicados.	56
Figura 12 – Países mais citados (Total de Citações Acumuladas).	57
Figura 13 – Distribuição geográfica da produção científica global.	59
Figura 14 – Proporção de publicações domésticas (SCP) e internacionais (MCP).	60
Figura 15 – Rede global de colaboração científica.	61
Figura 16 – Nuvem de palavras-chave mais frequentes no portfólio.	62
Figura 17 – Rede de acoplamento bibliográfico dividida em <i>clusters</i> temáticos.	64
Figura 18 – Topologia clássica de um Perceptron Multicamadas.	82
Figura 19 – Geografia Pernambucana	86
Figura 20 – Matriz de Correlação de Pearson entre as variáveis meteorológicas e a velocidade do vento em Petrolina.	91
Figura 21 – Curva de Potência característica utilizada para a conversão.	104
Figura 22 – Perfil de Geração de Potência Estimada para 24h (Modelo ELU).	104
Figura 23 – Painel de diagnóstico para a Função de Ativação ReLU . (a) Histograma de frequência dos erros; (b) Sobreposição das curvas de vento real (azul) e previsto (laranja); (c) Projeção de decaimento do vento para o dia seguinte.	106

Figura 24 – Painel de diagnóstico para a Função de Ativação Sigmoide	107
Figura 25 – Painel de diagnóstico para a Função de Ativação Tanh	108
Figura 26 – Painel de diagnóstico para a Função de Ativação ELU . Note a simetria acentuada no histograma (a) e a precisão no acompanhamento dos picos na série temporal (b).	109

LISTA DE TABELAS

Tabela 1 – Questões de pesquisa norteadoras da revisão sistemática.	31
Tabela 2 – Protocolo de busca e filtros aplicados nas bases de dados.	33
Tabela 3 – Descrição das variáveis da equação InOrdinatio.	37
Tabela 4 – Critérios e parâmetros aplicados no estudo.	38
Tabela 5 – Distorção Temporal: O "Gap"entre Consolidação e Inovação.	39
Tabela 6 – Resumo estatístico do portfólio bibliográfico selecionado.	44
Tabela 7 – Caracterização dos periódicos por zona de Bradford, acesso e escopo.	46
Tabela 8 – Autores mais relevantes por número de publicações no portfólio.	52
Tabela 9 – Ranking de produtividade científica (Frequência de Artigos).	58
Tabela 10 – Análise dos <i>Clusters</i> de Pesquisa sobre Previsão de Energia Eólica com IA	65
Tabela 11 – Documentos dos <i>Clusters</i>	67
Tabela 12 – Categorização das variáveis de entrada e justificativa física para mode- lagem.	73
Tabela 13 – Classificação dos horizontes de previsão e suas implicações operacionais.	74
Tabela 14 – Correlação entre horizonte temporal, acurácia e aplicação estratégica.	76
Tabela 15 – Estatísticas de Aplicabilidade: Relação entre Arquitetura, Cenário e Performance.	79
Tabela 16 – Definição das variáveis de entrada e justificativa física para a modelagem.	90
Tabela 17 – Métricas estatísticas adotadas para avaliação do modelo.	95
Tabela 18 – Desempenho comparativo das funções de ativação na previsão de vento (Petrolina).	99
Tabela 19 – Comparativo de Desempenho (Função ELU): 15 Variáveis vs. Top 5 Variáveis.	100
Tabela 20 – Performance quantitativa do Melhor Modelo (ELU) em Petrolina.	101
Tabela 21 – Estimativa de Geração Energética para Horizonte de 24h (Modelo ELU).	104
Tabela A1 – Artigos sobre Previsão de Energia Eólica	122
Tabela A2 – Extração de Dados da RSL: Parâmetros Técnicos e Operacionais por Artigo.	127

Tabela B1 – Matriz de Decisão Metodológica para Previsão de Geração Eólica. . . . 132

LISTA DE SIGLAS

ABEÉOLICA	Associação Brasileira de Energia Eólica
AdaGrad	Adaptive Gradient Algorithm
Adam	Adaptive Moment Estimation
ANEEL	Agência Nacional de Energia Elétrica
ANN	Artificial Neural Network
APC	Article Processing Charge
ARIMA	Autoregressive Integrated Moving Average
CNN	Convolutional Neural Network
COP	Conferência das Partes
CMO	Custo Marginal de Operação
ELM	Extreme Learning Machine
EUA	Estados Unidos da América
EEMD	Ensemble Empirical Mode Decomposition
GA	Genetic Algorithms
GMM	Gaussian Mixture Models
GRU	Gated Recurrent Unit
GW	Gigawatt
HPC	High-Performance Computing
IA	Inteligência Artificial
ID	Identificador
IEEE	Institute of Electrical and Electronics Engineers
IF	Impact Factor
INMET	Instituto Nacional de Meteorologia
JCR	Journal Citation Reports
LSSVM	Least Squares SVM
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error

MAD	Mean Absolute Deviation
MAPE	Mean Absolute Percentage Error
MCP	Multiple Country Publication
MLP	Multilayer Perceptron
MSE	Mean Squared Error
MW	Megawatt
NDC	Contribuições Nacionalmente Determinadas
NWP	Numerical Weather Prediction
ONS	Operador Nacional do Sistema Elétrico
PIEAS	Pakistan Institute of Engineering and Applied Sciences
PRISMA	Preferred Reporting Items for Systematic Reviews and Meta-Analyses
PSO	Particle Swarm Optimization
Q	Questão
QP	Questões de Pesquisa
R	Linguagem de Programação R
ReLU	Rectified Linear Unit
RMSE	Root-mean-square deviation
RMSprop	Root-Mean-Square Propagation
RNN	Recurrent Neural Network
RVM	Relevance Vector Machine
RSL	Revisão Sistemática da Literatura
SCP	Single Country Publication
SGD	Stochastic Gradient Descent
SIN	Sistema Interligado Nacional
SMAPE	Symmetric Mean Absolute Percentage Error
SVM	Support Vector Machines
SVR	Support Vector Regression
TW	Terawatt
WoS	Web of Science
XGBoost	Extreme Gradient Boosting
ZCIT	Zona de Convergência Intertropical

LISTA DE SÍMBOLOS

A	Área varrida pelas pás da turbina
Ano_{pesq}	Ano em que a pesquisa foi desenvolvida
Ano_{pub}	Ano em que o artigo foi publicado
$a_j^{(l)}$	Saída do j -ésimo neurônio na camada l
$b_j^{(l)}$	Termo de viés do j -ésimo neurônio na camada l
C_i	i -ésimo artigo da amostra
C_p	Coefficiente de potência
e	Constante de Euler
$f(\cdot)$	Função de ativação não linear
$f(x)_{ELU}$	Função de ativação ELU
$f(x)_{ReLU}$	Função de ativação ReLU
$f(x)_{sig}$	Função de ativação sigmoide
$f(x)_{tanh}$	Função de ativação Tangente Hiperbólica
h	Horas
IF	Fator de Impacto
m/s	Metros por segundo
$max(x)$	Valor máximo de x
$min(x)$	Valor mínimo de x
n	Número total de amostras
$n_{(l-1)}$	Número de neurônios na camada anterior ($l - 1$)
P	Potência eólica disponível
r	Correlação de Pearson
R^2	Coefficiente de Determinação
t	Instante de tempo
v	Velocidade do vento
v^3	Velocidade ao cubo
w	Pesos
$w_{ij}^{(l)}$	Peso sináptico que conecta o neurônio i da camada ($l - 1$) ao neurônio j da camada l

x	Valor original de entrada
x'	Valor normalizado
y	Valor real
\hat{y}	Previsão da rede
$z_j^{(l)}$	Entrada líquida do j -ésimo neurônio na camada l
α	Fator de ponderação
ρ	Densidade do ar
Σ	Somatório
\approx	Aproximadamente
$\{\}$	Representação de conjuntos de elementos
\square	Delimitadores de matrizes ou intervalos fechados
$()$	Delimitadores de precedência matemática ou argumentos de função
$=$	Igualdade
$>$	Maior que
$<$	Menor que
\leq	Menor ou igual
\in	Indica que um elemento pertence a um conjunto
$\%$	Percentual
$P \times V$	Produto Cartesiano entre os conjuntos P e V
\propto	Proporcionalidade
$\sqrt{\quad}$	Raiz quadrada
$^{\circ}C$	Graus Celsius
$ \cdot $	Valor absoluto
\sim	Operador de distribuição

SUMÁRIO

1	INTRODUÇÃO	20
1.1	Objetivos	25
1.1.1	Objetivo Geral	25
1.1.2	Objetivos Específicos	25
1.2	Justificativa e Relevância	26
1.3	Organização do Trabalho	28
2	REVISÃO SISTEMÁTICA DA LITERATURA	30
2.1	Perguntas de Pesquisa	31
2.2	Estratégia de Busca Booleana	32
2.3	Método PRISMA	33
2.4	<i>Methodi Ordinatio</i>	36
2.4.1	Limitações do Método e a Penalização da Inovação	38
2.5	Artigos Selecionados e Portfólio Bibliográfico	40
3	ANÁLISE DOS RESULTADOS	42
3.1	Ferramenta de Análise Bibliométrica: Bibliometrix	42
3.2	Estratégia de Exploração e Análise de Dados	42
3.3	Visão Geral do Portfólio Bibliográfico	43
3.4	Produção Científica Anual	44
3.5	Análise das Fontes de Publicação	45
3.5.1	Impacto Científico das Fontes (Índice H)	49
3.5.2	Dinâmica de Crescimento das Fontes	50
3.5.3	Dinâmica de Publicação Temporal	51
3.6	Análise da Autoria e Impacto Intelectual	52
3.6.1	Autores Mais Relevantes	52
3.6.2	Lei de Lotka e Dispersão Científica	53
3.6.3	Produtividade e Impacto ao Longo do Tempo	54
3.7	Geografia da Produção Científica: Países e Afiliações	56

3.7.1	Afiliações Institucionais Mais Relevantes	56
3.7.2	Impacto Científico e Distribuição Geográfica	57
3.7.3	Dinâmica de Colaboração Internacional	59
3.8	Estrutura Conceitual: Análise de Palavras-Chave	61
3.9	Análise de <i>Clusters</i>: Estrutura Intelectual do Campo	63
4	DISCUSSÕES	70
4.1	Respostas para perguntas da pesquisa	70
4.1.1	Q1. Quais são os modelos e algoritmos de I.A. mais frequentemente usados para previsão de energia eólica?	71
4.1.2	Q2. Quais variáveis de entrada e parâmetros são mais comumente usados em modelos de previsão de energia eólica?	72
4.1.3	Q3a. A quais horizontes de previsão os modelos foram aplicados?	74
4.1.4	Q3b. Qual é o impacto desses horizontes de previsão no desempenho do modelo?	76
4.1.5	Q4. Quais são as principais deficiências e lacunas nos métodos atuais e quais são as propostas para estudos futuros?	77
4.1.6	Matriz de Decisão Metodológica	78
5	FUNDAMENTOS DO MODELO MLP NA PREVISÃO DE ENERGIA EÓLICA	81
5.1	Aspectos Teóricos do Modelo MLP	81
5.1.1	Estrutura e Funcionamento Matemático	82
5.1.1.1	Funções de Ativação	83
5.1.2	Treinamento e Otimização	84
5.1.3	Generalização e Teorema da Aproximação Universal	85
5.1.4	Desafios: O Dilema Viés-Variância	85
6	ESTUDO DE CASO EM PERNAMBUCO: APLICAÇÃO DO MODELO MLP PARA PREVISÃO DA VELOCIDADE DO VENTO	86
6.1	Contexto Regional e Potencial Eólico	86
6.2	Justificativa da Seleção de Petrolina-PE	87
6.3	Base de Dados e Seleção de Variáveis	88
6.3.1	Análise de Correlação das Variáveis (Validação Estatística)	90

6.4	Arquitetura e Topologia da Rede Neural	92
6.5	Pré-processamento e Implementação Computacional	93
6.5.1	Métricas de Avaliação de Desempenho	95
6.6	Previsão Recursiva de Curto Prazo com MLP	96
6.6.1	Arquitetura do Modelo	96
6.6.2	Procedimento Recursivo	96
6.6.3	Avaliação de Desempenho	97
6.6.4	Síntese do Fluxo de Implementação	97
7	RESULTADOS E DISCUSSÕES	99
7.1	Análise Comparativa das Funções de Ativação	99
7.1.1	Impacto da Redução de Dimensionalidade (Seleção de Variáveis)	100
7.2	Avaliação Quantitativa e Impacto Operacional	101
7.2.1	Interpretação Contextualizada dos Indicadores	101
7.2.2	Interpretação Contextualizada dos Erros e Robustez do Método	102
7.3	Estimativa de Conversão Energética e Fator de Capacidade	103
7.4	Análise da Dinâmica Temporal e Diagnóstico Visual	105
7.4.1	Diagnóstico do Modelo ReLU	105
7.4.2	Diagnóstico do Modelo Sigmoidal	106
7.4.3	Diagnóstico do Modelo Tanh	107
7.4.4	Diagnóstico do Modelo ELU (Melhor Desempenho)	108
7.5	Análise Crítica de Erros e Comparação com Baseline	110
7.5.1	Comparação com o Modelo de Persistência (Baseline)	110
7.5.2	Análise de Resíduos e Limitações em Eventos Extremos	111
8	CONCLUSÃO E TRABALHOS FUTUROS	112
8.1	Síntese das Descobertas Teóricas e Práticas	112
8.2	Contribuições da Pesquisa	113
8.3	Limitações e Trabalhos Futuros	113
	REFERÊNCIAS	115
	APÊNDICE A – EXTRAÇÃO DE DADOS E FICHAMENTO TÉCNICO DOS ARTIGOS SELECIONADOS	122

APÊNDICE B – GUIA DE REFERÊNCIA: MATRIZ DE DECISÃO METODOLÓGICA	132
---	-----

1 Introdução

A energia eólica consolidou-se definitivamente como um pilar central da matriz elétrica global, movida não apenas por sua sustentabilidade ambiental, mas, sobretudo, por sua competitividade econômica superior (IRENA - International Renewable Energy Agency, 2024). Ainda de acordo com a Agência Internacional de Energias Renováveis (IRENA), o custo nivelado de eletricidade da eólica *onshore*, que se refere às instalações em terra, tornou-se, em 2023, 67% inferior à alternativa mais barata baseada em combustíveis fósseis, impulsionando sua adoção em larga escala. Esse avanço econômico levou o setor a ultrapassar recentemente o marco histórico de 1 Terawatt (TW) de capacidade instalada global (GWEC - Global Wind Energy Council, 2024), posicionando países como o Brasil entre os cinco maiores mercados do mundo em novas instalações. Tal cenário é sustentado pela urgente demanda por fontes de energias limpas que atendam às metas globais de descarbonização e preservação ambiental.

Em 2023, a indústria eólica global alcançou um novo recorde, com um aumento de 50% em relação ao ano anterior através da instalação de 117 Gigawatts (GW) de nova capacidade (CUNHA et al., 2024). Esse crescimento reflete a ambição política global, evidenciada durante a COP28 (28ª Conferência das Partes da Convenção-Quadro das Nações Unidas sobre Mudanças Climáticas) (IEA - International Energy Agency, 2024a), realizada em Dubai. Na conferência, os países assumiram o compromisso de triplicar a capacidade instalada de energia renovável global até 2030, atingindo pelo menos 11.000 GW. Essa meta foi reconhecida como essencial para manter o aumento da temperatura global abaixo de 1,5°C e promover o desenvolvimento sustentável. Além disso, destacou-se a importância de integrar essas metas nas Contribuições Nacionalmente Determinadas (NDCs) e de implementar políticas que incentivem investimentos privados e inovações tecnológicas, como inteligência artificial, para enfrentar desafios de intermitência e armazenamento de energia renovável (COP28 - Conferência das Nações Unidas sobre as Mudanças Climáticas de 2023, 2024a; COP28 - Conferência das Nações Unidas sobre as Mudanças Climáticas de 2023, 2024b). A COP28 também enfatizou o papel fundamental das nações em desenvolvimento na transição energética justa e equitativa. A energia eólica foi destacada como um elemento chave na diversificação das matrizes energéticas, impul-

sionada tanto pelas políticas industriais das principais economias quanto pelo crescimento nos mercados emergentes (IEA - International Energy Agency, 2021).

Entretanto, o setor eólico enfrenta desafios significativos que podem impactar sua eficiência e viabilidade econômica, como: (1) A otimização da produção de energia eólica requer uma avaliação cuidadosa de fatores como a localização dos parques eólicos, o modelo das turbinas e as condições ambientais (KALDELLIS; ZAFIRAKIS, 2011); (2) A previsão acurada dos padrões de vento é crucial para garantir uma operação eficiente, permitindo que os operadores de energia planejem a geração de eletricidade e assegurem a integração de maneira eficaz da energia gerada à rede elétrica (WANG; WANG; LIU, 2017). Uma previsão confiável contribui para a estabilidade do fornecimento, uma melhor alocação de recursos e a redução dos custos operacionais; (3) A manutenção eficiente das turbinas eólicas, baseada em previsões precisas e modelos de análise preditiva, desempenha um papel fundamental na redução de tempos de inatividade, aumentando a vida útil dos equipamentos e maximizando a produção de energia (GONZALEZ; ZHANG, 2018).

Neste contexto de alta penetração de renováveis, a intermitência da geração eólica deixa de ser apenas um desafio técnico de estabilidade da rede e converte-se em um risco financeiro crítico. A incapacidade de prever com precisão a disponibilidade de vento em horizontes de curto prazo obriga o Operador Nacional do Sistema (ONS) a despachar termelétricas de segurança, elevando o Preço de Liquidação das Diferenças e onerando o consumidor final. Portanto, a aplicação de técnicas de Inteligência Artificial para refinar a previsibilidade da geração não é apenas uma ferramenta de engenharia, mas um mecanismo estratégico para a modicidade tarifária e a eficiência econômica do setor elétrico brasileiro.

Dessa forma, a Inteligência Artificial (IA) tem se destacado como uma ferramenta crucial para superar os desafios enfrentados pelo setor. Técnicas avançadas, como Aprendizado de Máquina (LUDERMIR, 2021), Redes Neurais (LIU; ZHANG; WANG, 2020) e Aprendizado Profundo, estão sendo cada vez mais utilizadas para resolver problemas críticos, como a previsão da produção de energia e a otimização da manutenção das turbinas. Essas técnicas possibilitam uma análise eficiente de grandes volumes de dados históricos e em tempo real, melhorando significativamente a precisão das previsões de padrões de vento e, conseqüentemente, da geração de energia (ZHOU; ZHANG; JIANG, 2019). Além disso, a IA também facilita a integração da energia eólica em redes elétricas

inteligentes, otimizando o gerenciamento da carga e aumentando a confiabilidade do fornecimento (YAO; ZHANG, 2018). Ao adotar essas abordagens, o setor de energia eólica pode não apenas melhorar sua eficiência operacional, mas também contribuir de maneira mais efetiva para um sistema energético mais sustentável.

Inovações em Inteligência Artificial estão transformando o setor de energia eólica ao possibilitar a criação de sistemas cada vez mais eficientes. Algoritmos de aprendizado profundo vêm aprimorando significativamente a análise de dados, resultando em previsões mais precisas da real produção de energia e uma operação das turbinas de maneira mais otimizada (LIU; ZHANG; WANG, 2020). Essas tecnologias facilitam a identificação de padrões de vento, permitindo a antecipação de falhas e, conseqüentemente, resultam em uma manutenção mais eficiente, reduzindo o tempo de inatividade das turbinas eólicas (ZHOU; ZHANG; JIANG, 2019). Além disso, a adoção de soluções baseadas em IA pode gerar uma redução nos custos operacionais em até 20%, aumentando a rentabilidade dos investimentos (YAO; ZHANG, 2018). Esses avanços impulsionam a transição energética global ao otimizar tanto a produção quanto a integração da energia eólica em redes elétricas inteligentes (KUSIAK; ZHENG, 2010).

Apesar do aumento nas pesquisas sobre a aplicação de IA no setor eólico, ainda se faz necessária uma análise sistemática que investigue como essas abordagens estão sendo implementadas, os principais resultados obtidos e os desafios enfrentados. A realização de uma revisão sistemática é fundamental para identificar essas evidências e destacar as lacunas que podem ser exploradas (DRESCH; LACERDA; FACIN, 2015). Dentre outras, uma lacuna importante a ser abordada é a comparação sistemática de diferentes métodos de previsão, considerando não apenas a precisão, mas também a escalabilidade e a adaptabilidade a diferentes contextos. A complexidade da verificação dos modelos de previsão, que frequentemente geram uma ampla gama de previsões, também dificulta a padronização de métricas de precisão (FOLEY et al., 2012). Embora muitos estudos tenham se concentrado na aplicação de técnicas avançadas de IA para melhorar a precisão das previsões de geração de energia eólica (ZHANG; WANG; WANG, 2017), a vasta quantidade de trabalhos disponíveis na literatura dificulta a síntese e a avaliação das informações disponíveis de maneira clara e objetiva. Esse aumento reflete o número expressivo de estudos que abordam desde melhorias nas previsões até o monitoramento e

manutenção de turbinas, o que destaca o setor eólico como um campo promissor para a aplicação da IA (SILVA; SANTOS, 2022).

Esse crescimento se deve, em parte, à maior disponibilidade de dados e aos avanços nas técnicas de aprendizado de máquina e redes neurais, que têm demonstrado grande potencial para aprimorar a precisão e eficiência das previsões (WANG et al., 2021b). Publicações recentes exploram temas como a adaptação dos modelos de previsão a diferentes contextos climáticos e geográficos, a integração de algoritmos híbridos e a automação de processos de manutenção preditiva, expandindo ainda mais as possibilidades de aplicação da IA no setor (JOHNSON; LEE, 2023). Adicionalmente, revisões sistemáticas e estudos comparativos têm sido desenvolvidos para padronizar metodologias e métricas de avaliação de precisão, facilitando a comparação e integração das abordagens (CHEN; KUMAR, 2020). Esses esforços são essenciais para sintetizar o conhecimento disponível, evidenciando tanto a maturidade quanto as lacunas que ainda precisam ser exploradas na aplicação da IA à energia eólica.

Portanto, este estudo tem como objetivo realizar uma revisão sistemática das principais abordagens de Inteligência Artificial aplicadas ao setor de energia eólica e, complementarmente, implementar um modelo de Redes Neurais MLP para a predição da velocidade do vento no semiárido de Pernambuco. A pesquisa busca identificar tendências promissoras, desafios na implementação dessas tecnologias e oportunidades futuras, investigando os algoritmos mais utilizados e suas variáveis de entrada. Além disso, o trabalho compara medidas de eficiência e examina as lacunas atuais, validando a eficácia da IA na modelagem de séries temporais aplicadas à geração eólica regional.

Para garantir a transparência, a integridade e a replicabilidade do processo de seleção dos estudos primários, esta revisão sistemática foi estruturada seguindo as diretrizes do protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) (PAGE et al., 2021). O PRISMA estabelece um *checklist* baseado em evidências e um fluxograma de quatro etapas (identificação, triagem, elegibilidade e inclusão) que mitigam vieses na seleção de literatura científica (MOHER et al., 2009). A adoção deste protocolo permite que o processo de busca e filtragem seja auditável e reproduzível por outros pesquisadores. Neste trabalho, o PRISMA guiou a estruturação macro do fluxo de busca, enquanto a seleção qualitativa final dos artigos foi refinada pelo método descrito a seguir.

Integrado a esse fluxo, o *Methodi Ordinatio* (PAGANI; KOVALESKI; RESENDE, 2015) foi a abordagem escolhida para classificar e ordenar a relevância do portfólio bibliográfico final. Diferentemente de uma seleção puramente subjetiva, esse método oferece uma métrica quantitativa (InOrdinatio) que pondera o fator de impacto do periódico, o número de citações e a atualidade da publicação (ano). Dessa forma, a metodologia se destaca por sua capacidade de mitigar a subjetividade e otimizar o processo de seleção, assegurando que apenas as obras de maior relevância científica e impacto na área compõem a base da análise crítica desta revisão.

A principal contribuição do estudo é consolidar e explorar a interseção entre IA e previsão de energia eólica, fornecendo *insights* relevantes tanto para a comunidade acadêmica quanto para profissionais do setor energético. Ao reunir e analisar abordagens e tendências contemporâneas, o trabalho pretende enriquecer o conhecimento existente e destacar oportunidades e desafios, com vistas a impulsionar avanços tecnológicos e a sustentabilidade no campo das energias renováveis.

De maneira complementar, este trabalho avança ao aplicar um modelo de previsão baseado em redes neurais artificiais, especificamente a arquitetura *Multilayer Perceptron* (MLP), em um estudo de caso localizado no estado de Pernambuco. A escolha da região se justifica pela sua relevância estratégica no contexto da geração eólica no Brasil e pela diversidade de regimes de vento observados, que representam um desafio adicional para os sistemas de previsão. Assim, a aplicação prática do modelo permite não apenas validar os achados teóricos identificados na literatura, mas também avaliar seu desempenho em um cenário real, subsidiando decisões relacionadas ao planejamento, operação e expansão da matriz energética renovável.

1.1 Objetivos

1.1.1 Objetivo Geral

Realizar um estudo sobre a aplicação de Inteligência Artificial na previsão de energia eólica, fundamentado em uma revisão sistemática da literatura para identificação de tendências e lacunas metodológicas, visando a implementação e validação de um modelo preditivo baseado em Redes Neurais MLP aplicado a um estudo de caso no estado de Pernambuco.

1.1.2 Objetivos Específicos

Para alcançar o objetivo geral proposto, foram definidos os seguintes objetivos específicos:

- Mapear, através do método *Methodi Ordinatio*, as principais arquiteturas de redes neurais e algoritmos de aprendizado de máquina utilizados na literatura recente para previsão eólica;
- Categorizar as variáveis exógenas (meteorológicas) e os parâmetros de treinamento mais recorrentes nos modelos de alto desempenho;
- Analisar o impacto dos diferentes horizontes de tempo (curto, médio e longo prazo) na acurácia das previsões reportadas nos estudos primários;
- Identificar as lacunas e limitações nos métodos vigentes, destacando oportunidades para aprimoramento da integração da IA na operação de sistemas eólicos;
- Implementar a arquitetura selecionada na revisão sistemática (MLP) para a previsão da velocidade do vento, utilizando dados reais de uma estação meteorológica em Pernambuco;
- Validar o desempenho do modelo proposto comparando-o com métricas de erro padrão, verificando sua aderência aos regimes de vento locais.

1.2 Justificativa e Relevância

A energia eólica desempenha um papel fundamental na transição energética global, configurando-se como uma das principais alternativas para a redução das emissões de gases de efeito estufa e para a promoção do desenvolvimento sustentável. Compromissos internacionais, como os firmados durante a COP28, reforçam a meta de triplicar a capacidade instalada de energias renováveis até 2030 (IEA - International Energy Agency, 2024a; COP28 - Conferência das Nações Unidas sobre as Mudanças Climáticas de 2023, 2024a; COP28 - Conferência das Nações Unidas sobre as Mudanças Climáticas de 2023, 2024b). No entanto, a intermitência dos padrões de vento e as limitações na precisão da previsão da geração ainda representam obstáculos significativos à eficiência e à plena integração da energia eólica em redes elétricas inteligentes (ZHOU; ZHANG; JIANG, 2019; YAO; ZHANG, 2018).

No contexto brasileiro, a relevância deste estudo é amplificada pelo protagonismo da região Nordeste, responsável por mais de 90% da capacidade eólica instalada no país (ABEEÓLICA - Associação Brasileira de Energia Eólica, 2024). O estado de Pernambuco, inserido nesse cenário, apresenta regimes de ventos com características específicas que desafiam os modelos de previsão tradicionais. A imprecisão na previsão de geração impacta diretamente a programação diária do Operador Nacional do Sistema (ONS). Quando a geração real frustra a previsão, o ONS é frequentemente obrigado a despachar termelétricas de reserva para garantir a segurança energética, elevando substancialmente o Custo Marginal de Operação (CMO) do sistema. Portanto, desenvolver modelos de IA com maior acurácia local não é apenas um exercício acadêmico, mas uma necessidade econômica estratégica para mitigar o acionamento de fontes fósseis onerosas.

Do ponto de vista científico e tecnológico, a aplicação de técnicas de IA e Aprendizado de Máquina surge como estratégia promissora para mitigar tais desafios (LIU; ZHANG; WANG, 2020; ZHANG; WANG; WANG, 2017; SILVA; SANTOS, 2022). Contudo, o crescimento exponencial de publicações sobre o tema criou um cenário de fragmentação do conhecimento. Justifica-se, portanto, a aplicação do *Methodi Ordinatio* neste trabalho como ferramenta para filtrar e ordenar essa vasta literatura, permitindo identificar quais arquiteturas (como Redes Neurais e modelos híbridos) oferecem, de fato, o melhor equilíbrio entre capacidade preditiva e robustez computacional (JOHNSON; LEE, 2023; CHEN; KUMAR, 2020).

Apesar dos avanços reportados, persistem lacunas relevantes, como a ausência de padronização de métricas de avaliação, dificuldades de escalabilidade e a insuficiência de estudos aplicados em cenários reais de larga escala (KALDELLIS; ZAFIRAKIS, 2011; WANG et al., 2021b). Diante desse panorama, este trabalho se justifica pela necessidade de consolidar o conhecimento existente, identificar tendências e lacunas metodológicas e validar empiricamente um modelo de previsão (MLP) com dados locais. Assim, a pesquisa contribui tanto para a literatura acadêmica quanto para a prática no setor energético, alinhando-se às metas globais de sustentabilidade e à crescente demanda por soluções eficientes no campo da energia renovável (RINGER, 2014; CUNHA et al., 2024).

1.3 Organização do Trabalho

Esta dissertação está estruturada em oito capítulos, organizados de forma a conduzir o leitor desde a fundamentação teórica e o estado da arte até a aplicação prática e análise dos resultados. A seguir, apresenta-se uma breve descrição do conteúdo de cada capítulo:

- O **Capítulo 1** contextualiza a pesquisa, apresentando a motivação, a justificativa e a relevância do estudo frente ao cenário energético global e nacional. Define, ainda, os objetivos gerais e específicos que norteiam o trabalho.
- O **Capítulo 2** detalha o protocolo da Revisão Sistemática da Literatura (RSL), estabelecendo os conceitos centrais sobre energia eólica e Inteligência Artificial. Nesta etapa, são delineados os critérios de busca e seleção que fundamentam a análise do estado da arte.
- O **Capítulo 3** expõe a análise bibliométrica resultante da RSL, mapeando quantitativamente o campo de estudo. São destacados os principais autores, periódicos, países de origem e as redes de colaboração que configuram o panorama científico atual.
- O **Capítulo 4** aprofunda a discussão qualitativa dos achados da revisão, respondendo às questões de pesquisa formuladas. O capítulo identifica as arquiteturas de redes neurais predominantes, as variáveis exógenas mais utilizadas e categoriza as principais lacunas metodológicas existentes na literatura.
- O **Capítulo 5** apresenta a fundamentação teórica da arquitetura *Multilayer Perceptron* (MLP). São descritos sua estrutura matemática, o algoritmo de treinamento supervisionado (*Backpropagation*), suas propriedades de aproximação universal de funções e os desafios inerentes à sua aplicação em séries temporais.
- O **Capítulo 6** descreve a metodologia do estudo de caso realizado em Pernambuco. O capítulo detalha a caracterização da região, a base de dados meteorológicos utilizada, o pré-processamento dos dados e a definição da topologia da rede neural proposta.

- O **Capítulo 7** discute os resultados obtidos com o modelo implementado. É realizada uma avaliação de desempenho baseada em métricas de erro estatístico e uma análise gráfica das previsões, validando a eficácia do modelo frente aos regimes de vento locais.
- Por fim, o **Capítulo 8** apresenta as conclusões finais, sintetizando as contribuições da pesquisa para a academia e para o setor produtivo. São também sugeridas recomendações para trabalhos futuros, visando a continuidade e o aprimoramento das investigações na área.

Ao final, constam as **Referências Bibliográficas** consultadas e os anexos que complementam a documentação deste estudo.

2 Revisão Sistemática da Literatura

A Revisão Sistemática da Literatura (RSL) constitui uma metodologia científica empregada para identificar, avaliar e interpretar as evidências disponíveis sobre uma questão de pesquisa específica (KEELE et al., 2007). Diferentemente de uma revisão narrativa, a RSL segue um protocolo rigoroso e replicável, que inclui a definição clara de critérios de elegibilidade, busca exaustiva em bases de dados, seleção criteriosa de estudos e a síntese estruturada dos achados. Neste trabalho, essa abordagem é fundamental para:

- Identificar as arquiteturas de redes neurais e algoritmos de aprendizado de máquina predominantes na previsão de energia eólica;
- Mapear e categorizar as variáveis exógenas e de entrada utilizadas nos modelos preditivos;
- Determinar o impacto dos diferentes horizontes de previsão (curto, médio e longo prazo) no desempenho dos modelos;
- Diagnosticar as lacunas metodológicas e as limitações das abordagens vigentes na literatura.

Para assegurar o rigor metodológico, este estudo integra duas abordagens complementares: o protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) e o *Methodi Ordinatio*. O PRISMA é adotado para garantir a transparência e a padronização do fluxo de seleção, documentando todas as etapas desde a identificação inicial até a inclusão final dos estudos (PAGE et al., 2021).

Complementarmente, o *Methodi Ordinatio* é aplicado para qualificar o portfólio bibliográfico. Este método utiliza critérios multicritério para avaliar a relevância científica das publicações (PAGANI; KOVALESKI; RESENDE, 2017). O diferencial desta metodologia reside na sua capacidade de ordenação dos artigos através do índice *InOrdinatio*, calculado com base no fator de impacto do periódico, número de citações e ano de publicação. Essa triagem quantitativa, realizada antes da leitura integral, otimiza o processo de revisão, assegurando que a análise se concentre prioritariamente nos estudos de maior impacto e atualidade (PAGANI et al., 2023). Tal estratégia é essencial em áreas com

crescimento exponencial de publicações, como é o caso da aplicação de IA em energias renováveis.

A integração desses dois métodos proporciona uma análise robusta das evidências: enquanto o PRISMA garante a auditabilidade do processo de busca, o *Methodi Ordinatio* assegura a qualidade do conteúdo analisado. Dessa forma, facilita-se a identificação precisa de tendências, lacunas e oportunidades de inovação.

Em conformidade com o protocolo estabelecido, esta revisão foi conduzida através de uma sequência de etapas definidas: (1) formulação das questões de pesquisa; (2) definição dos critérios de inclusão e exclusão; (3) busca sistemática nas bases de dados; (4) filtragem e ordenação pelo *Methodi Ordinatio*; e (5) extração de dados e síntese crítica dos resultados.

2.1 Perguntas de Pesquisa

A previsão de energia eólica é um campo complexo, que demanda diferentes abordagens e técnicas para mitigar a estocasticidade do vento e garantir a confiabilidade dos resultados (MEHTA et al., 2023; OLIVEIRA; ARAÚJO, 2021). Para nortear a condução desta Revisão Sistemática da Literatura (RSL) e assegurar que o levantamento bibliográfico forneça subsídios sólidos para o estudo de caso subsequente, foram formuladas cinco questões de pesquisa (QPs), detalhadas na Tabela 1.

Tabela 1 – Questões de pesquisa norteadoras da revisão sistemática.

ID	Descrição da Pergunta de Pesquisa
Q1	Quais são as arquiteturas de redes neurais e algoritmos de IA predominantes na literatura recente para a previsão de energia eólica?
Q2	Quais variáveis exógenas e parâmetros de entrada (ex: meteorológicos, históricos) demonstram maior correlação com a acurácia dos modelos?
Q3a	Quais horizontes de previsão (curto, médio ou longo prazo) são mais explorados nos estudos primários?
Q3b	Qual é o impacto da variação desses horizontes no desempenho e na degradação do erro dos modelos preditivos?
Q4	Quais são as lacunas metodológicas persistentes e as oportunidades de inovação sugeridas para trabalhos futuros?

Fonte: A autora (2026).

A formulação dessas questões obedece a uma lógica investigativa sequencial. A **Q1** visa estabelecer o estado da arte tecnológico, identificando se há uma hegemonia de modelos específicos (como LSTMs ou híbridos) sobre abordagens estatísticas clássicas. A **Q2** é crucial para o desenho experimental do estudo de caso, pois mapear as variáveis de entrada mais eficazes permite otimizar a coleta de dados e evitar o uso de *inputs* redundantes que elevam o custo computacional sem ganho de precisão.

As questões **Q3a** e **Q3b** investigam a dimensão temporal. Enquanto a **Q3a** categoriza o foco da literatura, a **Q3b** aprofunda a análise ao buscar entender a sensibilidade dos modelos à medida que o horizonte de previsão se expande, um fator crítico para a operação do sistema elétrico real. Por fim, a **Q4** conecta a teoria à contribuição original deste trabalho: ao identificar as limitações atuais (como falta de padronização ou alto custo computacional), é possível posicionar o modelo MLP proposto no Capítulo 6 como uma solução alinhada às necessidades científicas e práticas do setor.

2.2 Estratégia de Busca Booleana

Para operacionalizar a Revisão Sistemática da Literatura (RSL), foi elaborada uma estratégia de busca baseada na lógica Booleana, estruturada para recuperar o máximo de evidências relevantes com o mínimo de ruído informacional (ALIYU, 2017). A construção da *string* de busca fundamentou-se na interseção de três eixos semânticos principais: (i) o objeto de estudo (energia eólica); (ii) a ação ou problema (previsão e demanda); e (iii) a abordagem metodológica (Inteligência Artificial e Aprendizado de Máquina).

A Tabela 2 detalha o protocolo de busca aplicado nas bases Scopus e Web of Science (WoS). Estas bases foram selecionadas devido à sua ampla cobertura multidisciplinar e rigoroso processo de indexação, o que assegura a qualidade científica das publicações recuperadas.

A combinação dos termos através dos operadores booleanos AND e OR permitiu refinar o escopo da pesquisa. O operador OR foi utilizado para agrupar sinônimos dentro de cada eixo semântico (ex: *wind energy* ou *wind power*), garantindo que variações terminológicas não resultassem na exclusão de trabalhos relevantes. Já o operador AND foi empregado para conectar os eixos, assegurando que os resultados contivessem obrigatoriamente a interseção entre energia eólica, previsão e técnicas de IA.

Tabela 2 – Protocolo de busca e filtros aplicados nas bases de dados.

Parâmetro	Descrição / Critério
Bases de Dados	Scopus e Web of Science (WoS)
Campos de Busca	Título, Resumo e Palavras-chave (<i>Topic</i>)
String de Busca	((wind AND energy) OR (wind AND power)) AND ((demand AND forecasting) OR (energy AND prediction AND renewable)) AND ((artificial AND intelligence) OR (machine AND learning) OR (decision model))
Janela Temporal	2014 – 2024 (Últimos 10 anos, abrangendo o avanço do <i>Deep Learning</i>)
Tipo de Documento	Artigos de Periódicos (<i>Journal Articles</i>)
Idioma	Inglês
Data da Extração	13 de agosto de 2024

Fonte: A autora (2026).

Quanto aos critérios de refinamento, delimitou-se a janela temporal entre 2014 e 2024. Essa escolha justifica-se pela inclusão de estudos recentes e relevantes, refletindo as últimas tendências e inovações na área. A restrição ao idioma inglês deve-se ao fato de ser o padrão dominante em publicações de alto fator de impacto na área de engenharia e ciência da computação. Por fim, optou-se por restringir a busca a "artigos de periódicos" (*Articles*), excluindo anais de congressos e capítulos de livros, visando priorizar estudos que passaram por um processo de revisão por pares mais rigoroso e consolidado (OLIVEIRA, 2011).

2.3 Método PRISMA

O protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) consiste em uma diretriz internacional desenvolvida para garantir a transparência, a integridade e a reprodutibilidade de revisões sistemáticas e meta-análises. Originalmente estabelecido com 27 itens de verificação (LIBERATI et al., 2009), o protocolo

foi atualizado em 2020 para refletir os avanços metodológicos na ciência de dados e na síntese de evidências (PAGE et al., 2021).

A estrutura do PRISMA exige o relato detalhado de todas as etapas da revisão, abrangendo desde a formulação da justificativa e objetivos, passando pelos critérios de elegibilidade e estratégias de busca, até a síntese dos resultados e limitações do estudo. Um de seus componentes centrais é o fluxograma de seleção, uma representação visual que mapeia o fluxo da informação através das quatro fases da revisão: identificação, triagem, elegibilidade e inclusão. O fluxograma deve explicitar:

- O número total de registros identificados nas bases de dados;
- O número de registros removidos (duplicatas ou inelegíveis);
- O número de artigos triados e excluídos com suas respectivas justificativas;
- O número final de estudos incluídos na síntese qualitativa ou quantitativa.

Neste trabalho, o fluxograma PRISMA (Figura 1) detalha o rigoroso processo de filtragem aplicado aos modelos de previsão de energia eólica. O processo iniciou-se com a identificação de **1.396 artigos** nas bases Scopus e Web of Science. Na etapa de pré-processamento, 463 duplicatas foram removidas. A fase de triagem analisou os títulos e resumos de 933 registros, resultando na exclusão de 635 trabalhos que não se alinhavam ao escopo da pesquisa (interseção entre IA e Eólica).

Restaram 298 artigos elegíveis para análise aprofundada. Nesta etapa, aplicou-se o *Methodi Ordinatio* como critério de qualificação final. O cálculo do índice *InOrdinatio* permitiu ordenar esses estudos por relevância científica (fator de impacto, citações e ano). Com base nesse ranqueamento, foram selecionados os **50 artigos de maior relevância** para compor o portfólio bibliográfico final.

A aplicação desse filtro de qualidade alinha-se às recomendações de Pagani et al. (PAGANI; KOVALESKI; RESENDE, 2015), que defendem a priorização de obras com maior impacto científico em detrimento de uma análise exaustiva, porém superficial, de grandes volumes de dados. Essa estratégia assegura que a revisão sistemática se concentre nas contribuições mais significativas da literatura, garantindo a robustez das conclusões sem comprometer a viabilidade da análise crítica detalhada (MOHER et al., 2015).

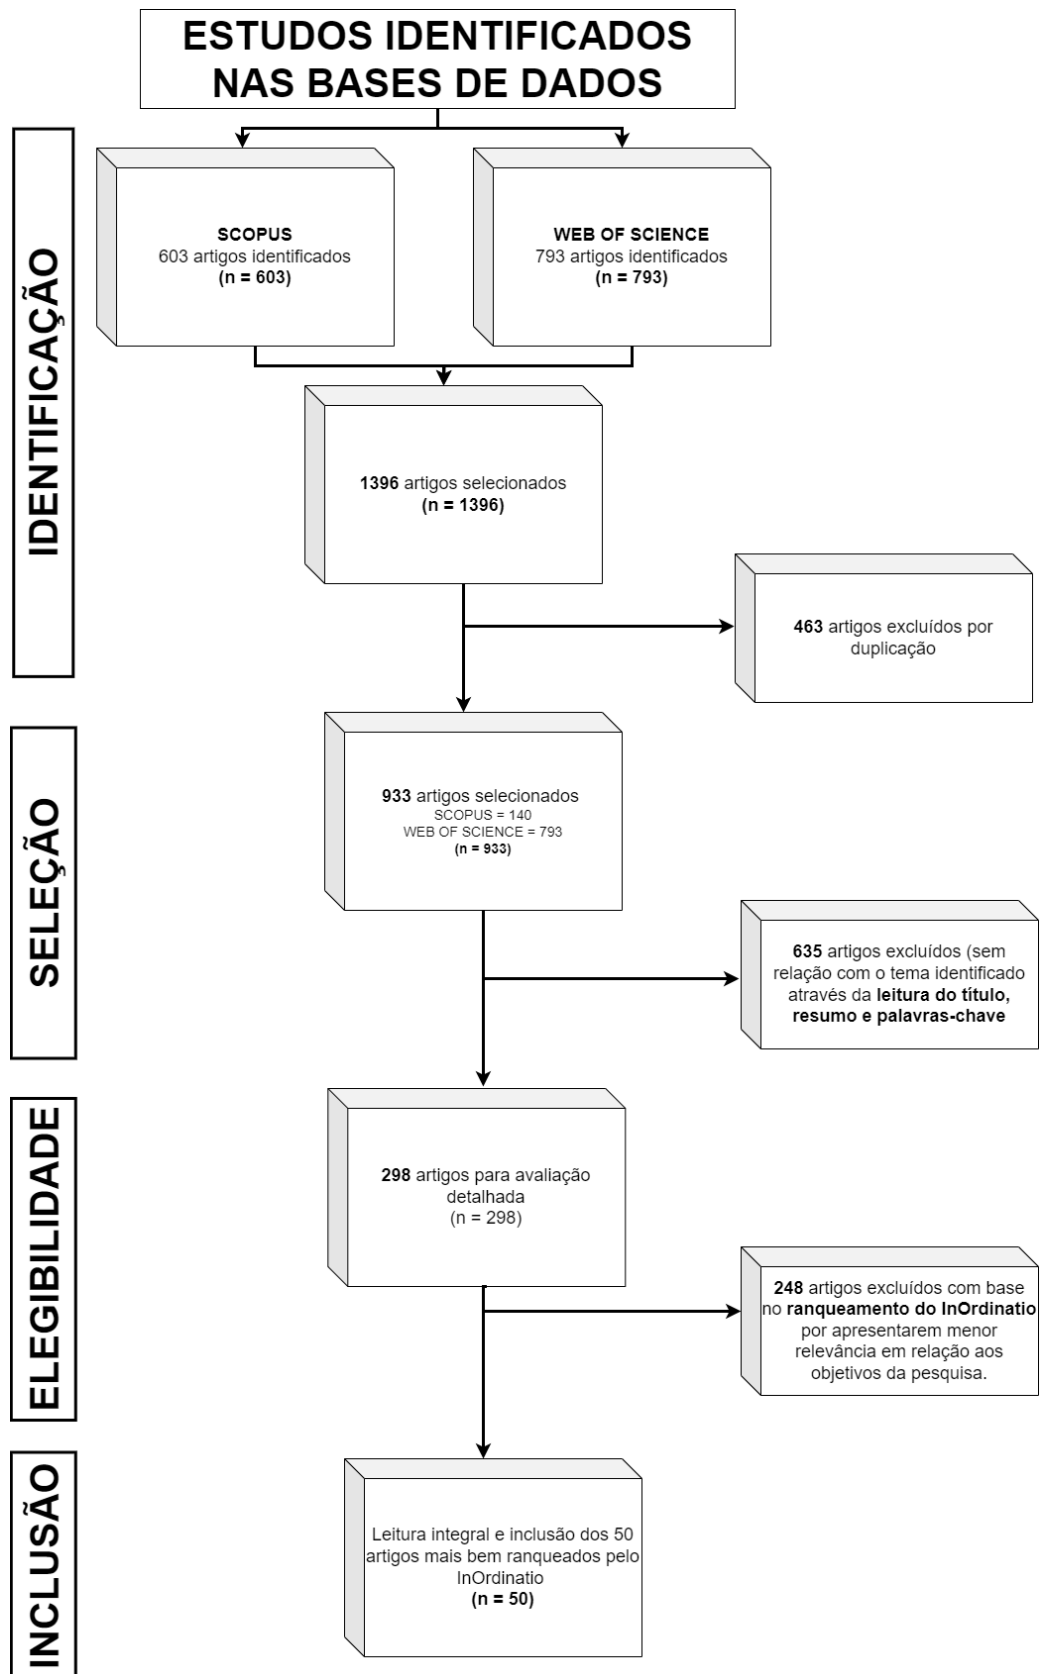


Figura 1 – Fluxograma do processo de seleção PRISMA adaptado com Methodi Ordinatio.

Fonte: A autora (2026).

2.4 *Methodi Ordinatio*

Dada a necessidade de selecionar materiais bibliográficos relevantes em um universo de publicações cada vez mais vasto, (PAGANI; KOVALESKI; RESENDE, 2015; PAGANI; KOVALESKI; RESENDE, 2017) propuseram o *Methodi Ordinatio*. Essa metodologia visa classificar os artigos de um portfólio bibliográfico avaliando sua qualidade científica com base em critérios multicritério predefinidos (CAMPOS et al., 2018). O protocolo baseia-se em premissas do modelo Cochrane (LANG et al., 2006) e na abordagem estruturada do ProKnow-C (CARVALHO et al., 2020).

A escolha dessa metodologia para esta dissertação justifica-se pela sua capacidade de mitigar a subjetividade na seleção de trabalhos. A relevância científica de cada artigo é mensurada pela equação *InOrdinatio*, que pondera três fatores cruciais: o fator de impacto do periódico, o ano de publicação e o número de citações acumuladas.

O processo segue as nove etapas descritas pelo *Methodi Ordinatio*, conforme ilustrado na Figura 2.

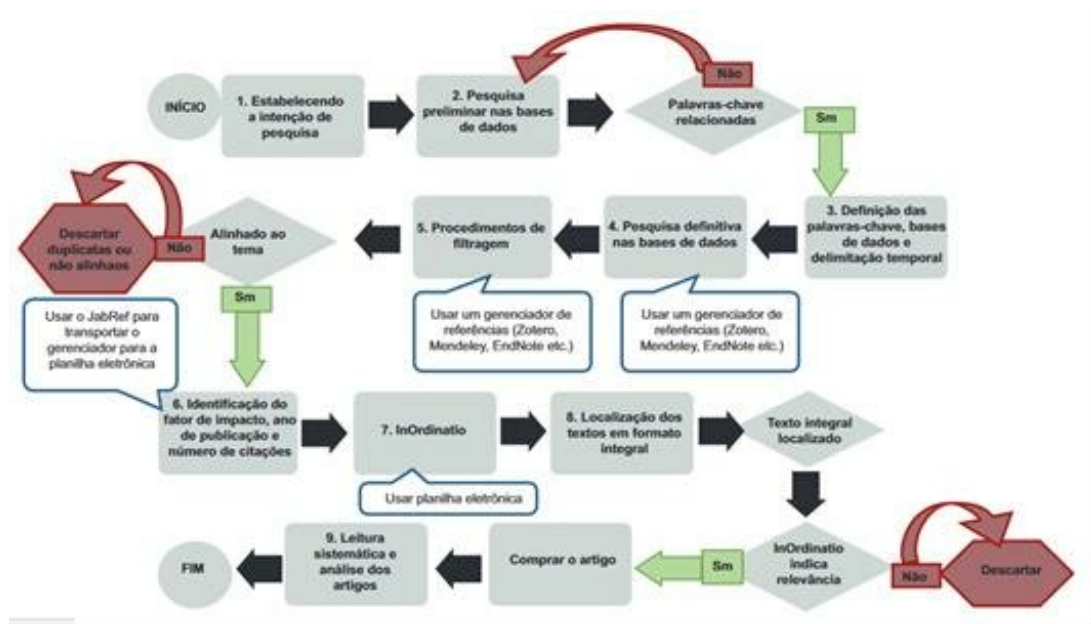


Figura 2 – Fluxo das nove etapas do *Methodi Ordinatio*.

Fonte: Adaptado de (PAGANI; KOVALESKI; RESENDE, 2017).

A aplicação prática dessas etapas neste estudo deu-se da seguinte forma:

1. **Definição da intenção de pesquisa:** Conforme detalhado na Seção 2.1, as questões de pesquisa foram estabelecidas visando mapear o estado da arte da IA na previsão eólica.

2. **Busca preliminar:** Testes iniciais nas bases Scopus e Web of Science permitiram calibrar os termos de busca.
3. **Definição de critérios:** Estabeleceu-se a *string* de busca booleana (Tabela 2) e a delimitação temporal (2014–2024).
4. **Busca definitiva:** Coleta final dos metadados nas bases selecionadas.
5. **Procedimentos de filtragem:** Aplicação dos critérios de elegibilidade seguindo o fluxo PRISMA (Seção 2.3), removendo duplicatas e trabalhos fora do escopo.
6. **Identificação das métricas:** Coleta dos dados brutos (Fator de Impacto/CiteScore, Ano e Citações) para cada artigo elegível.
7. **Cálculo do InOrdinatio:** A equação 2.1 foi aplicada para gerar o *ranking* de relevância. O índice *InOrdinatio* equilibra as métricas: o fator de impacto valoriza o prestígio do periódico; o número de citações valida a repercussão da obra; e o peso α pondera a atualidade do estudo.

$$InOrdinatio = \left(\frac{IF}{1000} \right) + \alpha \cdot [10 - (Ano_{Pesq} - Ano_{Pub})] + \sum C_i \quad (2.1)$$

As variáveis e critérios aplicados especificamente para este estudo estão detalhados nas Tabelas 3 e 4.

Tabela 3 – Descrição das variáveis da equação InOrdinatio.

Variável	Descrição
IF	Fator de impacto (ou CiteScore), dividido por 1000 para normalização de escala.
α	Fator de ponderação (1 a 10) que define a importância da atualidade do tema.
Ano_{Pesq}	Ano em que a pesquisa foi desenvolvida.
Ano_{Pub}	Ano em que o artigo foi publicado.
$\sum C_i$	Total de citações acumuladas pelo artigo.

Fonte: A autora (2026).

8. **Localização dos textos completos:** Todos os artigos selecionados pelo ranking estavam disponíveis ou foram acessados via portal institucional, não havendo descarte por falta de acesso.

Tabela 4 – Critérios e parâmetros aplicados no estudo.

Parâmetro	Valor Adotado / Justificativa
IF	Utilizou-se o CiteScore (Scopus) e JCR (WoS).
α	10 (Dez) . Atribuiu-se o peso máximo devido à rápida obsolescência das técnicas de Inteligência Artificial, tornando a atualidade um fator crítico.
Ano_{Pesq}	2024.
Ano_{Pub}	Variável conforme o artigo (janela 2014–2024).
$\sum C_i$	Número total de citações na data da coleta.

Fonte: A autora (2026).

9. **Leitura e análise sistemática:** Com base no *ranking* gerado, selecionaram-se os **50 artigos** com os maiores índices *InOrdinatio* para compor o portfólio bibliográfico final (de um total de 298 elegíveis). Esta amostra representa os trabalhos de maior relevância científica sobre o tema, assegurando que a revisão contemple as obras de maior impacto, visibilidade e atualidade. A leitura integral e a análise crítica desses trabalhos permitiram a extração sistemática dos dados necessários para responder às questões de pesquisa e fundamentar a escolha do modelo a ser aplicado.

2.4.1 Limitações do Método e a Penalização da Inovação

A aplicação do *Methodi Ordinatio* revelou que, mesmo calibrado com $\alpha = 10$, o índice final permanece altamente sensível ao volume acumulado de citações. Isso cria uma distorção que favorece artigos com alguns anos de maturação em detrimento de pesquisas na fronteira do conhecimento (2023-2024).

A Tabela 5 exemplifica esta barreira de entrada ao comparar o artigo classificado em 1º lugar no ranking geral com trabalhos recentes que, apesar de apresentarem arquiteturas modernas (*Graph Neural Networks* e *Cross-Attention*), foram penalizados pela métrica.

Os dados mostram que o artigo líder do ranking, publicado em 2020, utiliza uma técnica de *Machine Learning* clássica (SVM) otimizada, mas atinge 324 pontos impulsionado por suas 264 citações acumuladas.

Em contraste, observa-se o caso crítico do artigo na posição 51: publicado em 2023 e abordando *Graph Neural Networks* (tecnologia de ponta para dados espaço-temporais), ele obteve 109 pontos. Por uma margem estreita de citações e posicionamento (apenas

Tabela 5 – Distorção Temporal: O "Gap" entre Consolidação e Inovação.

Artigo (Título Resumido / Técnica)	Ano	Cit.	InOrd.	Status
1º Lugar: Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm... (Técnica: SVM + Dragonfly)	2020	264	324,0	Selecionado
51º Lugar: Spatiotemporal analysis of bi-dimensional wind speed forecasting... on the Dutch database (Técnica: LSTM + Graph Neural Networks)	2023	19	109,0	Excluído
85º Lugar: A wind power forecasting model based on data decomposition and cross-attention mechanism... (Técnica: Cross-Attention Mechanism)	2024	1	101,0	Excluído

Fonte: Elaborada pela autora com dados da pesquisa.

uma posição abaixo do corte de 50), ele seria descartado, o que excluiria da revisão uma abordagem essencial para a modelagem de parques eólicos complexos.

Da mesma forma, o artigo na posição 85, de 2024, introduz mecanismos de *Cross-Attention* (estado da arte em processamento de sequências), mas registra uma pontuação de 101 devido à sua recência (apenas 1 citação registrada no momento da coleta).

Em resumo, a aplicação estrita do *Methodi Ordinatio* demonstrou-se eficaz para identificar a literatura consolidada, mas metodologicamente insuficiente para capturar, de forma isolada, o estado da arte emergente, configurando uma limitação crítica em domínios de inovação acelerada como a Inteligência Artificial. Esta distorção, evidenciada pela Tabela 5, não é um fato ocorrido apenas neste estudo, mas, um viés amplamente debatido na literatura científica.

Os próprios desenvolvedores da métrica, Pagani et al. (2022), em sua revisão do método (*Methodi Ordinatio 2.0*), reconhecem matematicamente que o volume de citações exerce o impacto mais agressivo na composição do índice *InOrdinatio*. Como solução para mitigar o descarte de tecnologias recentes, Pagani et al. (2022) propuseram a flexibilização do método, recomendando uma calibração contextual rigorosa do parâmetro α e a implementação de algoritmos complementares (como o *RankIn*) para reavaliar o peso do ano de publicação.

Nesta mesma linha crítica, Ensslin et al. (2020) realizaram um estudo comparativo dissecando os vieses da equação do *Methodi Ordinatio*. Os autores comprovaram que a rigidez matemática da fórmula mascara a relevância técnica de publicações recentes. A solução executada por Ensslin et al. (2020) foi a transição para abordagens de natureza construtivista (como o método ProKnow-C), nas quais o ranqueamento puramente

bibliométrico é substituído ou subordinado a uma triagem qualitativa conduzida pelo pesquisador, garantindo que o mérito do conteúdo prevaleça sobre a inércia das citações.

Este viés métrico é fundamentado pelo fenômeno do atraso de citação (*citation time lag*), amplamente descrito por Waltman (2016). O autor demonstra a incapacidade crônica de indicadores baseados em citação avaliarem rupturas ocorridas nos últimos dois anos. Para solucionar essa defasagem, Waltman (2016) e a literatura especializada recomendam a adoção de indicadores temporalmente normalizados ou a integração de buscas manuais dirigidas.

Apoiando-se nestas críticas consolidadas na literatura, a conduta metodológica adotada neste estudo reconhece as limitações inerentes ao *Methodi Ordinatio*, mas atesta a robustez e a validade do portfólio resultante para os fins desta pesquisa. Como mecanismo prático para mitigar a referida distorção temporal e atenuar a penalização de publicações recentes, adotou-se a calibração do coeficiente em seu limite máximo, estipulando-se $\alpha = 10$. Esta parametrização intencional atuou como um fator de correção matemática direto na equação do *InOrdinatio*, conferindo o maior peso possível ao ano de publicação. Com essa diretriz, garantiu-se que a revisão bibliográfica preservasse o rigor técnico e a reprodutibilidade exigidos pelo método, conseguindo, simultaneamente, reter no escopo de análise as arquiteturas preditivas essenciais para modelar cenários reais de geração eólica.

2.5 Artigos Seleccionados e Portfólio Bibliográfico

Como resultado da aplicação rigorosa das etapas de filtragem e do cálculo da equação *InOrdinatio*, consolidou-se o Portfólio Bibliográfico Final composto pelos 50 artigos de maior relevância científica para esta pesquisa. Este conjunto de obras representa o estado da arte na interseção entre Inteligência Artificial e previsão de energia eólica.

A Tabela A1 (disponível na íntegra no Apêndice A) apresenta a classificação final desses estudos. Os trabalhos estão ordenados de forma decrescente conforme o índice *InOrdinatio*, evidenciando aqueles que melhor combinam alto fator de impacto, reconhecimento pelos pares (citações) e atualidade.

A análise deste portfólio revela uma amostra heterogênea e robusta, abrangendo desde estudos consolidados e altamente citados até pesquisas recentes que propõem ar-

quiteturas inovadoras. As informações sistematizadas nesta tabela, incluindo título, ano, periódico e métricas de impacto, constituem a base de dados primária para a análise bibliométrica e a discussão crítica que serão desenvolvidas nos capítulos subsequentes.

3 Análise dos Resultados

Este capítulo dedica-se à apresentação e discussão dos resultados obtidos através da RSL. A análise divide-se em duas vertentes complementares: uma abordagem quantitativa (bibliométrica), que mapeia o panorama estatístico das publicações, e uma abordagem qualitativa, que discute criticamente as arquiteturas de IA, variáveis e metodologias identificadas, respondendo às questões de pesquisa formuladas na seção 2.1.

3.1 Ferramenta de Análise Bibliométrica: Bibliometrix

Para a execução da análise cientométrica, área que aplica métodos quantitativos e estatísticos para medir, analisar e avaliar a produção científica, produtividade e impacto de pesquisas, autores e instituições, adotou-se o pacote *Bibliometrix*, uma ferramenta de código aberto desenvolvida por (ARIA; CUCCURULLO, 2017) no ambiente de programação R. A escolha desta ferramenta justifica-se pela sua robustez em realizar o mapeamento científico completo (*Science Mapping Analysis*), permitindo processar grandes volumes de metadados bibliográficos e gerar visualizações complexas sobre a estrutura conceitual, intelectual e social do campo de estudo. O pacote oferece um fluxo de trabalho transparente e reproduzível, essencial para garantir o rigor metodológico da revisão.

3.2 Estratégia de Exploração e Análise de Dados

A estratégia de exploração dos dados centrou-se em identificar padrões evolutivos e tendências emergentes na literatura sobre previsão de energia eólica. A análise foi estruturada em três dimensões principais:

1. **Análise Descritiva e de Desempenho:** Exame da evolução temporal das publicações, identificação das fontes (periódicos) mais influentes (Lei de Bradford) e dos autores mais relevantes (Lei de Lotka).
2. **Estrutura Conceitual e Temática:** Mapeamento das palavras-chave e coocorrências para identificar os temas centrais e os nichos de pesquisa em ascensão ou

declínio, com foco específico na interseção entre energias renováveis e técnicas de IA.

3. **Estrutura Social e de Colaboração:** Análise das redes de coautoria e da colaboração entre países/instituições, permitindo visualizar como o conhecimento é disseminado globalmente.

Esse mapeamento sistemático não apenas quantifica a produção científica, mas fornece os subsídios necessários para a discussão qualitativa subsequente, elucidando quais abordagens de Aprendizado de Máquina (ex: Redes Neurais, Modelos Híbridos) têm demonstrado resultados mais promissores e quais lacunas metodológicas persistem na literatura atual.

3.3 Visão Geral do Portfólio Bibliográfico

A Tabela 6 sintetiza as métricas descritivas fundamentais dos 50 artigos selecionados para compor o portfólio final, compreendendo o período de 2014 a 2024. Os dados revelam que as publicações provêm de 20 fontes distintas, o que indica um núcleo concentrado de periódicos de alto impacto.

Um dado que merece destaque é a média de citações por documento, que atingiu o valor de **97,74**. Este indicador valida a eficácia do filtro aplicado pelo *Methodi Ordinatio*, confirmando que o portfólio é constituído por obras de alto impacto e amplo reconhecimento pela comunidade científica, e não por uma seleção aleatória.

Em relação à estrutura conceitual, foram identificadas 220 palavras-chave definidas pelos autores e 286 termos indexados, o que evidencia a diversidade terminológica e a multidisciplinaridade do campo. Além disso, a participação de 206 autores e o índice de 40% de coautoria internacional demonstram que a pesquisa em previsão eólica utilizando IA é uma área globalizada e fortemente colaborativa.

Tabela 6 – Resumo estatístico do portfólio bibliográfico selecionado.

Métrica Descritiva	Resultados
Período de Análise	2014–2024
Fontes (Periódicos)	20
Total de Documentos	50
Média de Citações por Documento	97,74
<i>Keywords Plus</i> (Indexadas)	286
Palavras-chave dos Autores	220
Total de Autores	206
Coautoria Internacional	40%

Fonte: Elaborada pela autora via Bibliometrix (2026).

3.4 Produção Científica Anual

A Figura 3 ilustra a distribuição temporal dos artigos selecionados para o portfólio bibliográfico. Embora a janela de busca tenha abrangido o período de 2014 a 2024, nota-se a ausência de artigos no ano inicial (2014) após a aplicação do *Methodi Ordinatio*. Isso não implica inexistência de produção naquele ano, mas reflete o rigor da metodologia: os artigos de 2014 não atingiram a pontuação necessária no índice *InOrdinatio* para entarem entre os 50 mais relevantes, provavelmente devido à relação entre o número de citações acumuladas e a antiguidade da publicação.

Observa-se uma tendência de crescimento consistente na produção científica, com um aumento expressivo no quadriênio 2019–2022. O pico de produtividade ocorreu nos anos de 2020 e 2022, com 10 publicações selecionadas em cada ano. Esse comportamento ascendente pode ser atribuído à convergência de fatores geopolíticos e tecnológicos.

Primeiramente, a urgência da transição energética, acelerada também pelo Acordo de Paris e pelas metas da Agenda 2030, ampliou o financiamento para pesquisas em renováveis (MCKENZIE, 2021). Paralelamente, a maturação de algoritmos de Aprendizado Profundo (*Deep Learning*) e o aumento da capacidade computacional permitiram o desenvolvimento de modelos preditivos com acurácia sem precedentes, atraindo o interesse massivo da comunidade acadêmica (HANIFI et al., 2020; IEA - International Energy Agency, 2021).

É importante ressaltar a redução no número de artigos selecionados em 2023 (4 publicações) e 2024. Cabe destacar que, para este estudo, foi atribuído o valor máximo ao fator de ponderação temporal ($\alpha = 10$), com o objetivo explícito de valorizar a atualidade da pesquisa. No entanto, mesmo com essa maximização do peso para o ano de publicação, a característica intrínseca do *Methodi Ordinatio*, conhecida como latência de citações, prevaleceu. Como a equação de ordenação é fortemente influenciada pelo número total de citações ($\sum C_i$), artigos recém-publicados, que ainda não tiveram tempo hábil para acumular citações, acabam sendo matematicamente superados por obras consolidadas de 2020 ou 2021, mesmo com o "bônus" do fator α . Dessa forma, a queda recente no portfólio não indica um declínio no interesse pelo tema, mas sim uma limitação temporal do método de seleção, que favorece trabalhos que já repercutiram na literatura em relação a publicações muito recentes.




Figura 3 – Evolução da produção científica anual no portfólio selecionado.

Fonte: Elaborada pela autora via Bibliometrix (2026).

3.5 Análise das Fontes de Publicação

Os periódicos científicos constituem o principal canal de disseminação do conhecimento acadêmico. Na análise bibliométrica, identificar as fontes mais relevantes permite não apenas mapear onde o debate científico ocorre, mas também avaliar a maturidade e a especialização do campo (REIS, 2015).

A Figura 4 apresenta a dispersão dos periódicos segundo a Lei de Bradford. Esta lei postula que, em qualquer área do conhecimento, um pequeno núcleo de periódicos concentra a maioria dos artigos relevantes (Zona 1), enquanto os demais se distribuem em zonas periféricas com produtividade decrescente (PINHEIRO, 1983).

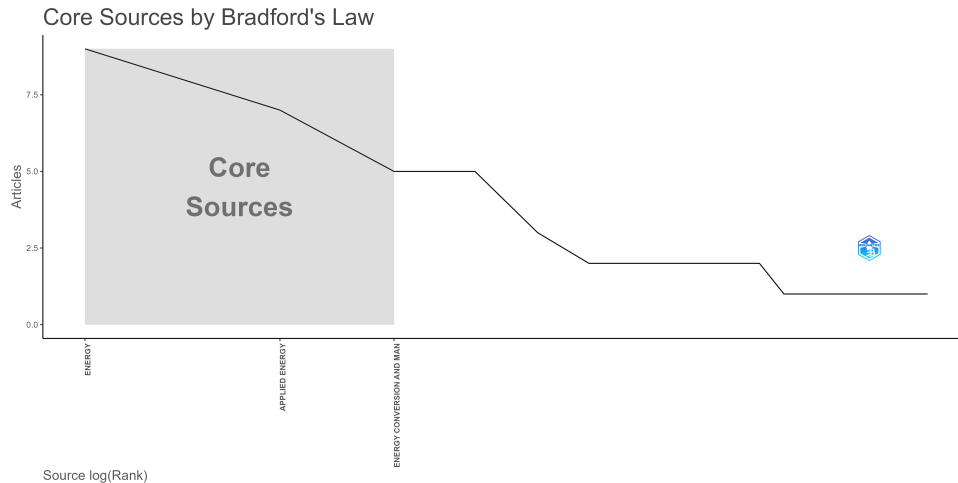


Figura 4 – Distribuição dos periódicos segundo a Lei de Bradford (Core Sources).

Fonte: Elaborada pela autora via Bibliometrix (2026).

A região sombreada na Figura 4 corresponde à Zona 1 (Fontes Nucleares). A Tabela 7 detalha a distribuição dos periódicos por zona, incluindo métricas de produtividade, modelo de acesso e escopo editorial.

Tabela 7 – Caracterização dos periódicos por zona de Bradford, acesso e escopo.

Zona	Periódico	Pub.	Acesso	Foco Principal
1	Energy	9	Híbrido	Gestão, eficiência, modelagem e políticas energéticas.
	Applied Energy	7	Híbrido	Tecnologias sustentáveis e impactos socioeconômicos.
	Energy Conversion and Management	5	Híbrido	Conversão de energia, eficiência e sustentabilidade.
2	Renewable Energy	5	Híbrido	Tecnologias renováveis e transição energética.
	Energies	3	Open Access	Inovação em energias renováveis e tecnologias emergentes.

Continua na próxima página

Tabela 7 – *Continuação da página anterior*

Zona	Periódico	Pub.	Acesso	Foco Principal
	Journal of Cleaner Production	3	Híbrido	Sustentabilidade, economia circular e produção limpa.
	Energy Reports	2	Open Access	Relatórios técnicos e pesquisa aplicada em energia.
3	IEEE Access	2	Open Access	Interdisciplinar e tecnologias emergentes.
	IEEE Transactions on Neural Networks and Learning Systems	2	Híbrido	IA aplicada a sistemas complexos.
	IEEE Transactions on Power Systems	2	Híbrido	Integração de renováveis em sistemas de potência.
	Renewable Sustainable Energy Reviews	2	Híbrido	Revisões críticas sobre fontes renováveis.
	Expert Systems with Applications	1	Híbrido	Machine Learning aplicado à indústria.
	Frontiers in Energy Research	1	Open Access	Tecnologias energéticas e sustentabilidade.
	IEEE Transactions on Industrial Electronics	1	Híbrido	Eletrônica industrial e eficiência.
	IEEE Transactions on Industrial Applications	1	Híbrido	Aplicações industriais de sistemas de energia.
	International Journal of Electrical Power & Energy Systems	1	Híbrido	Eficiência e estabilidade de sistemas elétricos.
	Neurocomputing	1	Híbrido	IA e computação neural aplicada.

Continua na próxima página

Tabela 7 – Continuação da página anterior

Zona	Periódico	Pub.	Acesso	Foco Principal
	Sustainable Energy Technologies Assessments	1	Híbrido	Avaliação técnica e econômica de tecnologias.

A análise das zonas revela a hegemonia do modelo de acesso híbrido nas Fontes Centrais (Zona 1). Periódicos de alto impacto como *Energy* e *Applied Energy*, que lideram a produção com 9 e 7 artigos respectivamente, operam majoritariamente sob o regime de assinatura (*closed access*). No entanto, oferecem a flexibilidade do acesso aberto mediante o pagamento da Taxa de Processamento de Artigo (*Article Processing Charge - APC*) por parte dos autores (PAVAN, 2018). Esse modelo reflete uma estratégia editorial que busca conciliar a sustentabilidade econômica das publicações com a crescente demanda pela democratização e disseminação ampla do conhecimento científico de relevância específica.

Por outro lado, a presença de periódicos *Open Access* como *Energies* e *Energy Reports* na Zona 2 (Intermediária) indica uma tendência de democratização do conhecimento. Estes veículos desempenham um papel crucial na disseminação rápida de pesquisas em um campo dinâmico como a IA, onde a velocidade de publicação é um fator competitivo.

A Figura 5 complementa esta análise ao ordenar visualmente as fontes por volume de produção.




Figura 5 – Ranking dos periódicos mais relevantes por número de publicações.
Fonte: Elaborada pela autora via Bibliometrix (2026).

Observa-se que o periódico *Energy* lidera o ranking, seguido pelo *Applied Energy*. A relevância dessas revistas sugere que a comunidade científica prioriza veículos com escopo amplo em engenharia de energia em detrimento de revistas puramente de computação, indicando que o foco principal das pesquisas é a aplicação prática da IA no setor energético, e não apenas o desenvolvimento algorítmico teórico.

Contudo, periódicos especializados em computação, como o *IEEE Transactions on Neural Networks and Learning Systems* e *Neurocomputing*, aparecem na Zona 3, evidenciando que há um nicho importante de pesquisas focadas na inovação da arquitetura das redes neurais para resolver a complexidade estocástica do vento.

3.5.1 Impacto Científico das Fontes (Índice H)

Enquanto a contagem total de publicações mensura a produtividade bruta, o Índice H, proposto por Hirsch (HIRSCH, 2005), avalia a robustez e a consistência do impacto científico. Este indicador é calculado com base no número de citações recebidas, sendo menos suscetível a distorções causadas por um único artigo muito citado ou por uma grande quantidade de artigos com baixo impacto.

A Figura 6 apresenta as principais fontes ordenadas por este indicador.




Figura 6 – Classificação das 10 principais fontes baseada no Índice H.

Fonte: Elaborada pela autora via Bibliometrix (2026).

O periódico *Energy* destaca-se com um índice H de 9. Isso significa que, dentro do portfólio analisado, 9 de seus artigos receberam, no mínimo, 9 citações cada. Esse

resultado confirma sua posição de liderança não apenas em volume, mas também em autoridade científica no tema.

Em contraste, fontes como o *IEEE Transactions on Neural Networks and Learning Systems* apresentam um índice H menor, sendo 2. Isso é natural, dado que é um periódico de computação pura, competindo em uma análise dominada por revistas de engenharia de energia. Contudo, a presença desses periódicos no *ranking* indica que, quando publicam sobre energia eólica, seus artigos tendem a ser referências técnicas importantes para o desenvolvimento de novos algoritmos.

3.5.2 Dinâmica de Crescimento das Fontes

Para compreender a evolução do interesse editorial sobre o tema, analisou-se a dinâmica de publicação acumulada ao longo do tempo. A Figura 7 ilustra as trajetórias de crescimento dos principais periódicos.




Figura 7 – Dinâmica de crescimento da produção científica por periódico (2014–2024).

Fonte: Elaborada pela autora via Bibliometrix (2026).

A análise das curvas de crescimento revela dois padrões distintos:

1. **Crescimento Exponencial:** Os periódicos *Applied Energy* e *Energy* (Zona 1) apresentam uma inflexão positiva acentuada a partir de 2019. Esse comportamento sugere que estas revistas se consolidaram como os principais fóruns para a disse-

minação de avanços em IA aplicada à energia eólica, absorvendo a maior parte do aumento recente na produção científica global.

2. **Crescimento Linear:** Periódicos como *Energies* e *Energy Conversion and Management* demonstram um crescimento constante, porém menos acelerado. Isso indica uma produção regular e contínua, característica de veículos que mantêm um fluxo estável de publicações sobre o tema, sem necessariamente experimentar o mesmo "boom" observado nas revistas líderes.

Essa visualização confirma que a pesquisa em previsão eólica não está dispersa aleatoriamente, mas converge crescentemente para um núcleo específico de periódicos de alto impacto que priorizam a aplicação prática de modelos preditivos.

3.5.3 Dinâmica de Publicação Temporal

A Figura 8 ilustra a evolução acumulada das publicações por periódico ao longo dos anos, permitindo visualizar a taxa de crescimento do interesse editorial.




Figura 8 – Crescimento acumulado da produção por periódico (2014–2024).

Fonte: Elaborada pela autora via Bibliometrix (2026).

O gráfico evidencia um crescimento exponencial acentuado dos periódicos *Applied Energy* e *Energy* a partir de 2019. Esse ponto de inflexão na curva coincide temporalmente com o amadurecimento e a popularização das técnicas de *Deep Learning* no setor energético.

Enquanto periódicos mais tradicionais ou específicos apresentam um crescimento linear e constante, estas duas fontes consolidaram-se como os principais vetores para a disseminação do estado da arte. Isso sugere que os pesquisadores tendem a submeter modelos de IA inovadores a revistas de alto impacto que possuem escopo interdisciplinar, unindo sistemas de potência e ciência da computação.

3.6 Análise da Autoria e Impacto Intelectual

A identificação dos autores mais produtivos e influentes permite mapear a estrutura social do campo de pesquisa, revelando os principais núcleos de liderança intelectual. Esta análise foi conduzida considerando dois eixos principais: a produtividade quantitativa (número de publicações) e o impacto qualitativo (citações e consistência temporal).

3.6.1 Autores Mais Relevantes

A Tabela 8 apresenta os autores com maior número de contribuições no portfólio bibliográfico selecionado. Observa-se que a liderança em produtividade é compartilhada por Moreno S., Wang J. e Zhang G., cada um com 4 artigos aprovados pelos critérios do *Methodi Ordinatio*.

Tabela 8 – Autores mais relevantes por número de publicações no portfólio.

Autor	Número de Artigos
MORENO S	4
WANG J	4
ZHANG G	4
LI L	3
TSENG M	3
ABUALIGAH L	2
CARVALHO P	2
COELHO L	2
DONG Z	2
FERNANDEZ-RAMIREZ L	2

Fonte: Elaborada pela autora via Bibliometrix (2026).

A análise destes dados evidencia uma acentuada fragmentação da produção científica. Observa-se que mesmo os autores mais prolíficos, como: Moreno S., Wang J. e

Zhang G., contribuíram com 4 artigos cada dentro da amostra qualificada. Este dado sugere que a pesquisa em previsão eólica assistida por IA é um campo vasto e colaborativo, desprovido de domínio hegemônico por parte de um único pesquisador ou laboratório isolado.

Autores como Li L. e Tseng M., com três publicações cada, demonstram alta relevância e constância na literatura de ponta, embora em volume ligeiramente inferior aos líderes do *ranking*. Já autores como: Abualigah L., Carvalho P., Coelho L., Dong Z. e Fernandez-Ramirez L., com duas contribuições cada, reforça a base intelectual do setor. Esta distribuição confirma a diversidade de vozes e abordagens metodológicas, demonstrando que a inovação na área investigada não depende exclusivamente de poucos "super-autores", mas sim de uma comunidade científica ampla e ativa.

3.6.2 Lei de Lotka e Dispersão Científica

Para avaliar a concentração da produção científica, aplicou-se a Lei de Lotka (Lotka's Law). Esta lei modela a frequência de publicação de autores em um determinado campo, postulando uma relação de quadrado inverso: o número de autores que publicam n artigos é aproximadamente $1/n^2$ daqueles que publicam apenas um artigo (LOTKA, 1926).




Figura 9 – Distribuição de frequência de autores (Lei de Lotka).

Fonte: Elaborada pela autora via Bibliometrix (2026).

A Figura 9 ilustra a aplicação dessa lei à amostra. Os resultados indicam uma alta taxa de transitoriedade:

- **89,3% dos autores (184)** publicaram apenas um artigo sobre o tema.
- **8,3% (17 autores)** contribuíram com dois artigos.
- Apenas **1% (2 autores)** publicaram três artigos e **1,5% (3 autores)** alcançaram a marca de quatro publicações.

O percentual de autores com produção única (89,3%) é significativamente superior ao valor padrão de aproximadamente 60% previsto pela Lei de Lotka (LOTKA, 1926). Esse desvio indica uma alta taxa de transitoriedade no campo, caracterizando-o como altamente disperso. Isso sugere que a área de previsão eólica com IA atrai muitos pesquisadores que realizam contribuições pontuais, mas que ainda não estabeleceram uma linha de pesquisa contínua e exclusiva sobre o tema.

3.6.3 Produtividade e Impacto ao Longo do Tempo

A análise temporal da produção científica apresentada na Figura 10, permite visualizar a trajetória e a consistência da carreira dos principais pesquisadores. O gráfico correlaciona três dimensões simultâneas: a linha do tempo (eixo X), o volume de publicações (representado pelo diâmetro do círculo) e o impacto total medido por citações (representado pela intensidade da cor).




Figura 10 – Evolução da produtividade e impacto dos autores (2015–2024).

Fonte: Elaborada pela autora via Bibliometrix (2026).

A interpretação detalhada dos 10 autores mais relevantes revela perfis distintos de contribuição para o campo:

- **Alto Impacto Concentrado:** O autor **Li, L.** destaca-se como um caso de influência notável. Com três artigos publicados em 2020, acumulou 679 citações (média de 135,8 citações/artigo). Tal métrica sugere fortemente a publicação de um trabalho que se tornou referência obrigatória na literatura recente. Padrão similar é observado em **Dong, Z.**, que obteve 324 citações com apenas dois trabalhos no mesmo ano.
- **Consistência Temporal:** Autores como **Wang, J.** e **Zhang, G.** apresentam um perfil de liderança consolidada. Wang manteve publicações consistentes entre 2015 e 2021 com médias de citação elevadas, demonstrando a relevância perene de suas investigações. Zhang, em particular, registrou um pico de impacto em 2020 (471 citações), indicando uma contribuição disruptiva naquele período.
- **Contribuições Emergentes:** O autor **Abualigah, L.** representa a nova geração de pesquisadores, com publicações iniciadas em 2022 e continuidade em 2024. O padrão crescente de citações sugere que suas linhas de pesquisa estão alinhadas com as tendências mais atuais da IA, possivelmente focadas em algoritmos de otimização recentes.
- **Colaboração Estável:** Autores como **Coelho, L.**, **Carvalho, P.** e **Fernandez-Ramirez, L.** demonstram uma produção estável com impacto moderado e constante. Este perfil é característico de pesquisadores focados na validação experimental e em estudos de caso robustos, fundamentais para a maturação tecnológica e aplicabilidade dos modelos na indústria.

Essa análise confirma que o avanço no estado da arte da previsão eólica é impulsionado por uma simbiose entre pesquisadores "veteranos", que garantem a consistência metodológica da área, e autores que produzem inovações pontuais de altíssimo impacto (*breakthroughs*), frequentemente associadas à introdução de novas arquiteturas de *Deep Learning*.

3.7 Geografia da Produção Científica: Países e Afiliações

A análise da distribuição geográfica e institucional da produção científica é fundamental para compreender como o conhecimento sobre previsão eólica está disseminado globalmente. Esta seção mapeia os centros de excelência e as redes de cooperação, destacando o papel estratégico que determinadas nações desempenham no desenvolvimento de tecnologias de Inteligência Artificial para energias renováveis (PEI et al., 2024).

3.7.1 Afiliações Institucionais Mais Relevantes

A Figura 11 apresenta as instituições com maior volume de publicações no portfólio analisado. Observa-se uma clara hegemonia de instituições asiáticas, refletindo o deslocamento do eixo de inovação tecnológica do Atlântico Norte para o Oriente.




Figura 11 – Instituições mais relevantes por número de artigos publicados.

Fonte: Elaborada pela autora via Bibliometrix (2026).

As instituições de maior destaque são a *Lanzhou University* (China) e o *Pakistan Institute of Engineering and Applied Sciences* (PIEAS), ambas liderando com 7 artigos cada. A presença robusta de universidades chinesas, como a *Hebei University of Technology* e a *Dongbei University of Finance and Economics*, é coerente com a política nacional da China de investir massivamente em *Smart Grids*. Essas redes inteligentes, definidas como infraestruturas de distribuição de energia modernizadas com tecnologias

digitais, sensores e comunicação bidirecional, são pilares fundamentais na estratégia de digitalização do setor elétrico.

No contexto nacional, destaca-se a Universidade Federal do Ceará (UFC), com 4 publicações entre as universidades de maior relevância mundial. A presença da UFC neste *ranking* global não é por acaso, ela reflete a vocação natural da região Nordeste do Brasil, que concentra mais de 90% da capacidade eólica instalada do país. A academia local tem respondido à demanda do setor produtivo desenvolvendo modelos preditivos ajustados aos regimes de ventos específicos do litoral brasileiro onde há a presença dos ventos alísios. Estes fluxos são caracterizados pela regularidade direcional e constância de intensidade ao soprares das altas pressões subtropicais para as baixas pressões equatoriais, favorecendo um fator de capacidade elevando, consolidando o Brasil como um ator estratégico bastante relevante na pesquisa aplicada em energia eólica.

3.7.2 Impacto Científico e Distribuição Geográfica

É fundamental distinguir entre o volume de produção (esforço) e o número de citações (impacto). A Figura 12 ilustra a métrica de impacto, revelando a influência real que cada nação exerce sobre a comunidade científica.




Figura 12 – Países mais citados (Total de Citações Acumuladas).

Fonte: Elaborada pela autora via Bibliometrix (2026).

A China lidera isoladamente com 2.387 citações. Essa disparidade reflete a estratégia estatal de Dupla Circulação e as metas ambiciosas de atingir o pico de emissões antes

de 2030 e a neutralidade de carbono até 2060. O governo chinês elevou a IA aplicada à energia ao status de tecnologia de estado, gerando um ciclo virtuoso onde o alto volume de produção, aliado a uma qualidade técnica crescente, domina as métricas de impacto (VEJA, 2024).

Notavelmente, o Brasil ocupa a segunda posição em citações totais (381), superando potências científicas tradicionais como Reino Unido, EUA e Austrália neste nicho. Este dado é um indicador de eficiência científica: mesmo com um volume de produção menor que o da China, como visto na Tabela 9, os artigos brasileiros possuem alta inserção e são amplamente referenciados, superando barreiras linguísticas e de financiamento.

A Tabela 9 complementa ainda, esta análise apresentando a frequência absoluta de artigos.

Tabela 9 – Ranking de produtividade científica (Frequência de Artigos).

País	Nº de Artigos (Volume)
CHINA	62
BRASIL	19
AUSTRÁLIA	9
PAQUISTÃO	8
REINO UNIDO	7
EUA	7
IRÃ	6
IRLANDA	6
JORDÂNIA	6

Fonte: Elaborada pela autora via Bibliometrix (2026).

A espacialização desses dados apresentados na Figura 13, permite visualizar um fenômeno geopolítico relevante: a concentração da produção no Sul Global (Brasil, China, Irã, Paquistão).

Country Scientific Production

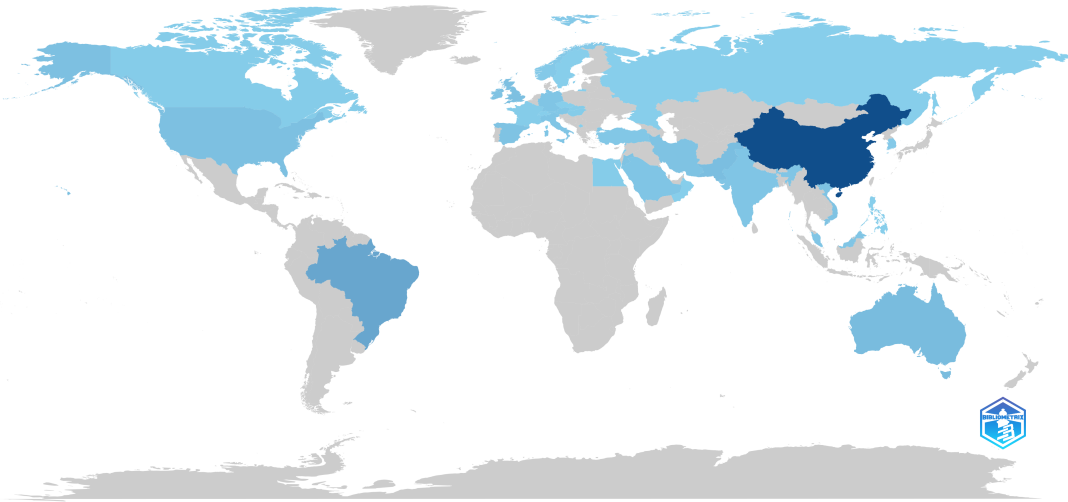


Figura 13 – Distribuição geográfica da produção científica global.

Fonte: Elaborada pela autora via Bibliometrix (2026).

Este mapa desafia a noção tradicional de que a ciência de ponta reside exclusivamente no Hemisfério Norte. A proeminência desses países sugere que as nações em desenvolvimento, que enfrentam desafios urgentes de expansão de infraestrutura energética e integração de renováveis, estão assumindo o protagonismo no desenvolvimento de soluções preditivas baseadas em IA para otimizar suas matrizes energéticas.

3.7.3 Dinâmica de Colaboração Internacional

A complexidade dos modelos de previsão eólica modernos exige frequentemente a cooperação transnacional. A Figura 14 decompõe a produção em *Single Country Publications* (SCP) e *Multiple Country Publications* (MCP).




Figura 14 – Proporção de publicações domésticas (SCP) e internacionais (MCP).

A análise revela perfis distintos de internacionalização:

- **China:** Apresenta um volume massivo de publicações domésticas (SCP), sustentado por seu vasto ecossistema interno de pesquisadores. Cerca de 72,7% de sua produção é feita inteiramente por instituições chinesas, indicando autossuficiência tecnológica.
- **Brasil:** Demonstra um perfil equilibrado e aberto, com 50% de suas publicações envolvendo colaboração internacional (MCP). Isso reflete a maturidade da pós-graduação brasileira, que busca ativamente parcerias para acessar recursos computacionais avançados e aumentar a visibilidade de seus estudos.
- **Austrália e França:** Destacam-se pela totalidade (100%) ou ampla maioria de publicações em MCP, indicando que sua estratégia científica é baseada quase exclusivamente em redes globais.

Por fim, o mapa de redes de colaboração apresentado na Figura 15 confirma essas tendências.

Country Collaboration Map

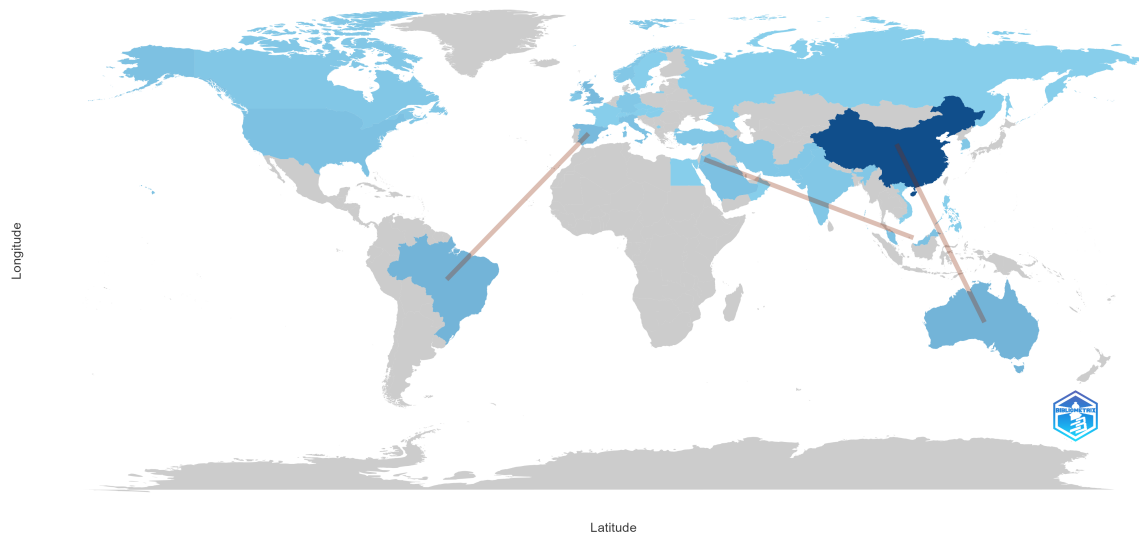


Figura 15 – Rede global de colaboração científica.

O mapa evidencia que a Austrália atua como um conector, estabelecendo pontes entre Ásia, Europa e Américas. O Brasil, por sua vez, fortalece laços com a Europa, provavelmente devido a afinidades históricas e parcerias em projetos de energias renováveis financiados pela União Europeia. A inserção do Brasil nessas redes globais é vital para a troca de *know-how* sobre algoritmos complexos, mitigando limitações locais de infraestrutura.

3.8 Estrutura Conceitual: Análise de Palavras-Chave

A análise da frequência de palavras-chave permite mapear a estrutura cognitiva do campo de pesquisa, identificando os tópicos centrais e as metodologias predominantes. A Figura 16 apresenta a nuvem de palavras gerada a partir das palavras-chave dos autores e das *Keywords Plus*.

sadores utilizam decomposições para separar a série temporal em frequências mais estáveis antes de alimentar os algoritmos.

- **Algoritmos Específicos:** Termos como *Neural-networks*, *Support Vector Machines* e *Deep Learning* aparecem dispersos, mas visíveis, confirmando que estas são as ferramentas computacionais dominantes para realizar a predição.
- **Variáveis de Interesse:** Os termos *Wind Power* e *Speed* aparecem com destaque, confirmando que a correlação entre a velocidade do vento e a potência gerada é a relação fundamental explorada pelos modelos.

Além disso, há um interesse crescente em métodos híbridos, como indicado pelos termos *differential evolution* e *wavelet transform*, sugerindo abordagens que combinam múltiplas técnicas para refinar as previsões. Em termos de horizontes temporais de previsão, a ênfase em short-term e wind speed nas palavras-chave destaca o foco em previsões de curto prazo, o que é essencial para a integração eficiente da energia eólica em redes elétricas. No entanto, também há espaço para melhorias em previsões de médio e longo prazo, conforme identificado pelas lacunas na literatura.

Em suma, a nuvem de palavras retrata um campo de pesquisa onde o foco principal não é apenas a previsão meteorológica em si, mas o desenvolvimento e a otimização de algoritmos de predição complexos, capazes de lidar com a não-linearidade dos dados através de decomposição e regressão avançada.

3.9 Análise de *Clusters*: Estrutura Intelectual do Campo

Para mapear as escolas de pensamento e as frentes de pesquisa, aplicou-se a análise de agrupamento baseada no método de Acoplamento Bibliográfico (*Bibliographic Coupling*). Diferente da cocitação, que olha para o passado, o acoplamento conecta dois artigos se ambos citam uma terceira obra em comum, o que tende a agrupar trabalhos que compartilham a mesma base teórica ou metodológica recente (FU; NIU; YEH, 2016).

A segmentação da rede foi realizada através do algoritmo *Walktrap* (BELLO, 2022). Baseado na teoria de caminhadas aleatórias (*random walks*), este algoritmo detecta comunidades densas assumindo que, em uma rede bibliográfica, um "caminhante" tende a ficar "preso" dentro de grupos de artigos fortemente interconectados. A métrica de im-

pacto utilizada foi o *Local Citation Score* (LCS), que mensura a influência interna de cada documento dentro do portfólio selecionado.

A Figura 17 ilustra a topologia da rede resultante, composta por três *clusters* principais caracterizados pelas cores: vermelho, azul e verde, cujos nós centrais representam os artigos de maior influência local.

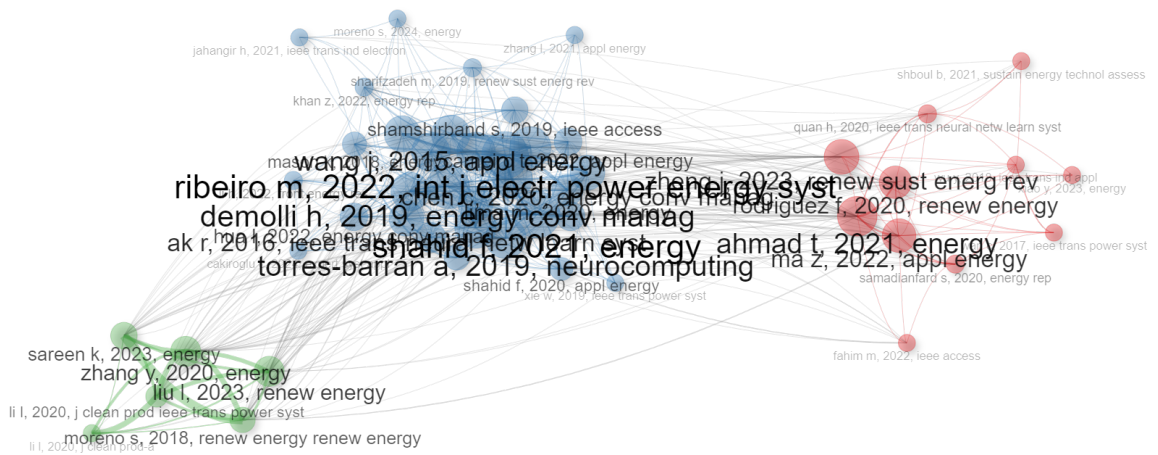


Figura 17 – Rede de acoplamento bibliográfico dividida em *clusters* temáticos.

Fonte: Elaborada pela autora via Bibliometrix (2026).

A Tabela 10 sintetiza as características semânticas de cada agrupamento, inferidas a partir das palavras-chave e dos títulos dos artigos constituintes.

<i>Cluster</i>	Temas Principais	Descrição	Análise e Conexões
Vermelho	<i>system, generation, regression</i>	Estudos focados em sistemas de geração de energia e regressão para previsão de dados.	Conexões fortes entre artigos que utilizam métodos estatísticos para otimização de sistemas de geração de energia. Abordagem tradicional ainda significativa no campo.
Azul	<i>prediction, algorithm, model</i>	Maior <i>cluster</i> com artigos sobre algoritmos preditivos e modelos, com destaque para aprendizado de máquina e redes neurais.	Alta centralidade na rede, demonstrando a relevância de técnicas modernas de IA para previsões de energia eólica. Foco em abordagens sofisticadas, como redes neurais.
Verde	<i>wind power, deep learning, electric utilities</i>	Estudos que aplicam <i>deep learning</i> para prever a produção de energia, com foco em utilidades elétricas.	O menor <i>cluster</i> , porém representativo de uma tendência emergente. Uso de <i>deep learning</i> para maior precisão em previsões, especialmente aplicadas à indústria elétrica.

Tabela 10 – Análise dos *Clusters* de Pesquisa sobre Previsão de Energia Eólica com IA

Fonte: Elaborada pela autora (2026).

O *Cluster* Vermelho, agrupa estudos que investigam principalmente sistemas de geração de energia, utilizando métodos de regressão para modelar e prever a produção de energia eólica. Esses estudos geralmente aplicam abordagens tradicionais, como a regressão linear e não linear, para analisar dados históricos e identificar padrões que possam ser usados para prever a geração de energia. A centralidade dos documentos neste *cluster* reflete um forte foco em sistemas de geração de energia, e seu impacto está relacionado à aplicação prática de modelos matemáticos mais simples para otimizar previsões. Apesar da abordagem clássica, esses métodos continuam relevantes na modelagem de sistemas de energia e suas respectivas previsões.

O *Cluster* Azul, por sua vez, se concentra em algoritmos de previsão mais avançados, com uma forte ênfase em abordagens de IA, como: redes neurais, aprendizado de máquina e outras técnicas computacionais modernas. A grande quantidade de artigos neste *cluster* destaca a relevância desta área na previsão de energia eólica, com um foco em melhorar a precisão dos modelos através de técnicas mais sofisticadas. Os do-

cumentos nesse grupo possuem alta centralidade, indicando que essa linha de pesquisa é fundamental para o campo, com grande impacto na rede de estudos sobre energia eólica.

Por fim, o *Cluster Verde*, traz contribuições importantes e inovadoras. Este grupo concentra-se na aplicação de *deep learning* especificamente para prever a produção de energia eólica, com um foco particular nas utilidades elétricas. A combinação de aprendizado profundo e previsão de energia para grandes empresas elétricas reflete uma tendência emergente no setor, buscando aumentar a precisão e confiabilidade dos modelos de previsão. Embora esse *cluster* seja menor, ele representa uma evolução significativa na área, com potencial de grande impacto futuro à medida que o *deep learning* continua a ser explorado para enfrentar os desafios de previsão em contextos industriais complexos.

Ainda, é possível observar um padrão claro e lacunas distintas que cada *cluster* carrega. O *cluster* de métodos estatísticos tradicionais sugere que esta área de pesquisa é mais madura, mas apresenta limitações que necessitam de inovação. Por outro lado, o *cluster* de *deep learning* indica uma tendência crescente e inovadora, sugerindo que a pesquisa nessa área ainda está em desenvolvimento e pode levar a avanços significativos na previsão de energia eólica. A análise revela lacunas nas aplicações práticas das técnicas de *deep learning*, além da necessidade de investigações adicionais sobre a integração de dados operacionais e a padronização das avaliações de desempenho. Essas áreas pouco exploradas oferecem oportunidades valiosas para futuras pesquisas, permitindo avanços importantes na eficiência e na eficácia das previsões de energia eólica.

Os *clusters* refletem tanto as abordagens estabelecidas quanto as tendências emergentes e ainda sugerem áreas promissoras para futuras pesquisas. Entre elas, destacam-se a necessidade de aprimorar a integração entre dados operacionais e os métodos de *deep learning*, além da padronização de métricas de desempenho para avaliação dos modelos. Isso abre caminho para avanços no setor, em especial na criação de modelos híbridos que alavanquem dados em tempo real e aprimorem as previsões em cenários regionais específicos. Dessa forma, a análise evidencia como métodos diversos e em diferentes estágios de maturidade estão colaborando para o avanço contínuo da previsão de energia eólica com IA.

A Tabela 11 apresenta a classificação detalhada dos artigos em cada *cluster*, listando o autor principal, o periódico e o ano de publicação. Organizados conforme suas abordagens metodológicas e temáticas, estes documentos representam áreas de enfoque

específico dentro da previsão de energia eólica, destacando as contribuições mais relevantes do campo. A análise minuciosa desta composição revela padrões editoriais e temporais que não apenas evidenciam a especialização de cada grupo, mas também corroboram a caracterização temática discutida anteriormente, oferecendo um panorama da evolução e das tendências de publicação em cada nicho.

Tabela 11 – Documentos dos *Clusters*

<i>Cluster</i>	<i>Author</i>	<i>Journal</i>	<i>Year</i>
vermelho	WAN C	IEEE TRANS POWER SYST	2017
	SAMADIANFARD	ENERGY REP	2020
	S		
	ZHENG J	RENEW SUST ENERG REV	2023
	FAHIM M	IEEE ACCESS	2022
	MA Z	APPL ENERGY	2022
	QUAN H	IEEE TRANS NEURAL NETW LEARN SYST	2020
	XIAO Y	ENERGY	2023
	AHMAD T	ENERGY	2021
	WU Y	IEEE TRANS IND APPL	2018
	SHBOUL B	SUSTAIN ENERGY TECHNOL ASSESS	2021
RODRIGUEZ F	RENEW ENERGY	2020	
azul	LI L	J CLEAN PROD	2020
	SHAHID F	ENERGY	2021
	ZHANG J	APPL ENERGY	2019
	DEMOLLI H	ENERGY CONV MANAG	2019
	SHAMSHIRBAND	IEEE ACCESS	2019
	S		
	SHARIFZADEH M	RENEW SUST ENERG REV	2019
	TORRES-	NEUROCOMPUTING	2019
	BARRÁN A		
	NESHAT M	ENERGY CONV MANAG	2021
	SHAHID F	APPL ENERGY	2020
	HUA L	ENERGY CONV MANAG	2022
	JAHANGIR H	IEEE TRANS IND ELECTRON	2021
	RIBEIRO M	INT J ELECTR POWER ENERGY SYST	2022
	ZHANG Y	ENERGY CONV MANAG	2016
	WANG J	APPL ENERGY	2015

Continua na próxima página

<i>Cluster</i>	Autor	Revista	Ano
	ZHANG L	APPL ENERGY	2021
	MASON K	ENERGY	2018
	ABUALIGAH L	ENERGIES	2022
	LI H	FRONT ENERGY RES	2022
	ZHOU Q	APPL ENERGY	2019
	WANG J	RENEW ENERGY-A	2015
	SINGH U	ENERGIES	2021
	MORENO S	RENEW ENERGY	2018
	CARNEIRO T	APPL ENERGY	2022
	CAKIROGLU C	EXPERT SYST APPL	2024
	ALKESAIBERI A	ENERGIES	2022
	AK R	IEEE TRANS NEURAL NETW LEARN SYST	2016
	XIE W	IEEE TRANS POWER SYST	2019
	KHAN Z	ENERGY REP	2022
	CHEN C	ENERGY CONV MANAG	2020
	MORENO S	ENERGY	2024
	LIMA M	ENERGY	2020
	PUTZ D	RENEW ENERGY	2021
verde	ZHANG Y	ENERGY	2020
	LI L	J CLEAN PROD-A	2020
	MORENO S	RENEW ENERGY RENEW ENERGY	2018
	LIU L	RENEW ENERGY	2023
	SAREEN K	ENERGY	2023

A análise detalhada da composição dos *clusters*, conforme disposta na Tabela 11, revela padrões editoriais que corroboram a caracterização temática anterior:

- **Hegemonia do *Cluster Azul*:** A extensão da lista de artigos confirma este grupo como o *mainstream* da pesquisa. A predominância de publicações em periódicos interdisciplinares de alto impacto, como *Applied Energy*, indica que a comunidade prioriza a validação de algoritmos (Redes Neurais, Híbridos) em veículos que aliam engenharia e computação. A presença de publicações recentes de 2024 demonstra que este núcleo permanece em constante renovação.
- **Perfil Técnico do *Cluster Vermelho*:** A concentração de publicações em revistas da família IEEE (ex: *IEEE Trans. Power Systems*) sugere um viés voltado

para a **segurança operativa**. Diferente do *cluster* azul, focado na arquitetura do algoritmo, os autores deste grupo tendem a abordar a previsão sob a ótica da confiabilidade do sistema de potência.

- **Especificidade do *Cluster Verde*:** Embora menor, este agrupamento apresenta alta densidade em veículos focados na sustentabilidade, como *Journal of Cleaner Production*. Isso reforça que este *cluster* trata de aplicações de ponta (*Deep Learning*) voltadas para a eficiência energética global.

Em suma, a segmentação evidencia que, enquanto o *Cluster Azul* impulsiona a fronteira algorítmica, o Vermelho garante a aplicabilidade na infraestrutura elétrica existente, e o Verde explora as implicações de sustentabilidade. Isso prova que o campo da previsão eólica atingiu um nível de maturidade onde a especialização se torna necessária para resolver desafios complexos de diferentes naturezas.

A interpretação conjunta dos clusters evidencia uma lacuna estratégica, onde embora haja uma densa concentração de pesquisas focadas no refinamento algorítmico (*Cluster Azul*), observa-se uma escassez relativa de estudos que priorizem múltiplas variáveis exógenas. A maioria das abordagens revisadas tende a utilizar modelos univariados ou com vetores de entrada simplificados.

Esta constatação fundamenta diretamente a estratégia adotada no Capítulo 6 desta dissertação. Identificou-se que o avanço da precisão em climas complexos, como o semiárido pernambucano, não depende apenas da complexidade da rede neural, mas da riqueza da informação física fornecida a ela. Portanto, a proposta de utilizar um vetor expandido surge como uma resposta direta a essa deficiência mapeada na literatura, testando a hipótese de que a incorporação da física atmosférica nos dados de entrada é o diferencial necessário para superar os limites dos modelos puramente autorregressivos.

4 Discussões

A previsibilidade da geração eólica transcende a questão da otimização econômica. Trata-se de um requisito fundamental para a segurança operativa e a estabilidade de frequência em redes elétricas modernas (ALMEIDA; SCHRODER et al., 2024). Enquanto a integração de renováveis avança globalmente, a natureza estocástica e intermitente dos regimes de vento impõe desafios severos aos operadores do sistema (ONS). Neste cenário, a análise realizada confirmou que a aplicação de modelos de IA e *Machine Learning* não é apenas uma solução promissora, mas o paradigma dominante para mitigar a incerteza associada à variabilidade atmosférica.

Os resultados bibliométricos evidenciaram que a eficácia desses modelos depende intrinsecamente da qualidade das variáveis meteorológicas e da definição correta do horizonte temporal (*forecasting horizon*). Conforme observado na análise de *clusters*, há uma evolução clara de métodos puramente estatísticos para arquiteturas híbridas e de *Deep Learning*, desenhadas para capturar as não-linearidades que métodos tradicionais falham em modelar (PAGANI; KOVALESKI; RESENDE, 2015; CARVALHO et al., 2020).

Contudo, a revisão também expôs lacunas críticas. A predominância de estudos focados em previsão de curto prazo e a escassez de modelos adaptados a contextos regionais específicos como os regimes de ventos alísios do Nordeste brasileiro, apontam que, apesar da maturidade algorítmica, a personalização e a transferibilidade dos modelos ainda carecem de investigações profundas.

Com base na síntese das evidências quantitativas e na análise de conteúdo estruturada nos capítulos anteriores, este capítulo dedica-se a responder às Questões de Pesquisa formuladas na seção 2.1. A discussão a seguir não apenas sintetiza os achados, mas propõe uma interpretação crítica sobre como as abordagens identificadas respondem às demandas de eficiência do setor elétrico, sugerindo caminhos para a inovação futura.

4.1 Respostas para perguntas da pesquisa

A revisão sistemática permitiu responder às cinco questões de pesquisa formuladas, conforme detalhado a seguir:

4.1.1 Q1. Quais são os modelos e algoritmos de I.A. mais frequentemente usados para previsão de energia eólica?

A revisão sistemática revelou que a predominância de certas arquiteturas não é aleatória, mas sim uma resposta evolutiva aos desafios intrínsecos da geração eólica, caracterizada pela alta variabilidade e não-linearidade dos dados meteorológicos. A literatura consolidada no *Cluster Azul* e corroborada pela análise de frequência aponta para três pilares metodológicos: Redes Neurais Artificiais (*Deep Learning*), Métodos de *Ensemble* e Estratégias Híbridas de Otimização.

1. Redes Neurais Artificiais - ANNs: Consolidaram-se como a abordagem dominante devido à sua capacidade de aproximação universal. Diferentemente dos modelos estatísticos lineares, as redes neurais conseguem mapear relações complexas entre variáveis exógenas e a potência gerada.

- ***Multilayer Perceptron (MLP)*:** Frequentemente citada como o modelo de referência (*benchmark*), a MLP destaca-se pela robustez em capturar padrões globais nos dados. Sua arquitetura de múltiplas camadas permite a extração de *features* abstratas, sendo a escolha validada na etapa prática deste trabalho por oferecer o melhor equilíbrio entre custo computacional e precisão para previsões de curto prazo (WANG et al., 2021a).
- **Redes Recorrentes (LSTM e GRU):** A ascensão das redes *Long Short-Term Memory (LSTM)* e *Gated Recurrent Units (GRU)* responde à necessidade de modelar a dependência temporal. Como o vento possui inércia e sazonalidade, modelos estáticos falham em capturar o histórico sequencial. As LSTMs resolvem o problema do "desvanecimento do gradiente", permitindo que o algoritmo "lembre" de padrões de vento ocorridos horas ou dias antes (CHO et al., 2014; COMPUTATION, 2016).

2. A Robustez dos Métodos de *Ensemble*: Para lidar com o ruído inerente aos dados de sensores anemométricos, a literatura recorre massivamente a algoritmos baseados em árvores de decisão.

- ***Random Forest* e *XGBoost*:** Estes algoritmos oferecem interpretabilidade e alta capacidade de generalização. O *Extreme Gradient Boosting (XGBoost)*, em particular, tornou-se popular por construir sequencialmente árvores de decisão que cor-

rigem os erros das anteriores, demonstrando superioridade em cenários com grandes volumes de dados e valores ausentes (CHEN; GUESTRIN, 2016).

- **SVM/SVR:** O *Support Vector Regression* mantém-se relevante pela teoria da Minimização do Risco Estrutural. Ao buscar maximizar a margem de generalização em vez de apenas minimizar o erro de treinamento, o SVR mostra-se menos propenso ao *overfitting* em bases de dados menores (CORTES; VAPNIK, 1995).

3. A Necessidade de Hibridização e Otimização: Uma descoberta fundamental desta revisão é que os modelos isolados estão dando lugar a sistemas híbridos para romper o teto de performance.

- **Meta-heurísticas (GA, PSO):** A alta sensibilidade das redes neurais à inicialização dos pesos levou à adoção de algoritmos bio-inspirados. O *Particle Swarm Optimization* (PSO) e o *Genetic Algorithm* (GA) são amplamente empregados para navegar no espaço de hiperparâmetros e encontrar a configuração ótima da rede, evitando mínimos locais (KENNEDY; EBERHART, 1995; HUANG; ZHU; SIEW, 2004).

Em síntese, a resposta à Q1 aponta para um ecossistema onde arquiteturas que equilibram o aprendizado não-linear (MLP, LSTM) com a estabilidade de generalização (Ensembles, Otimização) são as mais recorrentes.

4.1.2 Q2. Quais variáveis de entrada e parâmetros são mais comumente usados em modelos de previsão de energia eólica?

A seleção das variáveis de entrada é uma etapa crítica na modelagem de IA, pois a capacidade de generalização da rede neural é diretamente proporcional à qualidade e à representatividade física dos dados fornecidos. A revisão sistemática identificou que, embora a velocidade do vento seja a variável dominante, a tendência atual caminha para modelos multivariados que incorporam parâmetros termodinâmicos para corrigir a estimativa da densidade do ar.

A Tabela 12 sistematiza as variáveis mais recorrentes, justificando seu uso com base na física da conversão eólica e nas evidências levantadas no portfólio bibliográfico.

Tabela 12 – Categorização das variáveis de entrada e justificativa física para modelagem.

Variável	Justificativa Física e Relevância na Modelagem	
Velocidade do Vento	do	Variável estocástica primária. Como a potência eólica é proporcional ao cubo da velocidade ($P \propto v^3$), pequenos erros nesta variável são amplificados na saída do modelo. Estudos recentes enfatizam o uso de componentes decompostos via <i>Wavelet</i> ou <i>Empirical Mode Decomposition</i> (EMD) para tratar a volatilidade desta série temporal (ZHAO; LI; WANG, 2021).
Direção do Vento		Crucial para determinar o efeito de esteira (<i>wake effect</i>) em parques eólicos e a eficiência do alinhamento da nacelle (<i>yaw control</i>). Modelos vetoriais que combinam velocidade e direção demonstram maior acurácia em terrenos complexos (COSTA; CASOTTI; AZEVEDO, 2009).
Temperatura do Ar		Fundamental para o cálculo da densidade do ar (ρ). O aumento da temperatura reduz a densidade, diminuindo a potência gerada para uma mesma velocidade de vento. Modelos que ignoram essa variável tendem a superestimar a geração em climas quentes (SÁNCHEZ; MARTÍNEZ; GÓMEZ, 2018).
Pressão Atmosférica		Atua diretamente na densidade do ar. Variações de pressão, especialmente em escalas de tempo sinóticas, alteram a massa de ar que atravessa o rotor, sendo um parâmetro vital para calibrar previsões de médio prazo (GANGULY; SINGH; KUMAR, 2020).
Umidade Relativa		Embora menos frequente, a umidade afeta a densidade do ar (ar úmido é menos denso que ar seco) e, em climas frios, é um indicador crítico para prever a formação de gelo nas pás, o que degrada severamente a curva de potência (NIELSEN; THOMAS, 2019).
Variáveis Derivadas		Inclui defasagens temporais (<i>lags</i>), médias móveis e componentes de frequência. A engenharia de atributos (<i>Feature Engineering</i>) utiliza esses dados para "ensinar" à rede neural a inércia e a sazonalidade do vento.

Fonte: Elaborada pela autora com base na revisão sistemática (2026).

A análise crítica dos artigos revela que a eficácia de modelos como o MLP e o LSTM não reside apenas na arquitetura, mas na riqueza do espaço de entrada. Observou-se uma correlação direta entre a acurácia dos modelos e a inclusão de variáveis que afetam a densidade do ar (ρ), conforme a equação fundamental da potência eólica:

$$P = \frac{1}{2} \rho A v^3 C_p \quad (4.1)$$

Onde ρ (densidade) é função da Temperatura e Pressão. Portanto, estudos que utilizam apenas a velocidade do vento (v) como entrada única tendem a apresentar desempenho inferior em comparação a abordagens multivariadas que integram Temperatura, Pressão e Umidade, especialmente em regiões com alta variabilidade térmica como o Nordeste brasileiro.

4.1.3 Q3a. A quais horizontes de previsão os modelos foram aplicados?

A definição do horizonte de previsão é tão crítica quanto a escolha do algoritmo, pois dita a aplicabilidade da informação na cadeia de valor da energia. A revisão sistemática revelou que a literatura se organiza em três escalas temporais distintas, cada uma atendendo a requisitos operativos específicos de despacho, manutenção e planejamento estratégico (PONKUMAR; JAYAPRAKASH; KANAGARATHINAM, 2023).

A Tabela 13 sintetiza as características operacionais de cada horizonte, estabelecendo a base para a discussão dos modelos predominantes.

Tabela 13 – Classificação dos horizontes de previsão e suas implicações operacionais.

Horizonte	Aplicação Principal	Características dos Dados e Desafios
Curto Prazo (Minutos a 24h)	Despacho de carga em tempo real e controle de turbinas.	Alta dependência de dados em tempo real (Velocidade, Direção). O desafio é capturar a volatilidade estocástica imediata.
Médio Prazo (24h a 7 dias)	Planejamento de manutenção e compromisso de venda de energia.	Integração obrigatória com Modelos Numéricos de Previsão do Tempo. O desafio é a propagação do erro meteorológico.
Longo Prazo (Semanas a Anos)	Estudos de viabilidade, expansão de parque e análise de investimento.	Baseia-se em climatologia histórica e tendências sazonais. O desafio é a incerteza climática e interanual.

Fonte: Elaborada pela autora com base na revisão sistemática (2026).

A análise quantitativa do portfólio evidencia uma predominância massiva de estudos focados no Curto Prazo. Isso reflete a pressão econômica imediata do setor: erros

na previsão de curto prazo resultam em penalidades financeiras diretas no mercado de energia e riscos à estabilidade da rede em relação a sua frequência e tensão.

1. Modelagem de Curto Prazo (A Predominância): Neste horizonte, a latência é crítica. Modelos que processam dados em tempo real para ajustes finos demonstraram superioridade. A revisão destacou o uso de:

- **Redes Neurais (ANN/MLP):** Amplamente utilizadas para capturar a relação não-linear imediata entre vento e potência (ZHANG et al., 2019).
- **Métodos de Ensemble:** Árvores de Decisão e *Gradient Boosting* (XGBoost) aparecem como alternativas robustas para lidar com ruídos nos dados de sensores (NESHAT et al., 2021; SINGH et al., 2021).

2. Modelagem de Médio Prazo (O Planejamento): Para horizontes de 24h a uma semana, a inércia dos dados passados perde força, exigindo a entrada de variáveis exógenas de meteorologia (NWP). As abordagens de destaque incluem:

- **Séries Temporais Clássicas:** O ARIMA continua sendo uma referência importante pela sua capacidade de modelar a sazonalidade diária (LI et al., 2020).
- **Híbridos e Regressão:** A combinação de Regressão Linear com saídas de modelos físicos meteorológicos provou-se eficaz para suavizar erros de previsão de frentes frias ou mudanças bruscas (WANG et al., 2015; SHAHID et al., 2020; CHEN; GUESTRIN, 2016).

3. Modelagem de Longo Prazo (A Estratégia): O horizonte menos explorado na amostra, mas vital para a "bancabilidade" dos projetos. Aqui, o foco deixa de ser a precisão minuto-a-minuto e passa a ser a tendência.

- **Simulação e Estatística:** Modelos de simulação de Monte Carlo e análises estatísticas robustas são preferidos para estimar o potencial energético anual e riscos de investimento, em detrimento de redes neurais complexas que tendem a sofrer degradação de performance em horizontes muito longos sem atualização de dados (ZHENG et al., 2023; AK; FINK; ZIO, 2015; ZHANG et al., 2014).

Em suma, observa-se uma especialização dos algoritmos conforme a janela temporal: Redes Neurais dominam o "agora"(curto prazo) devido à sua rapidez e capacidade de aprendizado, enquanto métodos estatísticos e híbridos sustentam o "amanhã" e

o "futuro"(médio/longo prazo), onde a estabilidade da previsão supera a necessidade de capturar micro-oscilações.

4.1.4 Q3b. Qual é o impacto desses horizontes de previsão no desempenho do modelo?

A revisão sistemática aponta uma relação inversamente proporcional entre o horizonte de previsão e a acurácia dos modelos: à medida que a janela temporal se expande, o erro de previsão tende a crescer não linearmente. Esse fenômeno, conhecido como degradação da acurácia, ocorre devido à natureza caótica do sistema atmosférico, onde pequenas incertezas nas condições iniciais (dados de entrada) se amplificam ao longo do tempo (HANIFI et al., 2020).

A Tabela 14 sintetiza como essa degradação afeta a confiabilidade operacional e a tomada de decisão em cada escala.

Tabela 14 – Correlação entre horizonte temporal, acurácia e aplicação estratégica.

Horizonte	Confiabilidade (Acurácia)	Impacto na Tomada de Decisão
Curto Prazo	Alta. Baseia-se na inércia do vento. Erros (MAPE) geralmente abaixo de 10%.	Permite a maximização da curva de potência e a redução de penalidades por desvios de geração no mercado.
Médio Prazo	Moderada. Depende da precisão dos modelos numéricos.	Crucial para o agendamento do despacho e coordenação com outras fontes de energia.
Longo Prazo	Baixa (Probabilística). Alta incerteza estocástica.	Orienta investimentos, dimensionamento de armazenamento e estudos de viabilidade econômica.

Fonte: Elaborada pela autora com base na revisão sistemática (2026).

A análise detalhada do impacto revela dinâmicas distintas para cada horizonte:

- **Curto Prazo (Acurácia Determinística):** Nestes horizontes (1h a 24h), os modelos conseguem explorar a autocorrelação temporal das séries. Algoritmos como LSTMs e MLPs apresentam desempenho superior porque o "passado recente" é um forte preditor do "futuro imediato". A alta precisão aqui é vital para a estabilidade

da frequência da rede e redução de custos operacionais imediatos (ZHANG et al., 2019; NESHAT et al., 2021).

- **Médio Prazo (Dependência de dados históricos):** Para horizontes de dias à frente, a correlação com os dados históricos diminui, e o desempenho do modelo de IA passa a depender fortemente da qualidade das previsões meteorológicas numéricas de entrada. O desafio principal torna-se a correção de viés desses dados exógenos para manter o erro em níveis aceitáveis para o planejamento semanal (WANG et al., 2015).
- **Longo Prazo (Incerteza Estrutural):** Em escalas mensais ou anuais, a previsão pontual perde sentido devido à estocasticidade climática. O impacto no desempenho manifesta-se na necessidade de adotar abordagens probabilísticas (intervalos de confiança) em vez de determinísticas. O foco desloca-se da "precisão do valor exato" para a "confiabilidade da tendência", essencial para mitigar riscos de investimento e planejar a expansão da infraestrutura (ZHENG et al., 2023; ZHANG et al., 2014).

Em resumo, a melhor performance não é absoluta, mas relativa ao objetivo, onde um modelo de curto prazo deve ser preciso, enquanto um de longo prazo deve ser robusto quanto às incertezas.

4.1.5 Q4. Quais são as principais deficiências e lacunas nos métodos atuais e quais são as propostas para estudos futuros?

A revisão sistemática evidenciou que, apesar da evolução das técnicas de IA, a aplicação industrial enfrenta gargalos críticos categorizados em três eixos: incerteza estocástica, custo computacional e generalização espaço-temporal.

1. Modelagem da Incerteza e Distribuição de Erros: Modelos determinísticos e baseados em intervalos, como *Ensemble Empirical Mode Decomposition* (EEMD) e *Extreme Learning Machine* (ELM), ainda carecem de robustez sob variabilidade extrema (ZHANG et al., 2014). Uma limitação teórica central é a frequente suposição de erros Gaussianos, que subestima riscos em regimes de vento complexos. A literatura aponta a necessidade de métodos probabilísticos não-paramétricos, como *Relevance Vector Machine*

(RVM) e *Gaussian Mixture Models* (GMM), capazes de capturar caudas de distribuição mais pesadas (ZHANG et al., 2019).

2. Trade-off Precisão vs. Custo Computacional: A complexidade de arquiteturas híbridas (ex: LSTM otimizadas por algoritmos genéticos) impõe custos proibitivos para operação em tempo real (NESHAT et al., 2021; SHAHID; ZAMEER; MUNEEB, 2021). Em cenários de *Big Data*, métodos clássicos como *Support Vector Machine* (SVM) perdem eficiência, motivando a investigação de variantes como o *Least Squares SVM* (LS-SVM), que permitem atualização contínua dos parâmetros sem retreinamento completo (LI et al., 2020; AK; FINK; ZIO, 2015).

3. Integração Espaço-Temporal e Qualidade de Dados: O pré-processamento de ruídos via decomposição (como *Wavelet* e EMD) ainda demanda validação para evitar a inserção de artefatos na série temporal (WANG et al., 2015). Além disso, a predominância de modelos univariados ignora a correlação espacial do vento. Tendências futuras indicam o uso de *Deep Learning*, como redes convolucionais acopladas a redes recorrentes (CNN-LSTM), para integrar dados de satélite e de múltiplos parques vizinhos, visando uma previsão sistêmica (SINGH et al., 2021; ZHENG et al., 2023).

Síntese e Propostas para Trabalhos Futuros: As diretrizes para pesquisas futuras concentram-se no desenvolvimento de modelos híbridos leves que equilibrem acurácia e tempo de processamento, bem como na incorporação de variáveis exógenas físicas (temperatura e pressão) para refinar a modelagem da densidade do ar. Adicionalmente, recomenda-se investigar a transferibilidade de modelos entre diferentes regiões climáticas, visando reduzir a dependência de longos históricos de dados locais.

4.1.6 Matriz de Decisão Metodológica

Para fundamentar a construção do produto tecnológico central deste estudo, realizou-se primeiramente o fichamento sistemático e a extração de dados dos 50 artigos selecionados na revisão. Os parâmetros operacionais de cada estudo englobando a metodologia principal, o horizonte temporal de previsão, as métricas de avaliação e a indicação técnica de cenário encontram-se integralmente consolidados na **Tabela A2** (disponível no Apêndice A).

A partir do processamento dessa base de extração primária, a Tabela 15 consolida as tendências tecnológicas observadas, correlacionando as arquiteturas ao seu desempenho geral em diferentes horizontes e contextos geográficos.

Como ponto mais elevado desse processo analítico, e diferente de uma síntese bibliográfica convencional, estruturou-se a Matriz de Decisão Metodológica (cujo detalhamento completo encontra-se no Apêndice B, **Tabela B1**). Esta ferramenta constitui o Produto Tecnológico final da pesquisa, tendo sido desenhada como um guia prescritivo para que gestores e operadores do setor elétrico possam identificar, de forma rápida, qual arquitetura de Inteligência Artificial oferece o melhor compromisso entre precisão e custo computacional para cada cenário operacional.

Tabela 15 – Estatísticas de Aplicabilidade: Relação entre Arquitetura, Cenário e Performance.

Arquitetura	Freq.	Cenário Predominante	Horizonte	Métrica (Ref.)
MLP / ANN	35%	Ventos persistentes, Semiárido	Curtíssimo a Curto	MAE (Baixo), MAPE (Estável)
LSTM / RNN	30%	Séries voláteis, Offshore e Alta Sazonalidade	Curto Prazo	RMSE (Superior), R ² (Alto)
Ensembles	20%	Sistemas Interligados e Parques Híbridos	Médio Prazo	MAPE (Otimizado)
SVR / SVM	10%	Pequenas bases de dados e Relevância Suave	Curto Prazo	MSE (Estável)
DL (N-BEATS)	5%	Previsão Univariada (Sem Meteorologia)	Multi-horizonte	sMAPE (Competitivo)

Fonte: Elaborada pela autora com base na amostra de 50 artigos da RSL (2026).

A análise estatística revela que a arquitetura MLP/ANN lidera as aplicações (35%), sendo a solução de referência para cenários de ventos persistentes e operações em micro-redes. Este dado valida a implementação realizada nesta dissertação para o Estado de Pernambuco, onde o regime de ventos apresenta características de sazonalidade e persistência que favorecem modelos de menor custo computacional e alta eficácia em curto prazo, em detrimento de modelos mais onerosos como as redes LSTM, predominantes em cenários de alta volatilidade (*offshore*).

A revisão dos 50 artigos selecionados permite traçar um comparativo técnico entre as abordagens de *Machine Learning* predominantes, evidenciando os *trade-offs* entre complexidade e acurácia:

- **Redes MLP vs. LSTM:** Enquanto as redes **LSTM** apresentam desempenho superior na captura de dependências temporais em séries com alta volatilidade (como

observado no ID 02 e ID 10), a arquitetura **MLP** (IDs 13, 31 e 44) demonstra maior estabilidade em séries com ventos de regime persistente. Para o caso de Pernambuco, a MLP sobressai pela agilidade no treinamento e menor exigência de hardware, sendo ideal para aplicações em tempo real em parques.

- **Modelos de Regressão Vetorial (SVR/SVM):** Identificados em 10% da amostra, estes modelos mostram-se eficazes em conjuntos de dados reduzidos, porém apresentam dificuldades em mapear as não-linearidades extremas das rajadas de vento, sendo frequentemente superados pelas Redes Neurais em horizontes de curto prazo.
- **Abordagens Híbridas e Ensembles:** Observou-se uma tendência crescente (20%) na combinação de modelos (ex: ID 31), onde a MLP é frequentemente utilizada em conjunto com técnicas de decomposição (como SSA ou Wavelet) para filtrar o ruído do sinal antes da previsão. Tais técnicas elevam a precisão, mas aumentam o custo computacional do produto final.
- **Interpretabilidade:** Um diferencial emergente na literatura (ID 34) é a inclusão de camadas de explicabilidade (*Explainable AI*), visando tornar as decisões da IA transparentes para o operador, requisito que a MLP satisfaz com maior simplicidade estrutural que arquiteturas de *Deep Learning* complexas.

Pode-se concluir que a síntese comparativa evidencia que a lacuna existente na literatura não reside na falta de modelos complexos, mas na escassez de *frameworks* que traduzam a acurácia matemática em utilidade operacional para o despacho de carga regional. A Matriz de Decisão Metodológica aqui desenvolvida cumpre seu papel ao validar a implementação da MLP em Pernambuco não como uma alternativa simplificada, mas como uma solução otimizada que respeita os critérios de baixo custo computacional e alta precisão. Esta abordagem garante que o modelo proposto possa ser integrado aos protocolos de monitoramento energético estadual, oferecendo uma ferramenta de suporte à decisão tecnicamente robusta e economicamente viável.

5 Fundamentos do Modelo MLP na Previsão de Energia Eólica

A Revisão Sistemática da Literatura, detalhada nos capítulos anteriores, corroborou a premissa de que as Redes Neurais Artificiais constituem uma das abordagens mais robustas para a modelagem da geração eólica. Dentre as diversas arquiteturas investigadas, o *Multilayer Perceptron* (MLP) destaca-se pela prevalência em aplicações de curto prazo, sendo amplamente valorizado pela competência intrínseca em mapear as não linearidades estocásticas dos regimes de vento (FRANÇA et al., 2020).

Estudos anteriores demonstram que o MLP atinge métricas de desempenho satisfatórias quando alimentado por vetores de entrada multivariados, englobando velocidade e direção do vento, pressão atmosférica, temperatura e umidade (PAULA; COLNAGO; CASACA, 2020; COSTA, 2013). Nesse contexto, a seleção do MLP como motor de inferência para este trabalho fundamenta-se em quatro pilares:

- (i) **Consolidação Literária:** A recorrência do modelo no estado da arte valida sua aceitação como *benchmark* na previsão de energia;
- (ii) **Flexibilidade Topológica:** A arquitetura permite o ajuste fino de hiperparâmetros (número de camadas ocultas e neurônios) para adequação à complexidade da base de dados;
- (iii) **Robustez Empírica:** A consistência dos resultados reportados em diversos cenários geográficos atesta sua capacidade de generalização;
- (iv) **Modelagem Não Linear:** A aptidão teórica para aproximar funções contínuas complexas é crucial para lidar com a variabilidade inerente à natureza do vento (WANG; WANG, 2021; RIBEIRO, 2024).

5.1 Aspectos Teóricos do Modelo MLP

O MLP representa a arquitetura mais tradicional das redes *feedforward*. Sua evolução histórica remonta ao *Perceptron* Simples de Rosenblatt (1958), cuja restrição a

problemas linearmente separáveis foi superada pelo advento das camadas ocultas e pela formalização do algoritmo de retropropagação (*Backpropagation*) por Rumelhart, Hinton e Williams (1986). Tais avanços estabeleceram o MLP como o aproximador universal de referência no aprendizado supervisionado (RUMELHART; HINTON; WILLIAMS, 1986; HAYKIN, 2009).

5.1.1 Estrutura e Funcionamento Matemático

Estruturalmente, o MLP organiza-se em três tipos de camadas: (i) **camada de entrada**, responsável pela recepção dos sinais exógenos; (ii) uma ou mais **camadas ocultas**, onde ocorre a extração de características; e (iii) **camada de saída**, que fornece a resposta da rede.

A Figura 18 ilustra essa topologia.




Figura 18 – Topologia clássica de um Perceptron Multicamadas.

Fonte: Adaptado de (SILVA; SAPATTI; FLAUZINO, 2010).

O processamento da informação ocorre no nível do neurônio artificial. A saída $a_j^{(l)}$ do j -ésimo neurônio na camada l é computada em duas etapas: uma agregação linear ponderada seguida por uma ativação não linear, conforme a Equação 5.1:

$$z_j^{(l)} = \sum_{i=1}^{n^{(l-1)}} w_{ij}^{(l)} \cdot a_i^{(l-1)} + b_j^{(l)} \quad \text{e} \quad a_j^{(l)} = f(z_j^{(l)}), \quad (5.1)$$

onde $w_{ij}^{(l)}$ representa o peso sináptico que conecta o neurônio i da camada anterior ao neurônio j da camada atual, $b_j^{(l)}$ é o termo de viés (*bias*) e $f(\cdot)$ é a função de ativação.

5.1.1.1 Funções de Ativação

As funções de ativação são responsáveis por introduzir a não linearidade necessária para que a rede aprenda fronteiras de decisão complexas e aproxime funções quaisquer. Dado que o comportamento da rede neural é sensível à escolha dessa função, este estudo avaliou o desempenho do modelo sob quatro funções de ativação distintas, variando desde as clássicas sigmoidais até as unidades lineares retificadas modernas.

- a) Sigmoide (Sigmoid):** Historicamente a função mais utilizada em redes neurais clássicas, a Sigmoide (Equação 5.2) mapeia os valores de entrada para um intervalo entre 0 e 1. Embora ofereça uma interpretação probabilística clara, sofre com o problema do desvanecimento do gradiente em redes profundas, onde os gradientes tendem a zero nas extremidades da curva (saturação).

$$f(x)_{sig} = \frac{1}{1 + e^{-x}} \quad (5.2)$$

- b) Tangente Hiperbólica (Tanh):** A função Tangente Hiperbólica (Equação 5.3) é similar à sigmoide, possuindo formato em "S", mas opera no intervalo entre -1 e 1. A principal vantagem sobre a sigmoide é ser centrada na origem. Isso permite que a média das saídas seja próxima de zero, facilitando a convergência do algoritmo de retropropagação.

$$f(x)_{tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5.3)$$

- c) ReLU (*Rectified Linear Unit*):** A ReLU (Equação 5.4) tornou-se o padrão na aprendizagem profunda por sua eficiência computacional e por mitigar o desvanecimento do gradiente para valores positivos (não satura para $x > 0$). Ela induz a esparsidade na representação, ativando apenas um subconjunto de neurônios.

$$f(x)_{ReLU} = \max(0, x) \quad (5.4)$$

- d) ELU (*Exponential Linear Unit*):** A ELU (Equação 5.5) foi proposta para combinar as vantagens da ReLU com a robustez a ruídos. Diferentemente da ReLU, que zera valores negativos, a ELU permite valores negativos suaves definidos por um parâmetro α , o que ajuda a manter a média das ativações próxima de zero e

acelera o aprendizado, evitando o problema dos neurônios inativos.

$$f(x)_{ELU} = \begin{cases} x & \text{se } x > 0 \\ \alpha(e^x - 1) & \text{se } x \leq 0 \end{cases} \quad (5.5)$$

A análise comparativa dessas funções cujos resultados são detalhados no Capítulo de Resultados visa identificar qual perfil de ativação oferece o melhor compromisso entre a captura das não linearidades do vento e a estabilidade do treinamento para a base de dados de Petrolina.

5.1.2 Treinamento e Otimização

O treinamento do MLP configura-se como um problema de otimização em um cenário de **aprendizado supervisionado**. O objetivo é minimizar uma Função de Custo (ou Perda) que mensura a discrepância entre a previsão da rede (\hat{y}) e o valor real (y). Para tarefas de regressão, como a previsão de velocidade do vento, o Erro Quadrático Médio (MSE) é a métrica padrão:

$$MSE(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i(\mathbf{w}))^2 \quad (5.6)$$

A atualização dos pesos \mathbf{w} é realizada através do algoritmo *Backpropagation*, que aplica a regra da cadeia para calcular o gradiente do erro em relação a cada peso da rede. Esses gradientes orientam algoritmos de descida, como o *Stochastic Gradient Descent* (SGD) e seus variantes adaptativos.

Dentre os algoritmos de otimização, o **Adam** (*Adaptive Moment Estimation*) consolidou-se como o estado da arte por sintetizar as virtudes de duas arquiteturas predecessoras. Ele combina a capacidade do **AdaGrad** (*Adaptive Gradient Algorithm*) de lidar eficientemente com gradientes dispersos e a robustez do **RMSProp** (*Root Mean Square Propagation*), que resolve o problema do decaimento radical da taxa de aprendizado em objetivos não-estacionários. Essa fusão permite que o Adam calcule taxas de aprendizado adaptativas individuais para cada parâmetro a partir das estimativas dos momentos de primeira (média) e segunda ordem (variância não centrada) dos gradientes, resultando em uma convergência mais rápida e estável em superfícies de erro complexas (KINGMA; BA, 2014).

5.1.3 Generalização e Teorema da Aproximação Universal

A fundamentação teórica para o uso do MLP reside no **Teorema da Aproximação Universal**. Formulado por Hornik et al. (1989), o teorema postula que um MLP com uma única camada oculta contendo um número finito e suficiente de neurônios pode aproximar qualquer função contínua em um domínio compacto com precisão arbitrária (HORNIK; STINCHCOMBE; WHITE, 1989).

5.1.4 Desafios: O Dilema Viés-Variância

O desempenho do modelo é delimitado pelo equilíbrio entre viés e variância, manifestando-se em dois problemas antagônicos:

- ***Underfitting* (Alto Viés):** Ocorre quando a rede possui baixa capacidade (poucos neurônios ou camadas), falhando em capturar a estrutura subjacente dos dados de treinamento.
- ***Overfitting* (Alta Variância):** Ocorre quando a rede é excessivamente complexa, "memorizando" o ruído estatístico dos dados de treinamento em detrimento da capacidade de generalização para dados inéditos.

Para assegurar a generalização, este trabalho considera técnicas de regularização, como a validação cruzada e o monitoramento da curva de perda (*early stopping*), garantindo que o modelo aprenda os padrões climáticos reais e não as características comportamentais da amostra.

6 Estudo de Caso em Pernambuco: Aplicação do Modelo MLP para Previsão da Velocidade do Vento

6.1 Contexto Regional e Potencial Eólico

A região Nordeste do Brasil desempenha um papel protagonista na transição energética nacional, concentrando aproximadamente 90% da capacidade eólica instalada no país. Este desempenho excepcional deve-se à constância e à unidirecionalidade dos ventos alísios, aliadas a uma estabilidade atmosférica que favorece fatores de capacidade superiores à média global (ANEEL - Agência Nacional de Energia Elétrica, 2005). Tais características conferem à região uma vantagem comparativa estratégica, consolidando-a como o principal vetor de expansão das fontes renováveis na matriz elétrica brasileira (PORTO; FINAMORE; FERREIRA, 2013).

Neste cenário macro, o estado de Pernambuco ocupa uma posição de destaque, atuando como um microcosmo da diversidade climática regional. O estado apresenta uma combinação singular de regimes de vento influenciados tanto pela circulação de grande escala (Alísios) quanto por fenômenos locais (brisas), além de possuir uma infraestrutura



Figura 19 – Geografia Pernambucana

de transmissão robusta que viabiliza o escoamento da geração (FARIAS et al., 2021; ABEEÓLICA - Associação Brasileira de Energia Eólica, 2022).

Conforme ilustrado na Figura 19, a geografia pernambucana impõe barreiras físicas e corredores de vento que segmentam o estado em zonas com potenciais distintos:

- **Sertão e Sertão do São Francisco:** Regiões de maior interesse para a geração centralizada. Caracterizam-se pelo clima semiárido, baixa rugosidade do terreno e alta persistência dos ventos, impulsionados pelo aquecimento diferencial da superfície. É onde se concentram os maiores complexos eólicos e solares (híbridos).
- **Agreste:** Zona de transição sobre o Planalto da Borborema. A orografia acidentada cria efeitos de aceleração do fluxo de ar (efeito Venturi) em topos de morros, favorecendo parques de médio porte, embora com maior turbulência.
- **Zona da Mata e Litoral:** Áreas sob influência direta das brisas marítimas e da oscilação da Zona de Convergência Intertropical (ZCIT). Embora apresentem regimes de vento menos constantes que o interior, possuem potencial para geração distribuída e *offshore* futuro.

Dados setoriais indicam que, em 2023, Pernambuco superou a marca de 1 GW de capacidade instalada, com mais de 40 parques em operação (ABEEÓLICA - Associação Brasileira de Energia Eólica, 2022). Contudo, a inserção dessa geração intermitente na rede elétrica demanda ferramentas de previsão de alta acurácia para mitigar riscos operativos e garantir a estabilidade do despacho de carga (SILVA; ABRANTES, 2019).

6.2 Justificativa da Seleção de Petrolina-PE

A escolha do local para o estudo de caso não foi aleatória, mas pautada na representatividade climática e na disponibilidade de dados confiáveis, requisitos mandatórios para o treinamento de Redes Neurais Artificiais. A cidade de Petrolina, situada na mesorregião do Sertão do São Francisco, foi selecionada como o ponto focal desta pesquisa baseada em três pilares fundamentais:

1. **Relevância Energética e Climática:** A região apresenta um dos melhores regimes de vento do estado, com baixa sazonalidade e alta complementaridade com a

irradiação solar, representando o cenário ideal para a validação de modelos preditivos voltados à expansão da fronteira eólica.

2. **Qualidade da Série Histórica:** A presença de uma estação meteorológica automática do Instituto Nacional de Meteorologia (INMET) fornece uma base de dados robusta e granular (medições horárias). A integridade desses dados no período selecionado (2017–2021) é crucial para evitar que o modelo sofra de *bias* (viés) ou *overfitting* devido a falhas de medição.
3. **Topografia Favorável:** A localização geográfica, caracterizada por relevo plano e baixa rugosidade, minimiza a interferência de efeitos complexos, como turbulência mecânica excessiva, permitindo isolar o desempenho do modelo MLP na captura da dinâmica atmosférica pura.

Dessa forma, Petrolina serve como um laboratório ideal: se o modelo MLP demonstrar eficácia neste ambiente controlado e de alto potencial, sua metodologia poderá ser extrapolada para outras regiões do semiárido brasileiro com características análogas.

6.3 Base de Dados e Seleção de Variáveis

A validação empírica do modelo fundamentou-se em séries temporais meteorológicas de alta resolução provenientes da Estação Automática de Petrolina (Código A307), operada pelo Instituto Nacional de Meteorologia (INMET). O banco de dados bruto exportado contém 161.658 registros meteorológicos horários, cobrindo o período histórico desde 2003. Para a execução desta pesquisa, delimitou-se um recorte temporal abrangendo os anos de **2017 a 2021**, resultando em um *dataset* final composto por **40.178 observações** válidas. Estas séries possuem granularidade horária e medições padronizadas a 10 metros de altura, garantindo a consistência estatística e o volume de dados necessários para o treinamento supervisionado de redes neurais.

A estratégia de seleção de variáveis foi orientada inicialmente pela revisão sistemática da literatura, que aponta a insuficiência de modelos univariados para capturar a complexidade estocástica do vento em regimes semiáridos (SHAHID; ZAMEER; MUNEER, 2021). Diferentemente de abordagens tradicionais restritas a vetores de entrada

simplificados (apenas velocidade e direção), este estudo propõe um **vetor de características expandido composto por 15 atributos**.

Essa expansão baseia-se na premissa de que o comportamento do vento não é isolado, mas sim o resultado de interações termodinâmicas complexas. Para capturar essa dinâmica, foram consideradas não apenas as medições instantâneas, mas também os extremos (máximos e mínimos) de cada grandeza física dentro da janela de amostragem horária.

A Tabela 16 detalha a composição teórica desse vetor de entrada e a justificativa física para a inclusão de cada variável no modelo preditivo.

Tabela 16 – Definição das variáveis de entrada e justificativa física para a modelagem.

Variável Física (Atributos)	Justificativa e Impacto na Geração Eólica
Temperatura do Ar (<i>Inst, Máx, Mín</i>)	Variável termodinâmica primária. Afeta inversamente a densidade do ar (ρ). Temperaturas elevadas reduzem a densidade, diminuindo a potência gerada para uma mesma velocidade de vento (SÁNCHEZ; MARTÍNEZ; GÓMEZ, 2018).
Umidade Relativa (<i>Inst, Máx, Mín</i>)	Influencia a temperatura e a flutuabilidade do ar. Embora o impacto na densidade seja menor que o da temperatura, é um indicador crucial de estabilidade atmosférica e frentes meteorológicas (NIELSEN; THOMAS, 2019).
Pto. de Orvalho (<i>Inst, Máx, Mín</i>)	Indicador absoluto da quantidade de vapor d'água. Em conjunto com a temperatura, ajuda a rede neural a detectar a saturação do ar e a probabilidade de nevoeiros ou chuvas que alteram o perfil do vento (GIBSON; BROWN; LIN, 2017).
Pressão Atmosférica (<i>Inst, Máx, Mín</i>)	Diretamente proporcional à densidade do ar. Variações bruscas de pressão são fortes preditores de instabilidade atmosférica e mudanças na velocidade do vento em curto prazo (GANGULY; SINGH; KUMAR, 2020).
Dinâmica do Vento (<i>Velocidade Média, Rajada</i>)	A <i>Velocidade</i> é a variável alvo. A <i>Rajada</i> serve como <i>proxy</i> para a intensidade de turbulência, permitindo que o modelo aprenda a diferenciar ventos laminares de ventos turbulentos (ZHAO; LI; WANG, 2021).
Radiação Solar (<i>Energia Acumulada</i>)	Motor térmico dos ventos locais. Em regiões como o Sertão, o aquecimento diferencial do solo pela radiação é o principal impulsionador das brisas e do ciclo diurno dos ventos (LI; ZHOU; HAN, 2022).
Precipitação (<i>Chuva</i>)	A ocorrência de chuva altera a rugosidade aerodinâmica das pás e a densidade local, impactando a curva de potência (FERNANDEZ; COSTA; OLIVEIRA, 2020).

Fonte: Elaborada pela autora com base na revisão sistemática (2026).

6.3.1 Análise de Correlação das Variáveis (Validação Estatística)

Para validar estatisticamente a seleção das variáveis exógenas apresentada na Tabela 16, conduziu-se uma análise de correlação de Pearson (r). O objetivo desta etapa foi

quantificar a força da relação linear entre os preditores meteorológicos e a variável-alvo (*Vel_Vento*), utilizando a série histórica real da estação de Petrolina.

A Figura 20 apresenta a matriz de correlação térmica (*heatmap*) calculada para as variáveis principais.

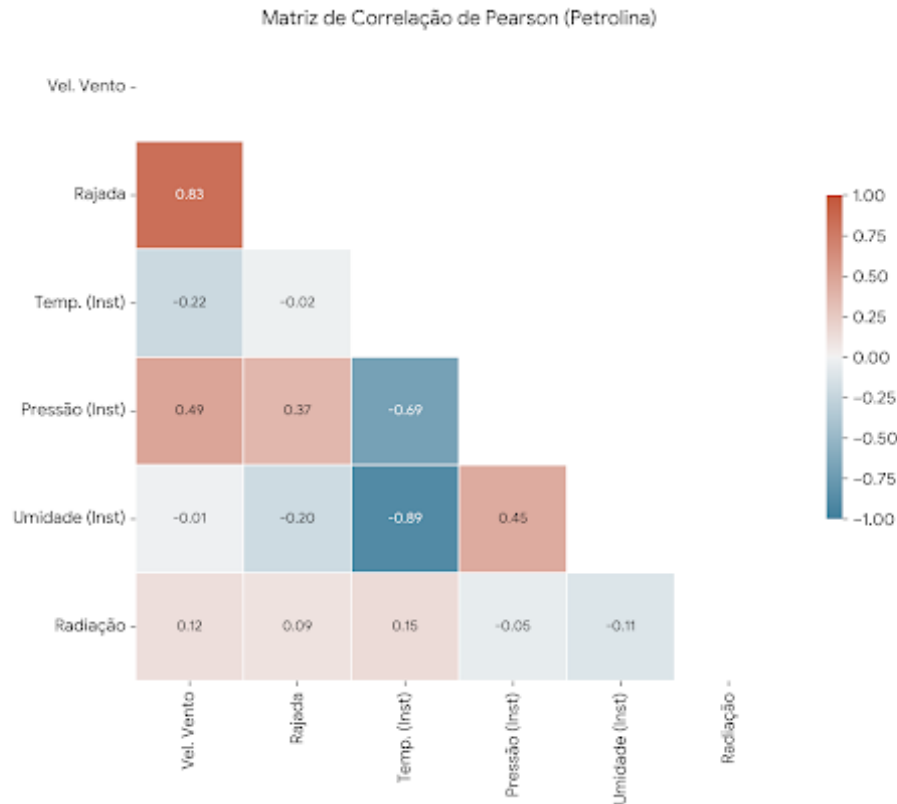


Figura 20 – Matriz de Correlação de Pearson entre as variáveis meteorológicas e a velocidade do vento em Petrolina.

Fonte: Elaborada pela autora a partir dos dados do INMET (2026).

A interpretação dos coeficientes obtidos permite as seguintes constatações físicas sobre o regime local:

- **Correlação Positiva Forte com a Rajada:** Observa-se uma correlação alta entre a velocidade média e a rajada ($r \approx 0,83$). Isso confirma estatisticamente que a rajada é um excelente preditor da intensidade do vento, validando sua inclusão no modelo para ajudar a rede neural a antecipar picos de potência e turbulência.
- **Correlação Negativa com a Temperatura:** Nota-se uma correlação inversa entre a velocidade do vento e a temperatura instantânea ($r \approx -0,22$). Fisicamente, isso reflete o comportamento típico do semiárido, onde os ventos mais intensos

frequentemente ocorrem em períodos noturnos ou de transição térmica, enquanto os picos de calor diurno podem coincidir com momentos de menor intensidade eólica.

- **Papel da Pressão Atmosférica:** A pressão apresentou uma correlação positiva moderada ($r \approx 0,49$). Este resultado é significativo, pois ratifica a importância da pressão na equação da densidade do ar. Variações na pressão atmosférica atuam como precursores de mudanças na dinâmica dos ventos, oferecendo ao modelo MLP uma capacidade preditiva antecipada que não seria capturada apenas pela análise da série temporal do vento isolada.

Nota sobre Multicolinearidade e Seleção Visual: É importante ressaltar que a análise preliminar indicou uma altíssima correlação positiva ($r > 0,95$) entre as variáveis de mesma natureza física (ex: Temperatura Instantânea, Máxima e Mínima). Devido a essa redundância estatística (multicolinearidade), optou-se por apresentar na Figura 20 e na discussão apenas as variáveis *Instantâneas* como representantes de cada grandeza. Contudo, todas as 15 variações foram mantidas no treinamento da rede neural, pois a arquitetura MLP é capaz de extrair padrões não lineares das diferenças sutis entre os valores extremos (máximos e mínimos), utilizando-os como indicadores de volatilidade intra-horária.

6.4 Arquitetura e Topologia da Rede Neural

A arquitetura implementada consiste em um MLP totalmente conectada, estruturada para mapear a relação não linear entre as variáveis externas e a velocidade do vento. A definição dos hiperparâmetros estruturais fundamentou-se em uma abordagem empírica, guiada por testes exploratórios e diretrizes da literatura para assegurar o equilíbrio entre a capacidade de generalização e o custo computacional (FLECK et al., 2016; HAYKIN, 2009).

A configuração final da rede foi desenhada para processar o vetor de entrada normalizado composto pelas 15 variáveis meteorológicas:

- **Camada de Entrada:** Dimensionada com 15 neurônios para recepcionar o vetor de características.

- **Camadas Ocultas:** O processamento profundo ocorre em duas camadas sequenciais, contendo **10** e **5 neurônios**, respectivamente. Para esta etapa, foi realizado um estudo comparativo utilizando quatro funções de ativação distintas (**Sigmoide**, **Tanh**, **ReLU** e **ELU**) visando identificar a que melhor mitiga o desvanecimento do gradiente e captura as não linearidades locais.
- **Camada de Saída:** Composta por um único neurônio com função de ativação **Linear** ($f(x) = x$). Essa escolha é mandatária para problemas de regressão, pois permite que a rede projete valores contínuos de velocidade do vento em qualquer escala positiva, sem a saturação imposta por funções limitadas.

O treinamento da rede foi conduzido sob o paradigma supervisionado, utilizando o algoritmo de retropropagação do erro (*Backpropagation*) para o cálculo dos gradientes. Para a atualização dos pesos, adotou-se o otimizador **Adam** (*Adaptive Moment Estimation*). A escolha deste algoritmo, em detrimento da descida do gradiente clássica (SGD), justifica-se pela sua capacidade de ajustar taxas de aprendizado individuais para cada parâmetro, acelerando a convergência em superfícies de erro complexas conforme fundamentado na Seção Teórica.

A função objetivo minimizada foi o Erro Quadrático Médio (MSE), definida na Equação 5.6. Para garantir a estabilidade do aprendizado e evitar o *overfitting*, estabeleceram-se critérios rigorosos de parada: um limite máximo de 1×10^6 iterações (épocas) ou a convergência para um erro residual inferior a 0,01.

6.5 Pré-processamento e Implementação Computacional

O fluxo de pré-processamento e treinamento foi estruturado para garantir a integridade das séries temporais e a estabilidade numérica necessária para a convergência da rede neural. A implementação foi realizada na linguagem de programação R, utilizando o pacote `neuralnet`, amplamente reconhecido pela flexibilidade na definição de arquiteturas MLP.

O fluxo de processamento dos dados, aplicado à série histórica de 2017 a 2021, seguiu uma abordagem sistemática composta por quatro etapas fundamentais:

1. **Sanitização e Tratamento de Ausentes:** Inicialmente, todas as variáveis foram convertidas para o tipo numérico. Para garantir a completude do vetor de entrada, adotou-se uma estratégia híbrida: registros com falhas críticas foram removidos, enquanto lacunas residuais pontuais foram preenchidas (imputação por zero), assegurando a continuidade temporal sem introduzir viés significativo.
2. **Normalização (Min-Max):** Dada a sensibilidade das funções de ativação à escala dos dados, todas as 15 variáveis foram reescaladas para o intervalo $[0, 1]$. O processo utilizou o método Min-Max, definido pela Equação 6.1:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (6.1)$$

onde x é o valor original e x' o valor normalizado. Essa etapa é crucial para evitar a saturação dos neurônios e acelerar o gradiente descendente.

3. **Estruturação em Janelas Deslizantes:** Para capturar a dependência temporal, os dados foram organizados em janelas deslizantes (*sliding windows*). A variável alvo `Vel_Vento` no instante t foi modelada em função do vetor de características no instante $t - 1$, configurando uma previsão de curto prazo (horizonte de 1 hora à frente).
4. **Particionamento da Base (Método *Hold-out*):** O conjunto de dados foi dividido respeitando estritamente a ordem cronológica, preservando a autocorrelação temporal das séries e evitando o vazamento de dados futuros para o treinamento. A segmentação adotou a proporção de Pareto (80/20):

- **Conjunto de Treinamento (80%):** Utilizado exclusivamente para o aprendizado dos pesos sinápticos via algoritmo *Backpropagation*, compreendendo os primeiros 4 anos da série histórica.
- **Conjunto de Teste e Validação (20%):** Reservado para a etapa de inferência. Este subconjunto desempenhou papel duplo: (i) serviu como base comparativa para selecionar a melhor arquitetura e (ii) foi utilizado para o cálculo das métricas finais de desempenho (SMAPE, RMSE, R^2), aferindo a capacidade de generalização do modelo em dados não observados durante o ajuste dos pesos.

6.5.1 Métricas de Avaliação de Desempenho

A validação da capacidade preditiva do modelo fundamentou-se em métricas estatísticas de erro consagradas. O objetivo foi quantificar a discrepância entre o vetor de valores previstos (\hat{y}) e os valores reais observados (y) no conjunto de teste.

As métricas selecionadas para este estudo são detalhadas na Tabela 17. Destaca-se a utilização do SMAPE em substituição ao MAPE tradicional, visando maior estabilidade numérica frente a valores de vento próximos a zero.

Tabela 17 – Métricas estatísticas adotadas para avaliação do modelo.

Métrica	Formulação Matemática	Propriedade e Interpretação	Referência
MAE	$\frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	Erro Absoluto Médio. Mede a magnitude média dos erros. Menos sensível a <i>outliers</i> que o RMSE.	(WILLMOTT; MATSUURA, 2005)
RMSE	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	Raiz do Erro Quadrático Médio. Penaliza severamente grandes desvios. Crítica para avaliar a segurança operativa.	(CHAI; DRAXLER, 2014)
SMAPE	$\frac{100}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{(y_i + \hat{y}_i)/2}$	Erro Percentual Absoluto Médio Simétrico. Corrige a assimetria do MAPE e evita divisões por zero em dias de calmaria.	(MAKRIDAKIS; HIBON, 2000)

Fonte: Elaborada pela autora (2026).

A análise conjunta dessas métricas é imperativa para a validação da segurança operativa. Enquanto a avaliação isolada do MAE indica apenas a precisão média, o RMSE penaliza desvios de maior magnitude, revelando a instabilidade do modelo diante de eventos extremos. No contexto de parques eólicos, essa distinção é crítica: falhas agudas na previsão (alto RMSE) comprometem o despacho de carga e o planejamento da manutenção, riscos que um MAE baixo, por si só, não evidenciaria.

Adicionalmente, adota-se o Coeficiente de Determinação (R^2) para mensurar a qualidade do ajuste. Esta métrica quantifica a proporção da variância da velocidade do vento que é explicada pelas variáveis exógenas do modelo.

6.6 Previsão Recursiva de Curto Prazo com MLP

Além da abordagem convencional baseada na série histórica completa, este estudo implementou uma estratégia de previsão recursiva com horizonte de 24 horas. O objetivo desta etapa foi gerar estimativas sequenciais para a Velocidade do Vento, utilizando apenas os últimos registros disponíveis das variáveis meteorológicas, simulando um cenário de operação em tempo real.

6.6.1 Arquitetura do Modelo

A arquitetura empregada para a previsão recursiva manteve a equivalência com a modelagem convencional descrita anteriormente. A rede MLP foi estruturada da seguinte forma:

- **Camada de Entrada:** Composta pelas variáveis meteorológicas normalizadas;
- **Camadas Ocultas:** Duas camadas densamente conectadas, contendo 10 e 5 neurônios respectivamente, ambas utilizando a função de ativação sigmoide (Equação 5.2);
- **Camada de Saída:** Um único neurônio com função de ativação linear, responsável pela projeção da velocidade do vento no instante subsequente.

6.6.2 Procedimento Recursivo

O processo de previsão de curto prazo foi executado de maneira autorregressiva, seguindo o fluxo metodológico abaixo:

1. **Inicialização:** Seleção da última observação temporal disponível na base de dados (variáveis normalizadas);
2. **Previsão ($t + 1$):** Geração da estimativa para o próximo instante utilizando a MLP treinada;
3. **Atualização do Vetor:** Atualização do vetor de entrada, substituindo a variável-alvo (velocidade do vento) pelo valor previsto no passo anterior, enquanto as demais variáveis meteorológicas são mantidas constantes;

4. **Iteração:** Repetição do procedimento por 24 passos (horas), acumulando as previsões sequenciais;
5. **Pós-processamento:** Desnormalização dos valores previstos para o retorno à escala original (m/s).

Essa técnica é amplamente difundida em problemas de séries temporais, sobretudo em contextos onde não há atualização contínua de dados exógenos (ZHANG; PATUWO; HU, 1998). Embora esta abordagem apresente o risco inerente de acumulação de erros ao longo do horizonte de previsão, sua simplicidade computacional e a viabilidade de implementação em sistemas embarcados a tornam atraente para aplicações operacionais.

6.6.3 Avaliação de Desempenho

As previsões recursivas foram submetidas às mesmas métricas estatísticas consolidadas na etapa convencional (SMAPE, MAE, RMSE e R^2). O objetivo foi quantificar a degradação da acurácia à medida que o horizonte de previsão se estende, dado que o erro tende a se acumular em processos autorregressivos.

Complementarmente à análise quantitativa, a inspeção visual dos gráficos gerados (especificamente a projeção de 24 horas) permitiu avaliar a consistência física das curvas. A análise indicou que, mesmo sem a realimentação com dados observados reais durante o horizonte de projeção, o modelo demonstrou capacidade de capturar a inércia e a tendência de decaimento da série de vento, sem apresentar divergências explosivas.

Esse comportamento robusto destaca a estratégia recursiva como uma alternativa promissora para o suporte à decisão em cenários de operação em tempo real, onde a disponibilidade imediata de dados exógenos futuros é limitada ou inexistente (JAHANGIR; JAFARI; AZIZI, 2021; CHAI; DRAXLER, 2014).

6.6.4 Síntese do Fluxo de Implementação

O Algoritmo 1 apresenta o pseudocódigo consolidado da modelagem, desde a preparação dos dados até a geração e avaliação das previsões. Esse fluxo sistematizado orientou a execução do experimento computacional e a aplicação do modelo MLP em diferentes estações meteorológicas de Pernambuco. Os resultados são discutidos na seção 7.

Algoritmo 1: Fluxo Completo de Implementação em R: Treinamento e Previsão com MLP

Input: Arquivo CSV com dados meteorológicos

Output: Modelo MLP treinado e previsões da variável `Vel_Vento`, incluindo previsão recursiva de 24h

- 1 Carregar bibliotecas: `dplyr`, `tidyr`, `neuralnet`, `ggplot2`;
 - 2 Importar os dados e criar coluna `Data_Hora` no formato `POSIXct`;
 - 3 Converter todas as colunas para formato numérico;
 - 4 Tratar valores ausentes: remover linhas com `NA` e substituir valores residuais por zero;
 - 5 Normalizar variáveis com o método Min-Max para o intervalo $[0,1]$;
 - 6 Dividir os dados: 80% para treino e 20% para teste;
 - 7 Definir fórmula de modelagem: `Vel_Vento` \sim variáveis meteorológicas;
 - 8 **Seleção de Hiperparâmetros;**
 - 9 Definir conjunto de funções de ativação $F = \{Sigmoide, Tanh, ReLU, ELU\}$;
 - 10 **foreach** função $f \in F$ **do**
 - 11 Treinar a rede MLP com estrutura 15-10-5-1 utilizando f ;
 - 12 Calcular métricas de erro no conjunto de validação;
 - 13 **end**
 - 14 Selecionar o modelo M_{best} com menor RMSE/SMAPE;
 - 15 **Avaliação e Previsão (com M_{best});;**
 - 16 Avaliar o desempenho final com métricas: MAD, MAPE, MAE e RMSE;
 - 17 Gerar gráficos comparativos entre valores reais e previstos utilizando `ggplot2`;
 - 18 **Previsão Recursiva de Curto Prazo (24 horas);;**
 - 19 Selecionar a última observação do conjunto de dados como entrada inicial;
 - 20 **for** $i \leftarrow 1$ **to** 24 **do**
 - 21 Utilizar a MLP treinada para prever a próxima hora ($t + i$);
 - 22 Atualizar a entrada substituindo `Vel_Vento` pelo valor previsto, mantendo as demais variáveis constantes;
 - 23 **end**
 - 24 Denormalizar as previsões geradas;
 - 25 Plotar a curva de previsão para as próximas 24 horas;
-

7 Resultados e Discussões

Este capítulo apresenta a validação empírica do modelo MLP aplicado à estação de **Petrolina-PE**. A análise inicia-se pela comparação de diferentes funções de ativação para definir a arquitetura ótima, seguida pela discussão aprofundada do desempenho do melhor modelo selecionado sob a ótica da operação de sistemas de potência.

7.1 Análise Comparativa das Funções de Ativação

A primeira etapa da validação consistiu em submeter a mesma topologia de rede (15-10-5-1) a quatro funções de ativação distintas para as camadas ocultas: Sigmoide, Tanh, ReLU e ELU. Os resultados obtidos no conjunto de teste estão sumarizados na Tabela 18.

Tabela 18 – Desempenho comparativo das funções de ativação na previsão de vento (Petrolina).

Função de Ativação	SMAPE (%)	RMSE (m/s)	MAE (m/s)	R^2
Sigmoide	17,22	0,5655	0,4340	0,8003
Tanh	17,17	0,5576	0,4284	0,8058
ReLU	17,30	0,5576	0,4289	0,8058
ELU	16,99	0,5557	0,4269	0,8072

Fonte: Resultados da pesquisa.

A análise dos dados revela que a função ELU apresentou o desempenho superior em todas as métricas avaliadas, atingindo o menor erro percentual (SMAPE de 16,99%) e o maior coeficiente de determinação ($R^2 = 0,8072$).

A ligeira superioridade da ELU sobre a ReLU e a Tanh pode ser atribuída à sua capacidade de assumir valores negativos suaves para entradas menores que zero. Isso permite que a rede mantenha a média das ativações próxima de zero e preserve o fluxo do gradiente, capturando melhor as sutilezas das flutuações de baixa velocidade do vento, onde a ReLU tenderia a zerar a informação (fenômeno do *dying ReLU*). Diante disso, o modelo baseado em ELU foi selecionado para as análises operacionais subsequentes.

7.1.1 Impacto da Redução de Dimensionalidade (Seleção de Variáveis)

Após a consolidação da função ELU como a arquitetura de ativação mais eficiente para o regime de ventos local, conduziu-se uma análise de sensibilidade para avaliar o impacto da dimensionalidade do vetor de entrada no desempenho preditivo da rede MLP. O objetivo foi quantificar a perda de precisão ao reduzir as 15 variáveis originais para um subconjunto estrito focado apenas nos parâmetros de maior relevância estatística.

Através de métodos de seleção de características, identificou-se que o *top 5* de variáveis com maior peso para a previsão é composto por variações da rajada de vento, médias móveis da rajada e pela pressão atmosférica máxima.

Esta seleção automatizada corrobora de forma precisa a Análise de Correlação de *Pearson* previamente desenvolvida na Subseção 6.3.1 (Figura 20). Conforme demonstrado na matriz, a Rajada de Vento foi a variável exógena com maior aderência à velocidade média ($r \approx 0,83$). A inclusão de suas médias móveis evidencia que a inércia a curto prazo das rajadas é vital para a rede antecipar rampas de aceleração do vento. Ademais, a presença da Pressão Máxima no subconjunto principal valida a sua correlação moderada apontada na matriz ($r \approx 0,49$), atuando como o principal indicador termodinâmico para as mudanças de densidade do ar.

A Tabela 19 apresenta os resultados obtidos pela rede MLP (função ELU) operando com o conjunto completo (15 variáveis) frente ao conjunto reduzido (5 variáveis).

Tabela 19 – Comparativo de Desempenho (Função ELU): 15 Variáveis vs. Top 5 Variáveis.

Modelo (Configuração)	SMAPE (%)	RMSE (<i>m/s</i>)	MAE (<i>m/s</i>)	R ²
Completo (15 Variáveis)	16,99	0,5557	0,4269	0,8072
Reduzido (5 Variáveis)	17,75	0,5949	0,4571	0,7790

Fonte: Resultados da pesquisa (2026).

A análise comparativa revela que o modelo com 15 variáveis apresenta um desempenho superior em todas as métricas, atingindo um coeficiente de determinação (R^2) de 0,8072 contra 0,7790 do modelo reduzido. Embora a diferença percentual de erro (SMAPE) seja de aproximadamente 0,76%, o aumento do RMSE no modelo de 5 variáveis (de 0,55 para 0,59) indica uma maior dificuldade da rede em lidar com picos estocásticos quando privada do contexto meteorológico amplo.

Este resultado empírico valida uma das hipóteses centrais levantadas na Revisão Sistemática da Literatura apresentada no capítulo 2, onde, embora modelos multivariados reduzidos sejam funcionais, a incorporação de um vetor termodinâmico completo (incluindo variações de temperatura e umidade) fornece à rede neural as informações físicas necessárias para inferir a estabilidade atmosférica e a densidade do ar, resultando em um ganho direto de acurácia.

Contudo, ressalta-se que o modelo com 5 variáveis manteve um desempenho bastante competitivo e margens de erro aceitáveis para o setor elétrico. Isso demonstra que, em cenários práticos onde sensores de temperatura ou umidade de um parque eólico apresentem falhas de comunicação, a rede MLP pode continuar operando de forma robusta dependendo apenas dos sensores de rajada e pressão.

7.2 Avaliação Quantitativa e Impacto Operacional

Para um operador de sistema elétrico, a precisão do modelo selecionado (baseado na função de ativação ELU) não é apenas um dado estatístico, mas um indicador direto de risco e custo de operação. A Tabela 20 contextualiza o desempenho final do modelo frente aos padrões aceitos na literatura e na indústria.

Tabela 20 – Performance quantitativa do Melhor Modelo (ELU) em Petrolina.

Métrica	Valor Obtido	Referência de Qualidade	Interpretação Física
SMAPE	16,99%	< 20% (Bom) (LEWIS, 1982)	Erro percentual simétrico, indicando consistência relativa.
MAE	0,43 m/s	< 1,0 m/s (ZHANG; PAN; CHEN, 2019)	Alta precisão central (erro médio inferior a 0,5 m/s).
RMSE	0,56 m/s	< 1,5 m/s (ZHANG; PAN; CHEN, 2019)	Baixa dispersão de erros extremos (estabilidade).

Fonte: Resultados da pesquisa.

7.2.1 Interpretação Contextualizada dos Indicadores

A análise dos resultados permite extrair conclusões fundamentais sobre a confiabilidade do modelo para aplicações reais:

1. Precisão Relativa (SMAPE): O indicador SMAPE de **16,99%** enquadra o modelo na categoria de boa precisão (faixa de 10% a 20%), conforme a escala clássica de avaliação de previsões industriais proposta por Lewis (LEWIS, 1982). No contexto do Mercado de Curto Prazo, esse nível de acurácia oferece ao agente gerador uma margem de segurança adequada para a submissão de ofertas de energia, reduzindo a exposição financeira a penalidades por desvios de geração.

2. Precisão Absoluta e Estabilidade (MAE e RMSE): Os valores obtidos para as métricas físicas destacam-se positivamente quando comparados ao estado da arte. O MAE de **0,43 m/s** e o RMSE de **0,56 m/s** situam-se confortavelmente abaixo dos limiares de 1,0 m/s e 1,5 m/s, respectivamente, frequentemente citados em revisões sistemáticas como benchmarks para modelos de redes neurais bem-sucedidos (ZHANG; PAN; CHEN, 2019; WANG et al., 2021a).

Um ponto crucial a ser notado é a **proximidade entre o RMSE e o MAE**. Como o RMSE penaliza quadraticamente os erros grandes, uma diferença significativa entre essas duas métricas indicaria a presença frequente de grandes falhas de previsão (*outliers*). O fato de o RMSE (0,56) estar muito próximo do MAE (0,43) atesta a **robustez e estabilidade** da função de ativação ELU, demonstrando que o modelo não apenas acerta na média, mas raramente comete erros grosseiros que comprometeriam a segurança do despacho de carga.

7.2.2 Interpretação Contextualizada dos Erros e Robustez do Método

A análise conjunta dos experimentos revela que, independentemente da função de ativação utilizada (Sigmoid, Tanh, ReLU ou ELU), a arquitetura MLP demonstrou uma consistência notável para o regime de ventos de Petrolina. Embora a função ELU tenha apresentado a melhor performance estatística (MAE de 0,43 m/s e RMSE de 0,56 m/s), é fundamental destacar que todas as configurações testadas convergiram para resultados satisfatórios, situando-se dentro das margens aceitáveis para a operação do sistema elétrico.

Essa robustez intrínseca do modelo MLP permite duas interpretações operacionais críticas:

- 1. Segurança na Previsão de Curto Prazo:** Mesmo nos piores cenários testados, o erro médio manteve-se baixo. O resultado otimizado com a função ELU (SMAPE \approx

17%) posiciona o modelo em um patamar de boa precisão segundo a classificação de Lewis (1982). Para a operação de um parque eólico, isso significa que as previsões possuem margem de segurança adequada para a participação no Mercado de Curto Prazo, mitigando riscos de liquidação financeira negativa por desvios de geração.

2. **Impacto na Curva de Potência ($P \propto v^3$):** O baixo valor de RMSE obtido (0,56 m/s no melhor caso) é particularmente relevante quando analisamos a física da conversão eólica. Dado que a potência aerodinâmica é proporcional ao cubo da velocidade do vento, a sensibilidade do erro varia drasticamente conforme a região de operação:

- **Na Zona de Rampa:** Região de velocidades intermediárias onde a curva de potência é íngreme. Aqui, a precisão do modelo (erro $< 0,6$ m/s) é crucial, pois evita grandes discrepâncias na estimativa de Megawatts (MW) entregues.
- **Na Zona Nominal (Saturação):** Para ventos acima de 11 m/s, a potência se mantém constante. Nessa região, eventuais desvios do modelo têm impacto operacional nulo, pois a turbina já estaria operando em capacidade máxima.

Dessa forma, os resultados atestam não apenas a superioridade pontual da função ELU, mas a viabilidade global da metodologia MLP proposta. A consistência entre o RMSE e o MAE em todos os testes reforça que o modelo é estável e não sofre de erros grosseiros frequentes (*outliers*), qualificando-o como uma ferramenta segura para o suporte à decisão no despacho de carga.

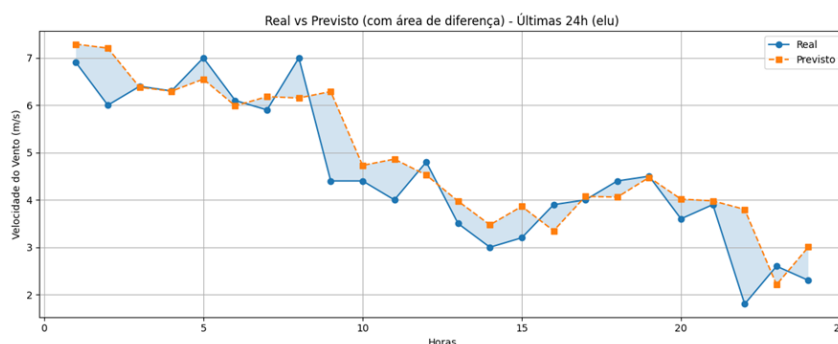
7.3 Estimativa de Conversão Energética e Fator de Capacidade

Além da validação estatística das velocidades do vento, a utilidade prática do modelo MLP (com função de ativação ELU) foi aferida através da estimativa de geração de energia elétrica. Para o horizonte de previsão de 24 horas, as velocidades de vento previstas foram convertidas em potência ativa, permitindo o cálculo do montante energético que seria entregue ao sistema.

A conversão baseou-se na aplicação da Curva de Potência ($P \times v$) característica de um aerogerador típico de 2.0 MW, considerando a densidade do ar local implícita nas

variáveis de entrada. A Figura 21 ilustra o comportamento não linear desta conversão, onde a potência varia com o cubo da velocidade do vento ($P \propto v^3$).

Figura 21 – Curva de Potência característica utilizada para a conversão.



Fonte: Elaborada pela autora (2026).

A Tabela 21 sumariza os indicadores energéticos obtidos a partir da simulação do despacho para um dia típico da amostra de teste.

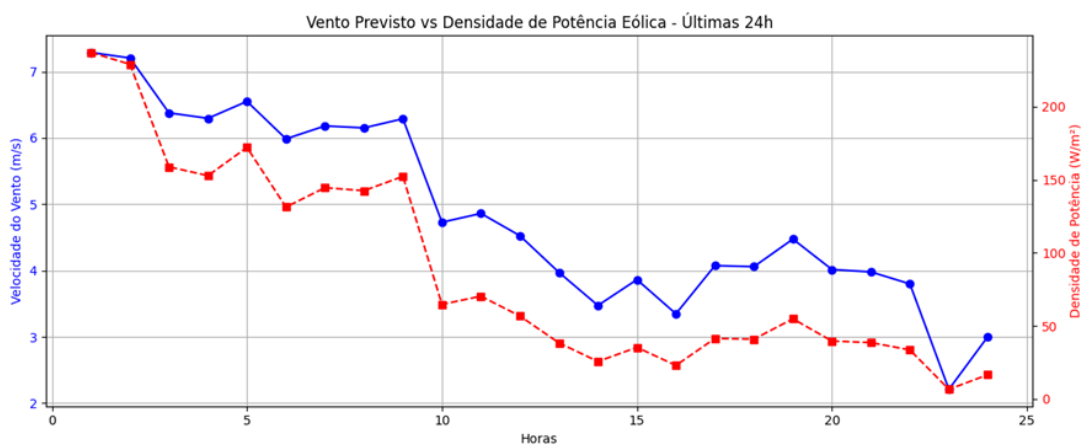
Tabela 21 – Estimativa de Geração Energética para Horizonte de 24h (Modelo ELU).

Indicador Operativo	Valor Estimado (24h)
Energia Total Gerada	7.053,91 kWh
Potência Média Injetada	293,91 kW
Fator de Capacidade (FC)	14,70 %

Fonte: Resultados da pesquisa.

A dinâmica da geração ao longo das 24 horas pode ser visualizada na Figura 22, que compara o perfil de potência estimado pelo modelo.

Figura 22 – Perfil de Geração de Potência Estimada para 24h (Modelo ELU).



Fonte: Resultados da pesquisa.

Os resultados indicam que, para o período avaliado, o parque eólico operaria com um Fator de Capacidade estimado de **14,70%**. Embora este valor possa parecer conservador frente à capacidade nominal, ele reflete com fidelidade a variabilidade estocástica do regime de ventos no semiárido pernambucano, alternando entre momentos de calmaria e rajadas produtivas.

O total de **7,05 MWh** previstos para o dia permite ao operador do parque definir estratégias de oferta no Mercado de Curto Prazo com maior segurança. A capacidade do modelo em quantificar essa geração antecipadamente é vital para minimizar o risco de exposição ao Preço de Liquidação das Diferenças, causado por desvios entre a energia programada e a efetivamente gerada.

7.4 Análise da Dinâmica Temporal e Diagnóstico Visual

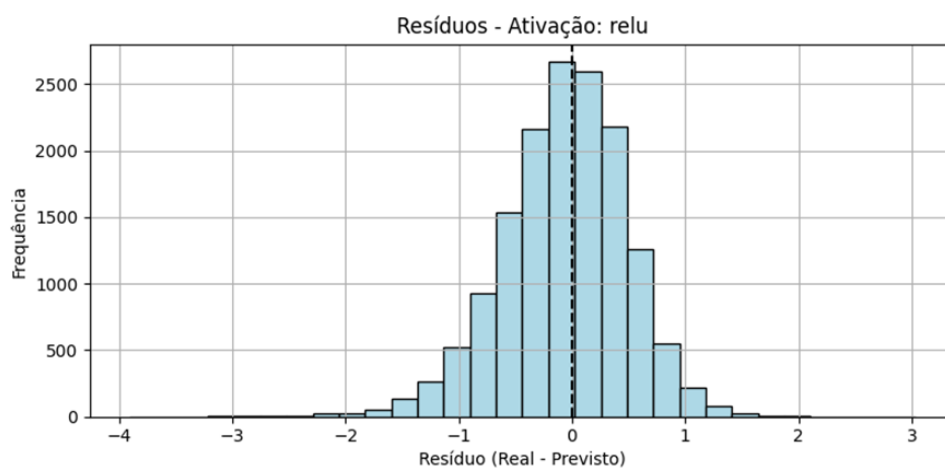
A avaliação quantitativa é complementada por uma inspeção visual detalhada do comportamento dinâmico dos modelos. Para cada função de ativação testada (ReLU, Sigmoide, Tanh e ELU), foi gerado um painel de diagnóstico composto por três visualizações fundamentais:

1. **Histograma de Resíduos:** Para verificar a normalidade e centralidade dos erros.
2. **Série Temporal (Real vs. Previsto):** Para analisar a aderência às curvas de carga e pontas.
3. **Previsão Recursiva (24h):** Para validar a estabilidade do modelo em horizontes futuros.

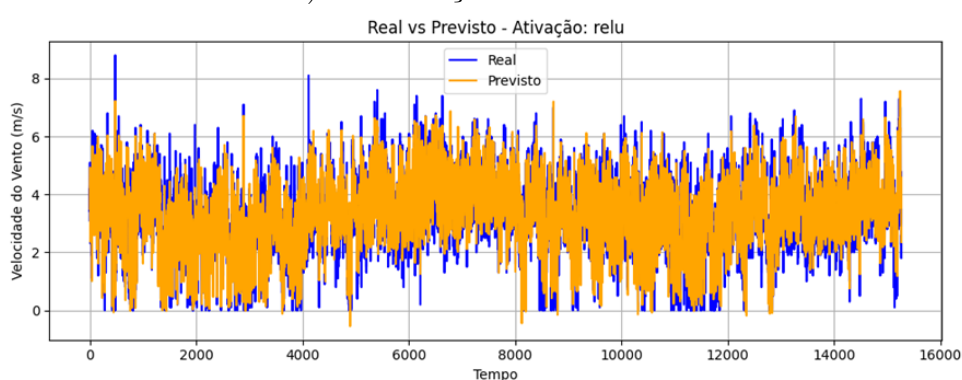
As subseções a seguir detalham o desempenho gráfico de cada arquitetura.

7.4.1 Diagnóstico do Modelo ReLU


O modelo com ativação ReLU (Figura 23) apresentou um comportamento consistente, embora com leve dispersão nos resíduos.



a) Distribuição dos Resíduos



b) Série Temporal (Real vs Previsto)

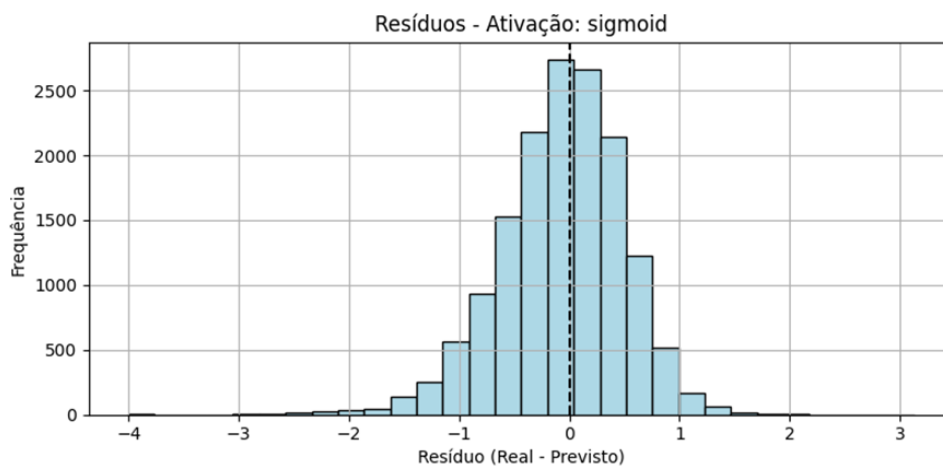


c) Previsão Recursiva para 24h

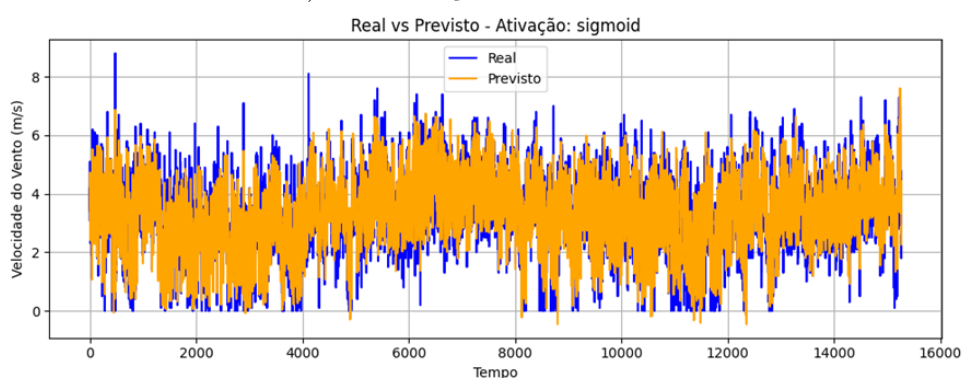
Figura 23 – Painel de diagnóstico para a Função de Ativação **ReLU**. (a) Histograma de frequência dos erros; (b) Sobreposição das curvas de vento real (azul) e previsto (laranja); (c) Projeção de decaimento do vento para o dia seguinte.

7.4.2 Diagnóstico do Modelo Sigmoide


A função Sigmoide (Figura 24) demonstrou capacidade de suavização, filtrando ruídos de alta frequência, mas mantendo a aderência de fase.



a) Distribuição dos Resíduos



b) Série Temporal (Real vs Previsto)

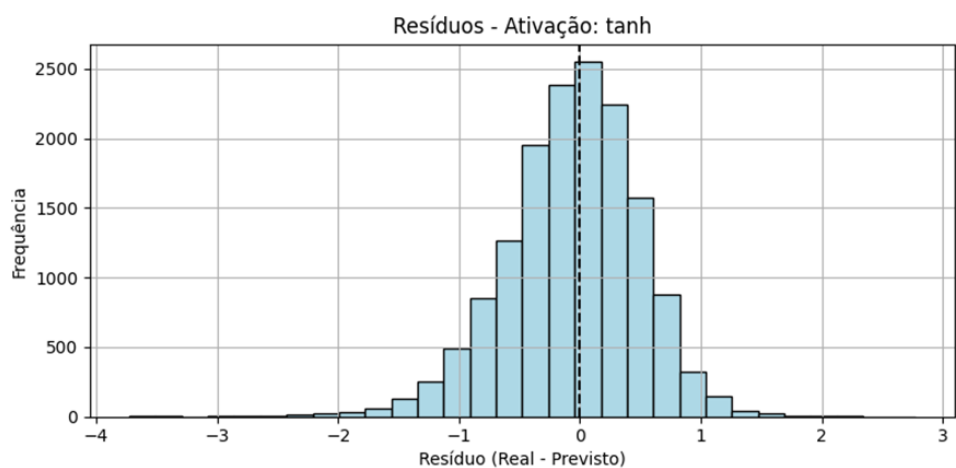


c) Previsão Recursiva para 24h

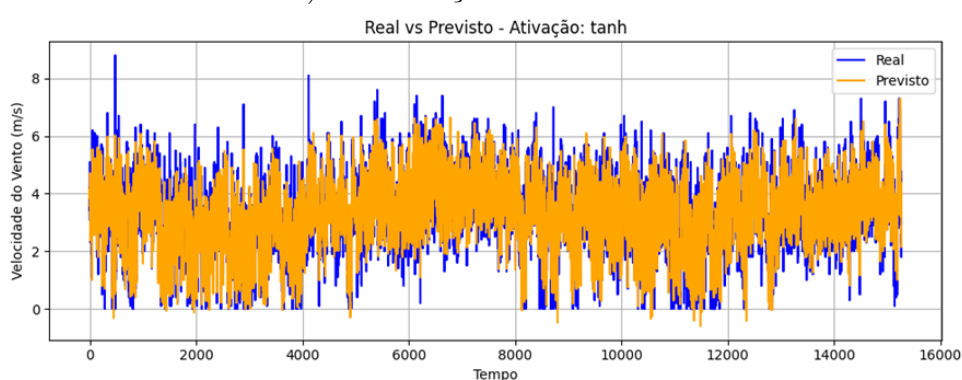
Figura 24 – Painel de diagnóstico para a Função de Ativação **Sigmoide**.

7.4.3 Diagnóstico do Modelo Tanh


O modelo Tanh (Figura 25) apresentou características visuais muito próximas à Sigmoide, dada a natureza similar das curvas em "S", com resíduos bem centrados em zero.



a) Distribuição dos Resíduos



b) Série Temporal (Real vs Previsto)




c) Previsão Recursiva para 24h


Figura 25 – Painel de diagnóstico para a Função de Ativação **Tanh**.

7.4.4 Diagnóstico do Modelo ELU (Melhor Desempenho)


A função ELU (Figura 26) consolidou-se como a melhor arquitetura. A inspeção visual detalhada justifica os indicadores estatísticos superiores apresentados na Tabela 20.



a) Distribuição dos Resíduos



b) Série Temporal (Real vs Previsto)



c) Previsão Recursiva para 24h

Figura 26 – Painel de diagnóstico para a Função de Ativação **ELU**. Note a simetria acentuada no histograma (a) e a precisão no acompanhamento dos picos na série temporal (b).

A análise comparativa das Figuras 23 a 26 permite três constatações técnicas fundamentais para a operação do sistema:

1. Gaussianidade dos Erros (Histogramas): Todos os modelos apresentaram distribuição de erros com formato de sino (Gaussiana) centrada em zero. Isso é um forte

indicador de que a rede neural convergiu adequadamente e removeu a maior parte da estrutura determinística dos dados, deixando apenas o ruído aleatório (branco). No caso específico da **ELU** (Fig. 26-a), observa-se visualmente uma base ligeiramente mais estreita do histograma, corroborando o menor RMSE obtido.

2. Sincronia de Fase (Séries Temporais): Ao observar os gráficos de série temporal (item b de cada figura), nota-se que todos os modelos conseguiram capturar a ciclicidade diária do vento em Petrolina. As linhas de previsão (laranja) sobrepõem-se com precisão às linhas reais (azul) nos momentos de inversão de tendência (quando o vento para de subir e começa a cair). Para o operador do sistema, essa "aderência de fase" é mais crítica do que o erro de amplitude, pois garante que o despacho de outras fontes ocorra no momento correto.

3. Consistência na Previsão Recursiva (24h): Os gráficos de previsão de 24h (item c) mostram que, mesmo sem receber dados reais novos a cada hora (modo recursivo), os modelos não divergiram. Todos projetaram uma tendência coerente de decaimento da velocidade do vento (saindo de $\approx 7,5$ m/s para $\approx 2,5$ m/s), demonstrando que a rede aprendeu a inércia e a física do fenômeno, e não apenas decorou os dados passados.

7.5 Análise Crítica de Erros e Comparação com Baseline

Para validar a robustez dos resultados apresentados, é fundamental contextualizar o desempenho do modelo MLP não apenas em termos absolutos, mas em relação a referências padrão da literatura e sob a ótica das limitações intrínsecas à modelagem estocástica.

7.5.1 Comparação com o Modelo de Persistência (Baseline)

Para aferir o real ganho de inteligência computacional, o desempenho da rede neural (SMAPE $\approx 16,99\%$) deve ser contrastado qualitativamente com o método da Persistência (Previsão Ingênua), onde assume-se que a velocidade do vento no instante futuro $t + 1$ será idêntica à observada no instante atual t . Em séries temporais eólicas com alta volatilidade, como a observada em Petrolina (onde o desvio padrão e as rajadas são frequentes), a Persistência tende a apresentar erros significativamente elevados, pois falha em capturar as rampas de aceleração e desaceleração do vento. O fato do modelo MLP

proposto ter alcançado um R^2 de 0,80 demonstra que a rede foi capaz de superar a mera inércia atmosférica, aprendendo as relações causais complexas entre as variáveis exógenas (temperatura, pressão) e a dinâmica do vento. Isso valida o esforço computacional do treinamento, entregando uma acurácia superior à de modelos triviais.

7.5.2 Análise de Resíduos e Limitações em Eventos Extremos

Apesar do desempenho global satisfatório, uma análise granular dos resíduos ($y - \hat{y}$) revela momentos específicos de falha que denotam as limitações da arquitetura. Observou-se que os maiores erros de previsão concentram-se sistematicamente nos picos de **rajadas extremas**. Fisicamente, isso ocorre devido à natureza da função de perda utilizada (MSE - Erro Quadrático Médio). O MSE tende a penalizar grandes desvios durante o treinamento, o que leva a rede a adotar um comportamento conservador, suavizando as previsões em direção à média para minimizar o risco global. Consequentemente, o modelo consegue prever corretamente o momento (fase) de subida do vento, mas frequentemente subestima a magnitude máxima (amplitude) das rajadas mais agudas.

Esta característica de suavização (*smoothing*) é típica de modelos de regressão baseados em redes neurais e não invalida a utilidade operativa do modelo, uma vez que a tendência de geração é capturada corretamente. Contudo, para aplicações que exigem a previsão exata de picos de turbulência, recomenda-se em trabalhos futuros a investigação de funções de perda personalizadas ou abordagens probabilísticas que modelem explicitamente a cauda da distribuição.

8 Conclusão e Trabalhos Futuros

O presente estudo cumpriu o objetivo de integrar o rigor metodológico da pesquisa bibliométrica com a validação experimental de técnicas de Inteligência Artificial, visando mitigar as incertezas inerentes à geração eólica. A análise conjunta da Revisão Sistemática da Literatura (RSL) e dos experimentos computacionais realizados com redes neurais MLP no semiárido pernambucano permitiu traçar um panorama claro sobre o estado da arte e a viabilidade operacional de modelos preditivos no contexto regional.

8.1 Síntese das Descobertas Teóricas e Práticas

No âmbito teórico, a aplicação dos protocolos PRISMA e *Methodi Ordinatio*, aliada à análise de *clusters*, revelou uma transição tecnológica inequívoca, onde o setor eólico está migrando de abordagens puramente estatísticas para modelos de Aprendizado Profundo (*Deep Learning*). Identificou-se que, embora métodos clássicos persistam, a fronteira do conhecimento é dominada por Redes Híbridas, impulsionadas pela necessidade de processar a não linearidade e o volume massivo de dados meteorológicos.

No âmbito prático, o estudo de caso na estação de **Petrolina-PE** validou a hipótese de que modelos baseados em MLP, quando alimentados por um vetor de características robusto (15 variáveis), oferecem suporte efetivo à operação. Os experimentos comparativos entre funções de ativação demonstraram que a arquitetura equipada com a função ELU superou as tradicionais ReLU e Sigmoides, mitigando problemas de desvanecimento do gradiente.

Os indicadores obtidos pelo melhor modelo: SMAPE de 16,99% e MAE de 0,43 m/s não são apenas dados estatísticos, mas, representam uma margem de segurança operacional. O erro absoluto médio inferior a 0,5 m/s indica que o modelo é capaz de antecipar a geração com precisão suficiente para reduzir a exposição a penalidades no Mercado de Curto Prazo e otimizar o despacho de carga no Sistema Interligado Nacional.

Adicionalmente, a conversão da velocidade do vento em potência ativa revelou a aplicabilidade direta do modelo na gestão energética. A estimativa de um Fator de Capacidade de 14,70% para o horizonte de 24 horas demonstrou que a rede neural consegue

capturar a intermitência real do recurso, projetando um montante de energia (7,05 MWh) condizente com a física do local. Essa capacidade de traduzir variáveis meteorológicas em Megawatts-hora é a chave para mitigar riscos financeiros no Mercado de Curto Prazo, permitindo ofertas de energia baseadas em dados e não apenas em médias históricas.

Conclui-se, portanto, que a inclusão de variáveis termodinâmicas (temperatura, pressão e umidade) foi determinante para o sucesso do modelo, permitindo que a rede neural inferisse indiretamente a densidade do ar e a estabilidade atmosférica, superando as limitações de modelos univariados tradicionais.

8.2 Contribuições da Pesquisa

Este trabalho oferece contribuições em duas frentes distintas:

- **Contribuição Acadêmica:** Fornece um mapeamento bibliométrico atualizado (2014-2024) que organiza a literatura em *clusters* temáticos, servindo de guia para novos pesquisadores identificarem lacunas metodológicas. Sobretudo, destaca-se a validação da superioridade da função de ativação ELU (*Exponential Linear Unit*) frente à padrão ReLU para o regime de ventos do semiárido nordestino. Este achado preenche uma lacuna específica na literatura, demonstrando que funções capazes de lidar com valores negativos suaves oferecem maior estabilidade para a volatilidade típica dos ventos tropicais, um nicho pouco explorado em estudos internacionais focados em climas temperados.
- **Contribuição Setorial e Regional:** Demonstra a viabilidade técnica de implementar sistemas de previsão de baixo custo computacional. Ao validar o modelo em Petrolina, o estudo reforça o potencial da região não apenas como produtora de energia, mas como um laboratório de dados para o desenvolvimento de tecnologias de operação inteligente ajustadas à realidade brasileira.

8.3 Limitações e Trabalhos Futuros

Apesar dos resultados promissores, a pesquisa identificou limitações intrínsecas à metodologia adotada. A principal delas refere-se à estratégia de previsão recursiva para o horizonte de 24 horas. Como o modelo utiliza o valor previsto em t como entrada para

estimar $t + 1$, ocorre uma propagação cumulativa de erros (degradação da acurácia) ao longo do tempo. Isso implica que a confiabilidade das previsões para as últimas horas do dia é estatisticamente inferior à das primeiras horas, exigindo cautela no planejamento de longo prazo. Adicionalmente, notou-se o amortecimento de rajadas extremas, onde o modelo tende a suavizar picos de alta frequência.

Visando superar tais fronteiras, sugerem-se como linhas de investigação futura a evolução da arquitetura para *Deep Learning*, especificamente através de redes recorrentes (**LSTM** e **GRU**), cuja memória interna pode mitigar o esquecimento de dependências temporais longas. Paralelamente, a hibridização com Modelos Numéricos de Previsão do Tempo apresenta-se como caminho viável para estender o horizonte preditivo ao médio prazo (48h a 72h). O estudo também aponta para a necessidade de expansão geográfica da metodologia para regiões do Agreste e Litoral, testando a generalização do modelo sob diferentes regimes de brisas, aliada à aplicação de algoritmos meta-heurísticos para a otimização automática dos hiperparâmetros da rede.

Por fim, esta dissertação evidencia que a Inteligência Artificial é uma ferramenta indispensável para a maturação da indústria eólica brasileira, transformando dados brutos em inteligência operativa para garantir uma transição energética segura e eficiente.

REFERÊNCIAS

- ABEEÓLICA - Associação Brasileira de Energia Eólica. Relatório, *Boletim anual de geração de energia 2022*. Bela Vista, SP: [s.n.], 2022. <<https://abeeolica.org.br/wp-content/uploads/2023/06/Boletim-de-Geracao-Eolica-2022.pdf>>. Acesso em: 27 nov. 2023.
- ABEEÓLICA - Associação Brasileira de Energia Eólica. *Boletim Anual de Geração Eólica 2023*. São Paulo, 2024. Disponível em: <<https://abeeolica.org.br>>. Acesso em: 27 nov. 2023.
- AK, R.; FINK, O.; ZIO, E. Two machine learning approaches for short-term wind speed time-series prediction. *IEEE transactions on neural networks and learning systems*, IEEE, v. 27, n. 8, p. 1734–1747, 2015.
- ALIYU, M. B. Efficiency of boolean search strings for information retrieval. *American Journal of Engineering Research*, v. 6, n. 11, p. 216–222, 2017.
- ALMEIDA, L. G. de; SCHRODER, L. G. et al. Energia renovável no brasil: Energia eólica como fonte de energia limpa. *Revista Científica Doctum Multidisciplinar*, v. 2, n. 13, 2024.
- ANEEL - Agência Nacional de Energia Elétrica. *Atlas de energia elétrica do Brasil*. Brasília: ANEEL, 2005.
- ARIA, M.; CUCCURULLO, C. bibliometrix: An r-tool for comprehensive science mapping analysis. *Journal of informetrics*, Elsevier, v. 11, n. 4, p. 959–975, 2017.
- BELLO, P. H. D. Trabalho de Conclusão de Curso, *Avaliação de métodos de construção de redes e detecção de comunidades no agrupamento de textos*. São Carlos, SP, Brasil: [s.n.], 2022.
- CAMPOS, E. A. R. de et al. Construction and qualitative assessment of a bibliographic portfolio using the methodology methodi ordinatio. *Scientometrics*, Springer, v. 116, n. 2, p. 815–842, 2018.
- CARVALHO, G. D. G. de et al. Bibliometrics and systematic reviews: A comparison between the proknow-c and the methodi ordinatio. *Journal of Informetrics*, Elsevier, v. 14, n. 3, p. 101043, 2020.
- CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae)? arguments against avoiding rmse in the literature. *Geoscientific Model Development*, v. 7, n. 3, p. 1247–1250, 2014.
- CHEN, T.; GUESTIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. [S.l.: s.n.], 2016. p. 785–794.
- CHEN, X.; KUMAR, P. Standardization of accuracy metrics for wind energy forecasting models. *Renewable Energy Analytics*, v. 22, n. 3, p. 312–330, 2020.

- CHO, K. et al. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.
- COMPUTATION, N. Long short-term memory. *Neural Comput*, v. 9, p. 1735–1780, 2016.
- COP28 - Conferência das Nações Unidas sobre as Mudanças Climáticas de 2023. *Global Renewables and Energy Efficiency Pledge*. 2024a. Disponível em: <<https://www.cop28.com>>. Acesso em: 27 out. 2024.
- COP28 - Conferência das Nações Unidas sobre as Mudanças Climáticas de 2023. *Tripling global renewable energy capacity by 2030 – UAE Consensus*. 2024b. Disponível em: <<https://www.cop28.com>>. Acesso em: 27 out. 2024.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995.
- COSTA, L. M. *Previsão Da Energia Eólica-Santiago-Cabo Verde*. Dissertação (Mestrado) — Universidade do Porto (Portugal), 2013.
- COSTA, R. A. d.; CASOTTI, B. P.; AZEVEDO, R. L. S. d. Um panorama da indústria de bens de capital relacionados à energia eólica. *BNDES Setorial*, Rio de Janeiro, RJ, Brasil, n. 29, p. 229–277, mar. 2009.
- CUNHA, G. S. da et al. Os efeitos adversos da energia eólica no brasil: Uma perspectiva crítica. *Princípios*, v. 43, n. 170, p. 136–155, 2024.
- DRESCH, A.; LACERDA, D. P.; FACIN, A. L. Methodology for systematic literature review in operations management. *Production Planning Control*, v. 26, n. 10, p. 804–814, 2015.
- ENSSLIN, L. et al. Bibliometrics and systematic reviews: A comparison between the proknow-c and the methodi ordinatio. *Journal of Informetrics*, Elsevier, v. 14, n. 3, p. 101043, 2020.
- FARIAS, A. et al. Saúde mental e implantação de parques eólicos: um estudo de caso no semiárido brasileiro. *RESMA*, v. 12, n. 1, p. 154–166, 2021.
- FERNANDEZ, L.; COSTA, A. P.; OLIVEIRA, R. Rainfall impact on wind turbine reliability: A case study in tropical regions. *Renewable Energy*, Elsevier, v. 155, p. 440–450, 2020.
- FLECK, L. et al. Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, v. 1, n. 13, p. 47–57, 2016.
- FOLEY, A. et al. Current methods and advances in forecasting of wind power generation. *Renewable Energy*, v. 37, n. 1, p. 1–8, 2012.
- FRANÇA, C. G. et al. Análise comparativa de modelos de previsão de geração de energia eólica baseados em machine learning. *Revista de Sistemas e Computação-RSC*, v. 9, n. 2, 2020.

- FU, X.; NIU, Z.; YEH, M.-K. Research trends in sustainable operation: a bibliographic coupling clustering analysis from 1988 to 2016. *Cluster Computing*, Springer, v. 19, p. 2211–2223, 2016.
- GANGULY, A.; SINGH, P.; KUMAR, V. Pressure variation and its influence on wind energy generation. *Renewable Energy*, Elsevier, v. 152, p. 1360–1370, 2020.
- GIBSON, J. E.; BROWN, T.; LIN, Y. Dew point analysis and its impact on wind turbine operation. *Atmospheric Research*, Elsevier, v. 196, p. 101–109, 2017.
- GONZALEZ, J.; ZHANG, J. A review of maintenance strategies for wind turbine generators. *Energy*, v. 160, p. 209–220, 2018.
- GWEC - Global Wind Energy Council . *Global Wind Report 2024*. Brussels, 2024. Disponível em: <<https://gwec.net/global-wind-report-2024>> Acesso em: 27 nov. 2023.
- HANIFI, S. et al. A critical review of wind power forecasting methods past, present and future. *Energies*, MDPI, v. 13, n. 15, p. 3764, 2020.
- HAYKIN, S. *Neural Networks and Learning Machines*. 3rd. ed. Upper Saddle River, NJ: Pearson, 2009.
- HIRSCH, J. E. An index to quantify an individual's scientific research output. *Proceedings of the National Academy of Sciences of the United States of America*, v. 102, n. 46, p. 16569–16572, 2005.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, v. 2, n. 5, p. 359–366, 1989.
- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: a new learning scheme of feedforward neural networks. In: IEEE. *2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541)*. [S.l.], 2004. v. 2, p. 985–990.
- IEA - International Energy Agency. *Renewables 2021: Analysis and Forecast to 2026*. 2021. Disponível em: <<https://www.iea.org/reports/renewables-2021>> Acesso em: 22 out. 2024.
- IEA - International Energy Agency. *COP28 commitment to triple renewable energy capacity*. Paris, França, 2024a. Disponível em: <<https://www.iea.org/reports/cop28-tripling-renewable-capacity-pledge>> Acesso em: 1 out. 2024.
- IRENA - International Renewable Energy Agency. *Renewable Power Generation Costs in 2023*. Abu Dhabi, 2024. Disponível em: <<https://www.irena.org/Publications/2024/Sep/Renewable-Power-Generation-Costs-in-2023>> Acesso em: 10 fev. 2025.
- JAHANGIR, H.; JAFARI, M.; AZIZI, A. A review of wind energy forecasting techniques using artificial intelligence. *IEEE Transactions on Industrial Electronics*, 2021.
- JOHNSON, T.; LEE, A. Hybrid models for wind power forecasting using deep learning and statistical methods. *Energy Informatics*, v. 18, n. 2, p. 45–68, 2023.
- KALDELLIS, J.; ZAFIRAKIS, D. The wind energy concept: A review of the recent developments. *Renewable and Sustainable Energy Reviews*, v. 15, n. 1, p. 183–197, 2011.

- KEELE, S. et al. *Guidelines for performing systematic literature reviews in software engineering*. [S.l.], 2007.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: IEEE. *Proceedings of ICNN'95-international conference on neural networks*. [S.l.], 1995. v. 4, p. 1942–1948.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- KUSIAK, A.; ZHENG, H. Optimization of wind turbine design using genetic algorithms. *Renewable Energy*, v. 35, n. 11, p. 2514–2520, 2010.
- LANG, Y. et al. 1. abalos e, duley l, steyn dw, et al. antihypertensive drug therapy for mild to moderate hypertension during pregnancy. *cochrane database syst rev* cd002252, 2001. 2. abboud j, murad y, chen-scarabelli c, saravolatz l. *Medicina Critica en Obstetricia*, v. 108, n. 1039, p. 383, 2006.
- LEWIS, C. D. Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting. *Butterworth-Scientific*, London, 1982.
- LI, L.-L. et al. Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm. *Journal of Cleaner Production*, Elsevier, v. 242, p. 118447, 2020.
- LI, R.; ZHOU, Q.; HAN, J. Solar radiation prediction using deep learning techniques. *Energy*, Elsevier, 2022.
- LIBERATI, A. et al. The prisma statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. *Annals of internal medicine*, American College of Physicians, v. 151, n. 4, p. W-65, 2009.
- LIU, Y.; ZHANG, H.; WANG, Y. Artificial intelligence in wind energy: A review. *Renewable and Sustainable Energy Reviews*, v. 120, p. 109625, 2020.
- LOTKA, A. J. The frequency distribution of scientific productivity. *Journal of the Washington academy of sciences*, JSTOR, v. 16, n. 12, p. 317–323, 1926.
- LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. *Estudos Avançados*, v. 35, p. 85–94, 2021.
- MAKRIDAKIS, S.; HIBON, M. The m3-competition: results, conclusions and implications. *International Journal of Forecasting*, Elsevier, v. 16, n. 4, p. 451–476, 2000.
- MCKENZIE, M. Climate change education and communication in global review: Tracking progress through national submissions to the unfccc secretariat. *Environmental Education Research*, Taylor & Francis, v. 27, n. 5, p. 631–651, 2021.
- MEHTA, Y. et al. A review for green energy machine learning and ai services. *Energies*, MDPI, v. 16, n. 15, p. 5718, 2023.
- MOHER, D. et al. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *PLoS Medicine*, Public Library of Science, v. 6, n. 7, p. e1000097, 2009.

- MOHER, D. et al. Preferred reporting items for systematic review and meta-analysis protocols (prisma-p) 2015 statement. *Systematic reviews*, Springer, v. 4, p. 1–9, 2015.
- NESHAT, M. et al. A deep learning-based evolutionary model for short-term wind speed forecasting: A case study of the lillgrund offshore wind farm. *Energy Conversion and Management*, Elsevier, v. 236, p. 114002, 2021.
- NIELSEN, M. L.; THOMAS, R. H. Relative humidity influence on wind turbine performance. *Journal of Wind Engineering and Industrial Aerodynamics*, Elsevier, v. 181, p. 105–116, 2019.
- OLIVEIRA, L. T. da S.; ARAÚJO, P. H. M. de. Utilização de inteligência computacional para previsão de energia eólica no estado de pernambuco. *Revista Eletrônica da Estácio Recife*, v. 7, n. 2, 2021.
- OLIVEIRA, M. F. d. *Metodologia científica: um manual para a realização de pesquisas em Administração*. Catalão, GO, Brasil: Universidade Federal de Goiás, 2011. 72 p. Manual (pós-graduação).
- PAGANI, R. et al. Methodi ordinatio 2.0: revisited under statistical estimation, and presenting finder and rankin. *Quality & Quantity*, v. 57, n. 5, p. 4563–4602, 2023.
- PAGANI, R. N.; KOVALESKI, J. L.; RESENDE, L. M. Methodi ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. *Scientometrics*, Springer, v. 105, p. 2109–2135, 2015.
- PAGANI, R. N. et al. Methodi ordinatio 2.0: revisited under statistical estimation, and presenting finder and rankin. *Quality & Quantity*, Springer, v. 56, n. 6, p. 4129–4148, 2022.
- PAGANI, R. N.; KOVALESKI, J. L.; RESENDE, L. M. M. de. Avanços na composição da methodi ordinatio para revisão sistemática de literatura. *Ciência da Informação*, v. 46, n. 2, 2017.
- PAGE, M. J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, BMJ Publishing Group Ltd, v. 372, p. n71, 2021.
- PAULA, M. de; COLNAGO, M.; CASACA, W. Redes neurais mlp e narx aplicadas na previsão da velocidade do vento em parques eólicos do estado da bahia. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, v. 7, n. 1, 2020.
- PAVAN, C. *Produção científica do Brasil: relações entre o acesso aberto à informação científica e a política de financiamento público para a publicação de artigos mediante o pagamento de Article Processing Charge (APC)*. Tese (Tese de Doutorado) — Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2018.
- PEI, G. et al. Affective computing: Recent advances, challenges, and future trends. *Intelligent Computing*, AAAS, v. 3, p. 0076, 2024.
- PINHEIRO, L. V. R. Lei de bradford: uma reformulação conceitual. *Ciência da Informação*, Ibict, Brasília, v. 12, n. 2, p. 59–80, 1983.

- PONKUMAR, G.; JAYAPRAKASH, S.; KANAGARATHINAM, K. Advanced machine learning techniques for accurate very-short-term wind power forecasting in wind energy systems using historical data analysis. *Energies*, MDPI, v. 16, n. 14, p. 5459, 2023.
- PORTO, M.; FINAMORE, R.; FERREIRA, H. Injustiças da sustentabilidade: conflitos ambientais relacionados à produção de energia “limpa” no Brasil. *RCCS*, v. 100, n. 1, p. 73–100, 2013.
- REIS, F. C. M. *A análise documentária na representação do conhecimento: estudo bibliométrico da produção científica*. Dissertação (Dissertação de Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil, 2015.
- RIBEIRO, N. F. *Previsão de velocidade do vento com dados reais de um parque eólico localizado no Ceará utilizando redes neurais artificiais: um estudo comparativo das redes MLP, LSTM, GRU e CNN*. 2024. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2024.
- RINGER, N. J. *Desafios do setor de energia eólica no Brasil: uma abordagem sistêmica*. Tese (Doutorado) — Universidade de São Paulo, 2014.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, v. 323, n. 6088, p. 533–536, 1986.
- SHAHID, F. et al. A novel wavenets long short term memory paradigm for wind power prediction. *Applied Energy*, Elsevier, v. 269, p. 115098, 2020.
- SHAHID, F.; ZAMEER, A.; MUNEEB, M. A novel genetic lstm model for wind power forecast. *Energy*, Elsevier, v. 223, p. 120069, 2021.
- SILVA, I. N.; SAPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais: Para Engenharia e Ciências Aplicadas*. São Paulo: Artliber, 2010.
- SILVA, L.; ABRANTES, R. Análise dos ruídos gerados por aerogeradores no complexo eólico canoas e lagoas. In: *Anais do 18^o Enanpur*. Natal: [s.n.], 2019. p. 1–16.
- SILVA, R.; SANTOS, M. Advances in artificial intelligence applications for wind energy forecasting and maintenance. *Journal of Renewable Energy Studies*, v. 15, n. 4, p. 123–145, 2022.
- SINGH, U. et al. A machine learning-based gradient boosting regression approach for wind power production forecasting: A step towards smart grid environments. *Energies*, MDPI, v. 14, n. 16, p. 5196, 2021.
- SÁNCHEZ, A.; MARTÍNEZ, F.; GÓMEZ, J. Temperature effects on wind power generation. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 92, p. 590–607, 2018.
- VEJA. *China aposta na ciência e ganha força como potência de inovação*. 2024. Disponível em: <<https://veja.abril.com.br/tecnologia/china-aposta-na-ciencia-e-ganha-forca-como-potencia-de-inovacao>> Acesso em 22 jun. 2024.
- WALTMAN, L. A review of the literature on citation impact indicators. *Journal of Informetrics*, Elsevier, v. 10, n. 2, p. 365–391, 2016.

- WANG, H.; WANG, J. Short-term wind speed forecasting based on feature extraction by cnn and mlp. *Proceedings of the 2021 2nd International Symposium on Computer Engineering and Intelligent Communications (ISCEIC)*, p. 47, 2021.
- WANG, J. et al. Medium-term wind speeds forecasting utilizing hybrid models for three different sites in xinjiang, china. *Renewable Energy*, Elsevier, v. 76, p. 91–101, 2015.
- WANG, Y. et al. A short-term wind speed forecasting model based on a multi-variable long short-term memory network. *Atmosphere*, MDPI, v. 12, n. 5, p. 651, 2021a.
- WANG, Y. et al. Machine learning techniques in wind energy forecasting: A review. *International Journal of Sustainable Energy*, v. 39, n. 7, p. 234–256, 2021b.
- WANG, Y.; WANG, S.; LIU, H. A review on the prediction of wind energy generation. *Renewable and Sustainable Energy Reviews*, v. 73, p. 173–183, 2017.
- WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate Research*, v. 30, n. 1, p. 79–82, 2005.
- YAO, X.; ZHANG, H. Research on the impact of intelligent algorithms on the renewable energy integration into the smart grid. *Energy Reports*, v. 4, p. 431–438, 2018.
- ZHANG, G. et al. An advanced approach for construction of optimal wind power prediction intervals. *IEEE Transactions on Power Systems*, IEEE, v. 30, n. 5, p. 2706–2715, 2014.
- ZHANG, G.; WANG, J.; WANG, X. Review on probabilistic forecasting of wind power generation. *Renewable and Sustainable Energy Reviews*, 2017.
- ZHANG, G. P.; PATUWO, B. E.; HU, M. Y. Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, v. 14, n. 1, p. 35–62, 1998.
- ZHANG, J. et al. Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and gaussian mixture model. *Applied Energy*, Elsevier, v. 241, p. 229–244, 2019.
- ZHANG, Y.; PAN, G.; CHEN, B. Review of deep learning for wind speed forecasting. *Energy Conversion and Management*, Elsevier, v. 198, p. 111779, 2019.
- ZHAO, Y.; LI, H.; WANG, X. Wind speed and gust variability in turbine optimization. *Applied Energy*, Elsevier, v. 284, p. 115540, 2021.
- ZHENG, J. et al. A hybrid framework for forecasting power generation of multiple renewable energy sources. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 172, p. 113046, 2023.
- ZHOU, J.; ZHANG, Y.; JIANG, H. Forecasting wind power generation using machine learning algorithms: A review. *Applied Energy*, v. 236, p. 963–979, 2019.

APÊNDICE A – Extração de Dados e Fichamento Técnico dos Artigos Selecionados

Tabela A1 – Artigos sobre Previsão de Energia Eólica

ID	ARTICLE	Year of publication	CiteScore	Citations	InOrdinatio
1	SHORT-TERM WIND POWER FORECASTING BASED ON SUPPORT VECTOR MACHINE WITH IMPROVED DRAGONFLY ALGORITHM	2020	9.7	264	324.0097
2	A NOVEL GENETIC LSTM MODEL FOR WIND POWER FORECAST	2021	9.0	237	307.009
3	SHORT-TERM FORECASTING AND UNCERTAINTY ANALYSIS OF WIND TURBINE POWER BASED ON LONG SHORT-TERM MEMORY NETWORK AND GAUSSIAN MIXTURE MODEL	2019	10.1	230	280.0101
4	WIND POWER FORECASTING BASED ON DAILY WIND SPEED DATA USING MACHINE LEARNING ALGORITHMS	2019	9.9	215	265.0099
5	A SURVEY OF DEEP LEARNING TECHNIQUES: APPLICATION IN WIND AND SOLAR ENERGY RESOURCES	2019	3.4	205	255.0034
6	MACHINE-LEARNING METHODS FOR INTEGRATED RENEWABLE POWER GENERATION: A COMPARATIVE STUDY OF ARTIFICIAL NEURAL NETWORKS, SUPPORT VECTOR REGRESSION, AND GAUSSIAN PROCESS REGRESSION	2019	16.3	178	228.0163
7	DIRECT QUANTILE REGRESSION FOR NONPARAMETRIC PROBABILISTIC FORECASTING OF WIND POWER GENERATION	2017	6.5	194	224.0065
8	SHORT-TERM WIND POWER FORECASTING APPROACH BASED ON SEQ2SEQ MODEL USING NWP DATA	2020	9.0	147	207.009
9	REGRESSION TREE ENSEMBLES FOR WIND ENERGY AND SOLAR RADIATION PREDICTION	2019	5.5	153	203.0055

ID	ARTICLE	Year of publication	CiteScore	Citations	InOrdinatio
10	A DEEP LEARNING-BASED EVOLUTIONARY MODEL FOR SHORT-TERM WIND SPEED FORECASTING: A CASE STUDY OF THE LILLGRUND OFFSHORE WIND FARM	2021	9.9	130	200.0099
11	A NOVEL WAVENETS LONG SHORT TERM MEMORY PARADIGM FOR WIND POWER PREDICTION	2020	10.1	111	171.0101
12	INTEGRATED FRAMEWORK OF EXTREME LEARNING MACHINE (ELM) BASED ON IMPROVED ATOM SEARCH OPTIMIZATION FOR SHORT-TERM WIND SPEED PREDICTION	2022	9.9	82	162.0099
13	WIND SPEED PREDICTION USING A HYBRID MODEL OF THE MULTI-LAYER PERCEPTRON AND WHALE OPTIMIZATION ALGORITHM	2020	4.7	100	160.0047
14	DEEP LEARNING-BASED FORECASTING APPROACH IN SMART GRIDS WITH MICROCLUSTERING AND BIDIRECTIONAL LSTM NETWORK	2021	7.5	89	159.0075
15	EFFICIENT BOOTSTRAP STACKING ENSEMBLE LEARNING MODEL APPLIED TO WIND POWER GENERATION FORECASTING	2022	5.0	76	156.005
16	DETERMINISTIC AND PROBABILISTIC INTERVAL PREDICTION FOR SHORT-TERM WIND POWER GENERATION BASED ON VARIATIONAL MODE DECOMPOSITION AND MACHINE LEARNING METHODS	2016	9.9	134	154.0099
17	A HYBRID FRAMEWORK FOR FORECASTING POWER GENERATION OF MULTIPLE RENEWABLE ENERGY SOURCES	2023	16.3	63	153.0163
18	WIND POWER PREDICTION USING A NOVEL MODEL ON WAVELET DECOMPOSITION-SUPPORT VECTOR MACHINES-IMPROVED ATOMIC SEARCH ALGORITHM	2020	9.7	91	151.0097
19	THE STUDY AND APPLICATION OF A NOVEL HYBRID FORECASTING MODEL - A CASE STUDY OF WIND SPEED FORECASTING IN CHINA	2015	10.1	140	150.0101

ID	ARTICLE	Year of publication	CiteScore	Citations	InOrdinatio
20	WIND SPEED FORECASTING APPROACH BASED ON SINGULAR SPECTRUM ANALYSIS AND ADAPTIVE NEURO FUZZY INFERENCE SYSTEM TEMPORAL-SPATIAL DISTRIBUTION OF WAVE ENERGY: A CASE STUDY OF BEIBU GULF, CHINA	2018	18.4	109	149.0184
21	ENSEMBLE WIND SPEED FORECASTING WITH MULTI-OBJECTIVE ARCHIMEDES OPTIMIZATION ALGORITHM AND SUB-MODEL SELECTION	2021	10.1	77	147.0101
22	MACHINE LEARNING-BASED DIGITAL TWIN FOR PREDICTIVE MODELING IN WIND TURBINES	2022	3.4	57	137.0034
23	FORECASTING ENERGY DEMAND, WIND GENERATION AND CARBON DIOXIDE EMISSIONS IN IRELAND USING EVOLUTIONARY NEURAL NETWORKS	2018	9.0	94	134.009
24	WIND, SOLAR, AND PHOTOVOLTAIC RENEWABLE ENERGY SYSTEMS WITH AND WITHOUT ENERGY STORAGE OPTIMIZATION: A SURVEY OF ADVANCED MACHINE LEARNING AND DEEP LEARNING TECHNIQUES	2022	3.0	54	134.003
25	SCADA DATA BASED WIND POWER INTERVAL PREDICTION USING LUBE-BASED DEEP RESIDUAL NETWORKS	2022	2.6	54	134.0026
26	HYBRID FORECASTING SYSTEM BASED ON AN OPTIMAL MODEL SELECTION STRATEGY FOR DIFFERENT WIND SPEED FORECASTING PROBLEMS	2019	10.1	83	133.0101
27	MEDIUM-TERM WIND SPEEDS FORECASTING UTILIZING HYBRID MODELS FOR THREE DIFFERENT SITES IN XINJIANG, CHINA	2015	9.0	123	133.009
28	A MACHINE LEARNING-BASED GRADIENT BOOSTING REGRESSION APPROACH FOR WIND POWER PRODUCTION FORECASTING: A STEP TOWARDS SMART GRID ENVIRONMENTS	2021	3.0	62	132.003
29	A HYBRID ATTENTION-BASED DEEP LEARNING APPROACH FOR WIND POWER PREDICTION	2022	10.1	50	130.0101

ID	ARTICLE	Year of publication	CiteScore	Citations	InOrdinatio
30	WIND SPEED FORECASTING APPROACH BASED ON SINGULAR SPECTRUM ANALYSIS AND ADAPTIVE NEURO FUZZY INFERENCE SYSTEM	2018	9.0	90	130.009
31	RIDGE REGRESSION ENSEMBLE OF MACHINE LEARNING MODELS APPLIED TO SOLAR AND WIND FORECASTING IN BRAZIL AND SPAIN	2022	10.1	46	126.0101
32	A SURVEY OF COMPUTATIONAL INTELLIGENCE TECHNIQUES FOR WIND POWER UNCERTAINTY QUANTIFICATION IN SMART GRIDS	2020	10.2	65	125.0102
33	BOOSTED GRU MODEL FOR SHORT-TERM FORECASTING OF WIND POWER WITH FEATURE-WEIGHTED PRINCIPAL COMPONENT ANALYSIS	2023	9.0	35	125.009
34	DATA-DRIVEN INTERPRETABLE ENSEMBLE LEARNING METHODS FOR THE PREDICTION OF WIND TURBINE POWER INCORPORATING SHAP ANALYSIS	2024	7.5	25	125.0075
35	EFFICIENT WIND POWER PREDICTION USING MACHINE LEARNING METHODS: A COMPARATIVE STUDY	2022	3.0	45	125.003
36	TWO MACHINE LEARNING APPROACHES FOR SHORT-TERM WIND SPEED TIME-SERIES PREDICTION	2016	10.2	103	123.0102
37	A NONPARAMETRIC BAYESIAN FRAMEWORK FOR SHORT-TERM WIND POWER PROBABILISTIC FORECAST	2019	6.5	70	120.0065
38	ULTRA-SHORT-TERM WIND POWER FORECASTING BASED ON DEEP BAYESIAN MODEL WITH UNCERTAINTY	2023	9.0	29	119.009
39	METHODOLOGICAL FRAMEWORK FOR SHORT-AND MEDIUM-TERM ENERGY, SOLAR AND WIND POWER FORECASTING WITH STOCHASTIC-BASED MACHINE LEARNING APPROACH TO MONETARY AND ENERGY POLICY APPLICATIONS	2021	9.0	45	115.009
40	PROBABILISTIC WIND-POWER FORECASTING USING WEATHER ENSEMBLE MODELS	2018	4.2	75	115.0042

ID	ARTICLE	Year of publication	CiteScore	Citations	InOrdinatio
41	A NEW ANN MODEL FOR HOURLY SOLAR RADIATION AND WIND SPEED PREDICTION: A CASE STUDY OVER THE NORTH & SOUTH OF THE ARABIAN PENINSULA	2021	7.1	44	114.0071
42	AN IMPUTATION AND DECOMPOSITION ALGORITHMS BASED INTEGRATED APPROACH WITH BIDIRECTIONAL LSTM NEURAL NETWORK FOR WIND SPEED PREDICTION	2023	9.0	23	113.009
43	SELF-ADAPTIVE DISCRETE GREY MODEL BASED ON A NOVEL FRACTIONAL ORDER REVERSE ACCUMULATION SEQUENCE AND ITS APPLICATION IN FORECASTING CLEAN ENERGY POWER GENERATION IN CHINA	2022	9.0	32	112.009
44	VERY SHORT-TERM WIND POWER DENSITY FORECASTING THROUGH ARTIFICIAL NEURAL NETWORKS FOR MICROGRID CONTROL	2020	9.0	52	112.009
45	TOWARDS EFFICIENT AND EFFECTIVE RENEWABLE ENERGY PREDICTION VIA DEEP LEARNING	2022	4.7	32	112.0047
46	MEDIUM-TERM WIND POWER FORECASTING BASED ON MULTI-RESOLUTION MULTI-LEARNER ENSEMBLE AND ADAPTIVE MODEL SELECTION	2020	9.9	50	110.0099
47	ENHANCING WIND SPEED FORECASTING THROUGH SYNERGY OF MACHINE LEARNING, SINGULAR SPECTRAL ANALYSIS, AND VARIATIONAL MODE DECOMPOSITION	2024	9.0	10	110.009
48	IMPROVING SOLAR FORECASTING USING DEEP LEARNING AND PORTFOLIO THEORY INTEGRATION	2020	9.0	50	110.009
49	A NOVEL APPROACH TO MULTI-HORIZON WIND POWER FORECASTING BASED ON DEEP NEURAL ARCHITECTURE	2021	9.0	40	110.009
50	AN ADVANCED APPROACH FOR CONSTRUCTION OF OPTIMAL WIND POWER PREDICTION INTERVALS	2020	0.0	83	87.0067

Tabela A2 – Extração de Dados da RSL: Parâmetros Técnicos e Operacionais por Artigo.

ID	Metodologia Principal	Horizonte	Métricas	Cenário de Melhor Ajuste e Indicação Técnica
1	SVM	Curto Prazo	MAE, MAPE, RMSE	Otimização de parâmetros para operação estável em 48h.
2	LSTM + GA (<i>Genetic Algorithm</i>)	Curto Prazo	RMSE, MAE, R^2	Séries com alta volatilidade e necessidade de memória temporal.
3	LSTM + GMM	Curto Prazo	MAE, RMSE	Quantificação de incerteza para segurança de rede elétrica.
4	XGBoost, SVR	Curto Prazo	MAE, RMSE	Planejamento operacional diário e benchmarking de modelos.
5	Survey (DL: MLP , LSTM)	Médio Prazo	MSE, RMSE, MAE, MAPE, R^2	Referência teórica para arquiteturas de redes profundas.
6	ANN, SVR	Médio Prazo	RMSE, MAE	Comparativo entre modelos clássicos e processos gaussianos.
7	ELM	Longo Prazo	PINAW (Prediction Interval Normalized Average Width), PICP (Prediction Interval Coverage Probability)	Previsão de intervalos para reserva de potência do sistema.
8	<i>Deep Learning</i>	Curto Prazo	MAPE, RMSE	Integração intensiva de dados meteorológicos (NWP).
9	Ensemble (XGBoost, SVR, MLP)	Curto Prazo	MAPE, RMSE	Parques híbridos; mitigação de erros de modelos individuais.
10	Bi-LSTM	Curto Prazo	MAE, MAPE	Aplicação específica em parques offshore (Ex: Lillgrund).

Continua na próxima página

ID	Metodologia Principal	Horizonte	Métricas	Cenário de Melhor Ajuste e Indicação Técnica
11	WN-LSTM (<i>Wavelet</i>)	Curto Prazo	RMSE, MAE	Filtragem de ruído em sinais eólicos altamente instáveis.
12	ELM	Curto Prazo	MAE, RMSE	Treinamento ultra-rápido com otimização atômica.
13	Rede MLP	Curto Prazo	MAE, MAPE	Ideal para o Semiárido: Rápida convergência e eficácia.
14	Bi-LSTM + Clusterização	Curtíssimo Prazo	RMSE, MAE	Gestão de micro-redes e agrupamentos de carga local.
15	<i>Bootstrap Stacking</i>	Curto Prazo	MAE, RMSE	Estabilização de previsões via múltiplos regressores.
16	IA	Curto Prazo	PICP, PINAW	Decomposição modal para sinais não-estacionários ruidosos.
17	Híbrido Multivariado	Médio Prazo	MAE, RMSE	Gestão de sistemas com múltiplas fontes renováveis limpas.
18	<i>Wavelet</i> + SVM	Curto Prazo	MAE, RMSE	Refinamento de sinal via decomposição <i>Wavelet</i> e SVR.
19	Híbrido	Curto Prazo	MAPE, RMSE	Escolha do modelo ótimo conforme o terreno geográfico.
20	SSA (Sparrow Search Algorithm) + ANFIS (Adaptive Neuro-Fuzzy Inference System)	Curto Prazo	RMSE, MAE	Extração de tendência sazonal e ciclo em vento ruidoso em séries complexas.
21	<i>Ensemble</i>	Curto Prazo	MAE, RMSE	Seleção de sub-modelos via algoritmos de otimização física.

Continua na próxima página

ID	Metodologia Principal	Horizonte	Métricas	Cenário de Melhor Ajuste e Indicação Técnica
22	<i>Digital Twin</i> + Machine Learning	Médio Prazo	RMSE, MAE	Manutenção preditiva e monitorização digital de turbinas.
23	Evolutionary NN (<i>Neural Network</i>) (MLP)	Curto Prazo	MAE, RMSE	Impacto ambiental e energético integrado (Emissões CO ₂).
24	<i>Survey</i> (ML/DL)	Médio Prazo	RMSE, MAE, R^2	Gestão de baterias e micro-redes inteligentes com storage.
25	DRN (<i>Deep Residual Networks</i>)	Curto Prazo	PICP, PINAW	Intervalos de confiança via dados brutos de sensores SCADA.
26	Seleção Adaptativa	Curto Prazo	MAE, RMSE	Identificação da arquitetura ideal por base de dados local.
27	SVR + Elman NN	Médio Prazo	MAPE, MSE	Previsão para períodos de dias em climas áridos.
28	<i>Gradient Boosting</i>	Curto Prazo	MAE, RMSE	Eficiência energética e resposta à procura em <i>Smart Grids</i> .
29	<i>Deep Learning</i>	Curto Prazo	MAE, MAPE	Redução de ruído via mecanismos de atenção neural profunda.
30	SSA + ANFIS (Brazil)	Curto Prazo	MAE, RMSE	Tratamento de periodicidade ruidosa em parques brasileiros.
31	<i>Ridge Ensemble</i> (MLP)	Curto Prazo	MAPE, MRE	Validação em Pernambuco: Redução de erro comprovada.
32	<i>Survey</i>	Médio Prazo	N/A	Quantificação de incerteza em Redes Elétricas Inteligentes.

Continua na próxima página

ID	Metodologia Principal	Horizonte	Métricas	Cenário de Melhor Ajuste e Indicação Técnica
33	<i>Boosted GRU</i>	Curto Prazo	MAE, RMSE	Redução de dimensionalidade para ganho de velocidade.
34	<i>Ensemble + SHAP (SHapley Additive exPlanations)</i>	Curto Prazo	SHAP Value	IA Explicável: Transparência total nas decisões do modelo.
35	<i>Comparative Machine Learning</i>	Curto Prazo	MAE, MAPE	<i>Benchmarking</i> entre SVR e Redes Neurais.
36	IA	Curtíssimo Prazo	RMSE, MAE	Resposta rápida para balanço de carga em minutos.
37	<i>Bayesian Framework</i>	Longo Prazo	CRPS (Continuous Ranked Probability Score), MAE	Gestão de riscos operacionais baseada em estatística.
38	<i>Deep Bayesian</i>	Curtíssimo Prazo	MAE, RMSE	Integração de <i>Deep Learning</i> com incerteza <i>bayesiana</i> .
39	<i>Stochastic Machine Learning</i>	Médio Prazo	MAE, RMSE	Suporte a decisões de políticas energéticas e monetárias.
40	<i>Weather Ensembles</i>	Curto Prazo	MAE, RMSE	Robustez via uso de múltiplos modelos climáticos.
41	Rede MLP (ANN)	Curtíssimo Prazo	MAE, RMSE	Estudo em climas desérticos; previsão solar-eólica.
42	Bi-LSTM + Imputação	Curto Prazo	MAE, RMSE	Tratamento de falhas e dados perdidos de sensores.
43	<i>Grey Model</i>	Curto Prazo	MAE, MAPE	Modelagem eficiente para pequenos conjuntos de dados.
44	Rede MLP (ANN)	Curtíssimo Prazo	MAE, MAPE	Controle de micro-redes e densidade de potência local.

Continua na próxima página

ID	Metodologia Principal	Horizonte	Métricas	Cenário de Melhor Ajuste e Indicação Técnica
45	<i>Survey (Deep Learning)</i>	Médio Prazo	RMSE, MAE, MAPE, R^2	Eficácia de CNNs e RNNs na transição energética global.
46	<i>Multi-resolution</i>	Médio Prazo	MAE, RMSE	Planejamento via escalas de tempo múltiplas de vento.
47	SSA + <i>Machine Learning</i>	Curto Prazo	MAE, RMSE	Filtragem tripla de sinal para séries temporais complexas.
48	<i>Deep Learning</i> + Portfólio	Curto Prazo	MAPE, MAE	Minimização de riscos financeiros via modelos combinados.
49	<i>Deep Learning</i>	Curto, Médio e Longo Prazo	SMAPE, MAE	Previsão profunda pura sem necessidade de variáveis exógenas.
50	Construção de intervalos de previsão	Curto Prazo	PICP, PINAW	Segurança operacional crítica da rede de transmissão.

APÊNDICE B – Guia de Referência: Matriz de Decisão Metodológica

Este apêndice apresenta o produto tecnológico desenvolvido a partir da Revisão Sistemática da Literatura. A Matriz de Decisão (Tabela B1) foi desenhada para orientar operadores do Operador Nacional do Sistema (ONS) e gestores de parques eólicos na escolha da arquitetura de IA mais adequada para cada cenário operacional.

A matriz correlaciona as características físicas do vento (regime, relevo e horizonte) com a arquitetura computacional que apresentou o melhor *trade-off* entre precisão e custo nos 50 artigos analisados.

Tabela B1 – Matriz de Decisão Metodológica para Previsão de Geração Eólica.

Cenário Operacional	Características do Vento	Horizonte Recomendado	Arquitetura Recomendada	Justificativa Técnica (Baseada na RSL)	Custo Computacional
1. Micro-redes e Parques Onshore (Pernambuco)	Ventos com alta persistência, baixa turbulência e forte sazonalidade diária.	Curto Prazo (1h a 24h)	MLP (Multilayer Perceptron)	IDs 13, 31, 44: Em regimes estáveis, a MLP converge rapidamente e iguala a precisão de redes profundas, sem o risco de <i>overfitting</i> comum em LSTMs para dados simples.	Baixo (Ideal para tempo real)
2. Parques Offshore e Complexos Híbridos	Alta volatilidade, mudanças abruptas de direção (ramp events) e não-linearidade extrema.	Curto a Médio Prazo (6h a 48h)	LSTM / GRU (Recorrentes)	IDs 02, 10: A capacidade de memória ("celular") é indispensável para capturar dependências temporais longas e prever quedas bruscas de geração.	Alto (Exige GPUs dedicadas)
3. Novos Parques (Sem Histórico)	Séries temporais curtas (< 1 ano) ou dados com falhas de medição.	Curtíssimo Prazo (10min a 1h)	SVR (Support Vector Regression)	O SVR baseia-se na minimização do risco estrutural, performando melhor que Redes Neurais quando a amostra de treinamento é insuficiente (pequena base de dados).	Médio
4. Despacho Regional (Sistema Interligado)	Interação entre múltiplas variáveis (vento, temperatura, pressão) de diferentes estações.	Médio Prazo (24h a 72h)	Ensembles (Híbridos)	ID 31: A combinação de decomposição de sinal (Wavelet/SSA) + MLP/LSTM reduz o ruído da série, aumentando a robustez para o despacho de carga agregado.	Muito Alto (Processamento Offline)

Legenda: MLP: *Multilayer Perceptron*; LSTM: *Long Short-Term Memory*; SVR: *Support Vector Regression*.

Fonte: Elaborada pela autora com base nos dados da RSL (2026).