

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO CENTRO TECNOLÓGICO

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AMBIENTAL

PEDRO JUNIOR ZUCATELLI

METODOLOGIA HÍBRIDA PARA PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA PARA CURTO E MÉDIO PRAZO UTILIZANDO INTELIGÊNCIA COMPUTACIONAL EM REGIÃO TROPICAL E SUBTROPICAL

VITÓRIA 2021

METODOLOGIA HÍBRIDA PARA PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA PARA CURTO E MÉDIO PRAZO UTILIZANDO INTELIGÊNCIA COMPUTACIONAL EM REGIÃO TROPICAL E SUBTROPICAL

Tese apresentada ao Programa de Pós-Graduação em Engenharia Ambiental do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do título de Doutor em Engenharia Ambiental na área de concentração Poluição do Ar e linha de pesquisa Energia.

Orientador: Prof. Dr. Davidson Martins Moreira.

Coorientador: Prof. Dr. Erick Giovani Sperandio Nascimento.

VITÓRIA 2021

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

Zucatelli, Pedro Junior, 1989-Z94m Metodologia híbrida para previsão da geração de energia eólica para curto e médio prazo utilizando inteligência computacional em região tropical e subtropical / Pedro Junior Zucatelli. - 2021. 273 f. : il. Orientador: Davidson Martins Moreira. Coorientador: Erick Giovani Sperandio Nascimento. Tese (Doutorado em Engenharia Ambiental) - Universidade Federal do Espírito Santo, Centro Tecnológico. 1. Energia eólica. 2. Redes neurais. 3. Inteligência artificial. 4. Engenharia ambiental. 5. Wavelets (Matemática). 6. Atmosfera. I. Moreira, Davidson Martins. II. Nascimento, Erick Giovani Sperandio. III. Universidade Federal do Espírito Santo. Centro Tecnológico. IV. Título.

CDU: 628

PEDRO JUNIOR ZUCATELLI

METODOLOGIA HÍBRIDA PARA PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA PARA CURTO E MÉDIO PRAZO UTILIZANDO INTELIGÊNCIA COMPUTACIONAL EM REGIÃO TROPICAL E SUBTROPICAL

Tese apresentada ao Programa de Pós-Graduação em Engenharia Ambiental do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do título de Doutor em Engenharia Ambiental na área de concentração Poluição do Ar e linha de pesquisa Energia.

Aprovada em 21 de maio de 2021.

Professor Dr. Davidson Martins Moreira. Universidade Federal do Espírito Santo – UFES e SENAI CIMATEC – Bahia. Orientador.

Professor Dr. Neyval Costa Reis Júnior. Universidade Federal do Espírito Santo – UFES. Examinador Interno, PPGEA/UFES.

Professor Dr. Alejandro Mauricio Gutiérrez Arce. Universidad de la República (UdelaR) – FING – IMFIA. Uruguay. Examinador Externo ao PPGEA.

COMISSÃO EXAMINADORA:

Professor Dr. Erick Giovani Sperandio Nascimento. SENAI CIMATEC – Bahia. Coorientador.

Professora Dra. Ana Paula Meneguelo. Universidade Federal do Espírito Santo – UFES. Examinador Interno, PPGEN/UFES.

Professor Dr. Alex Álisson Bandeira Santos. SENAI CIMATEC – Bahia. Examinador Externo ao PPGEA.

Coordenador do PPGEA: Prof. Dr. Diogo Costa Buarque. Universidade Federal do Espírito Santo – UFES.

DEDICATÓRIA

Dedico esta tese à Deus, aos meus queridos pais Pedro e Fatima, à minha estimada irmã Daniely, aos meus amigos, familiares, meu orientador Prof. Dr. Davidson M. Moreira e coorientador Prof. Dr. Erick G. S. Nascimento, e a todos os meus estimados professores que sempre me incentivaram durante a jornada acadêmica a qual fui submetido na UFES para a realização deste sonho.

AGRADECIMENTOS

A Deus Pai todo poderoso, a Jesus Cristo e a Nossa Senhora das Graças, por sempre ouvirem minhas orações, por me concederem sabedoria, saúde e iluminarem a minha inteligência. "E tudo o que vocês na oração pedirem com fé, vocês receberão" (Bíblia Sagrada: Mateus 21, 22). Aos meus familiares, em especial aos meus pais, Pedro e Fatima, e à minha irmã, Daniely, por acreditarem em mim, pelo constante apoio, amor, carinho e generosidade durantes os anos de estudos e pesquisas. Ao meu avô Geraldo Souto por sempre me abençoar em oração. Agradeço também ao meu primo Murilo Zucatelli Elias pela companhia e estadia em Vitória durante os estudos presenciais na UFES campus Goiabeiras, e a minha amiga Regina Celia Pansiere Uliana pela verdadeira amizade, orações, incentivos e abraços que recebi ao longo desta jornada de muitos estudos.

À Universidade Federal do Espírito Santo – UFES, ao Centro Tecnológico – CT e ao CEUNES por me concederem um ensino gratuito e de qualidade. Ao SENAI CIMATEC de Salvador – Bahia, em especial, pelo apoio educacional e financeiro prestado durante esses quatro anos de muitas pesquisas e estudos. Meus sinceros agradecimentos pelas contribuições científicas ao Professor Dr. Alex Álisson Bandeira Santos do SENAI CIMATEC. Ao Professor Dr. Alejandro Mauricio Gutiérrez Arce, à UTE (*La Administración Nacional de Usinas y Trasmisiones Eléctricas*) e ao Sistema FIEB pelo fornecimento dos dados meteorológicos do Uruguai e Bahia, respectivamente.

Ao meu orientador Prof. Dr. Davidson Martins Moreira e coorientador Prof. Dr. Erick Giovani Sperandio Nascimento pela amizade, ensinamentos, orientações e apoio científico prestado incansavelmente ao longo destes quatro anos de muitos estudos, pesquisas e escritas de artigos científicos. Aos meus estimados professores, doutores da UFES, em especial a professora Dra. Ana Paula Meneguelo (minha orientadora de graduação e mestrado) por sempre ter me incentivado nos estudos, ao Prof. Dr. Luís O. Rigo Jr. e ao Prof. Dr. Leonardo José Silvestre pelos ensinamentos técnicos e aulas ministradas sobre Inteligência Computacional no início do doutorado. Ao Prof. Dr. Antônio José da Silva Neto por ter participado da qualificação desta tese. Ao Prof. Dr. Neyval Costa Reis Jr. por ter aceitado ser o supervisor da tese e por lutar pelo desenvolvimento científico do PPGEA UFES com importantes projetos. A todos professores do PPGEA, registo o meu agradecimento.

A todos meus amigos e colegas, em especial, agradeço aos amigos Lucas Salvalaio e Breno Pereira (por terem me incentivado tanto enquanto morávamos na república em São Mateus), ao Élcio Dias Junior por sempre me encorajar a desbravar o desconhecido e sempre dizer que eu era capaz; ao Arnon Soares e Cíntia Cassa pela irmandade; Mariana Lima e Ciara Barcelos Zanelato pelo companheirismo de sempre; Georgynio Yossimar Rosales Aylas, Noéle Perini, Yasmin Kaore, Anusio Menezes Correia pelo apoio e amizade compartilhando momentos fantásticos; Thais Sena e Rener Hemerson por todo carinho e palavras de motivação; Nayara La-Gatta, Akemi Moscon Yoshitome e Bárbara Paulo Moraes por terem me apoiado e ajudado sem medirem esforços como verdadeiras amigas durante e após nossa vida de estudante; Sandrélia Cerutti Carminati, Elen Karla Trés e Josete Pertel (estes três últimos representando a Faculdade Multivix a qual me deu a oportunidade de ser docente), eu registro o meu muito obrigado pela força e pelo incentivo durante os estudos e as pesquisas deste doutorado. Há muito mais a quem agradecer.

Finalizo agradecendo a todos que me encorajaram nessa caminhada acadêmica. A todos aqueles que, embora não nomeados ou que já partiram desta vida e foram morar com Deus, me brindaram com inestimável apoio em distintas circunstâncias e pela presença afetiva em inesquecíveis momentos, o meu reconhecimento e carinhoso: MUITO OBRIGADO!

"Como grãos de areia que compõe imensas dunas, como pequenas gotas que formam as chuvas, gestos de fé, gratidão, compreensão, ternura e respeito são partes de um amor maior".

Fiquem felizes, pois todos vocês são coautores desta tese de doutorado! Grande abraço! Atenciosamente, Pedro Junior Zucatelli.

> Vitória – ES, Brasil 2021

EPÍGRAFE

"O trabalho do francês Yves Meyer não pode ser rotulado como matemática pura ou aplicada, nem ciência da computação, mas simplesmente como algo incrível". (Stéphane Mallat, colaborador de Yves Meyer na teoria das Wavelets)

> "Deus é como o vento que tudo toca". (Filme: O menino que descobriu o vento)

"Of all the forces of nature, I should think the wind contains the greatest amount of power". (Abraham Lincoln)

RESUMO

Sabe-se que um dos principais constituintes da sociedade moderna é a energia, sendo-a necessária para se criar bens de consumo baseados em recursos naturais e para suprir muitos dos serviços com os quais o ser humano tem se favorecido. É fato que a partir da primeira revolução industrial registrou-se um aumento exponencial das emissões dos gases de afeito estufa para a atmosfera potencializando o aquecimento global e, por consequência, as mudanças climáticas, poluição do ar e os problemas de saúde. Portanto, justificam-se os estudos científicos aplicados às tecnologias sustentáveis para garantir a qualidade e aumentar a geração de energia proveniente de fontes alternativas afim de suprir esta demanda. Inserido neste contexto, a energia eólica é uma alternativa sustentável em pleno desenvolvimento no Brasil e no Uruguai, sítios estes que contemplaram esta pesquisa sobre a previsão da geração de energia eólica para curto e médio prazo utilizando modelo híbrido baseado em inteligência computacional e decomposição Wavelet. O objetivo geral deste estudo foi avaliar e implementar melhorias na previsão da geração de energia eólica a curto e médio prazo, 1 h a 168 h à frente, em resolução espacial de microescala usando metodologia advinda de simulação computacional aplicando aprendizado de máquina supervisionado via redes neurais artificiais e a decomposição de sinais temporais por meio das transformadas Wavelets. Tal esforço visou atender à carência neste assunto e à demanda do setor de produção e distribuição de energia elétrica no Brasil e no Uruguai, com a finalidade de possibilitar uma melhoria no aproveitamento da energia eólica nos empreendimentos atuais e em futuros projetos de exploração, produção e comercialização desta fonte de energia. Ressalta-se que este modelo híbrido de previsão originou um ferramental de baixo custo computacional destinado a fornecer tais previsões às concessionárias, geradoras e distribuidoras de energia elétrica e, inclusive, aos operadores do sistema elétrico. Os resultados alcançados nesta pesquisa provaram que a função Wavelet discreta Meyer dentre 48 funções estudadas tem menor erro associado para aplicação da filtragem e decomposição dos sinais de velocidade do vento, se tornando a mais eficiente para tal aplicação, e a utilização destes dados filtrados na alimentação das redes neurais recorrentes foi eficaz para previsão da velocidade do vento e potência de saída a médio prazo e previsão do fenômeno de rampa de energia eólica a curto prazo em região tropical e subtropical.

Palavras – chave: Ciências da Computação; Energia Renovável; Engenharia Ambiental; Inteligência Computacional; Simulação Computacional; Redes Neurais Artificiais.

ABSTRACT

It is known that one of the main constituents of modern society is energy, which is necessary to create consumer goods based on natural resources and to supply many of the services that human beings have favored. It is a fact that since the first industrial revolution there has been an exponential increase in emissions of greenhouse gases into the atmosphere, potentiating global warming and, consequently, climate change, air pollution, and health problems. Therefore, scientific studies applied to sustainable technologies are justified to guarantee quality and increase the generation of energy from alternative sources to supply this demand. Inserted in this context, wind energy is a sustainable alternative in full development in Brazil and Uruguay, sites that contemplated this research on the short-term and medium-term wind power forecasting using a hybrid model based on computational intelligence and wavelet decomposition. The general objective of this study was to evaluate and implement improvements in the forecast of wind power generation in the short and medium-term, 1 h to 168 h ahead, in microscale spatial resolution using computational simulation methodology applying supervised machine learning by artificial neural network and the decomposition of temporal signals using Wavelets transform. This effort aimed to meet the shortage in this matter and the demand of the electric energy production and distribution sector in Brazil and Uruguay, to enable an improvement in the use of wind power in current projects and future exploration, production, and commercialization of this energy source. It is noteworthy that this hybrid forecasting model originated a low computational cost tool designed to provide such forecasts to electric energy concessionaires, generators and distributors, and even to the electric system operators. The results achieved in this research proved that the discrete Meyer wavelet function among 48 studied functions has less associated error for the application of filtering and decomposition of wind speed signals, becoming the most efficient for such application, and the use of these filtered data in the feed of recurrent neural networks it was effective for mediumterm wind speed forecasting and medium-term wind power forecasting, and short-term wind power ramp forecasting in tropical and subtropical sites.

Keywords: Computer Science; Renewable Energy; Environmental Engineering; Computational Intelligence; Computational Simulation; Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1: Concentração global média de CO2 na atmosfera no período de 1959 a 202017
Figura 2: Capacidade instalada e número de parques eólicos por estado brasileiro19
Figura 3: Dispersão dos dados preditos para 1 h à frente
Figura 4: Dispersão dos dados preditos para 12 h à frente31
Figura 5: As camadas da Atmosfera Terrestre
Figura 6: Estrutura da Troposfera, evidenciando a localização da Camada Limite Planetária e
da Atmosfera Livre
Figura 7: Circulação atmosférica idealizada
Figura 8: Perfil vertical da velocidade do vento40
Figura 9: Famílias Wavelets discretas50
Figura 10: Relação entre inteligência computacional ou artificial, aprendizado de máquina e
aprendizado profundo
Figura 11: Tipos de aprendizado de máquina57
Figura 12: Modelo matemático simples de um neurônio
Figura 13: RNA do tipo <i>multilayer perceptron</i> 61
Figura 14: RNN do tipo <i>multilayer perceptron</i> 62
Figura 15: Fluxograma das etapas para previsão usando RNA via aprendizado de máquina
supervisionado64
Figura 16: Esquema da rede LSTM e sua célula de memória67
Figura 17: Arquitetura da Rede GRU68
Figura 18: Exemplo de topologia da rede neural convolucional70
Figura 19: Exemplo de convolução matemática70
Figura 20: Estrutura do setor de energia elétrica no Brasil72
Figura 21: Preço horário calculado pela CCEE para dia 18/01/202174
Figura 22: Localização das torres anemométricas na Bahia, Nordeste brasileiro
Figura 23: Localização da torre anemométrica de Colônia Eulacio, em Soriano, no Uruguai.91
Figura 24: Série temporal da velocidade do vento em Espanada, a) 100 m, b) 120 m, c) 150 m.
Figura 25: Distribuição normal da velocidade do vento em Espanada, a) 100 m, b) 120 m, c)
150 m

Figura 26: Série temporal da velocidade do vento em Mucugê, a) 100 m, b) 120 m, c) 150 m. Figura 27: Distribuição normal da velocidade do vento em Mucugê, a) 100 m, b) 120 m, c) 150 Figura 28: Série temporal da velocidade do vento em Mucuri, a) 100 m, b) 120 m, c) 150 m. Figura 29: Distribuição normal da velocidade do vento em Mucuri, a) 100 m, b) 120 m, c) 150 Figura 30: Série temporal da velocidade do vento em Colônia Eulacio, a) 81.8 m, b) 101.8 m. Figura 31: Distribuição normal da velocidade do vento em Colônia Eulacio, a) 81,8 m, b) 101,8 Figura 32: Função densidade de probabilidade para a) Esplanada, b) Mucugê, c) Mucuri e d) Figura 33: Metodologia para modelagem e simulação com planejamento e divisão das etapas Figura 34: Base da torre anemométrica de 150 m localizada em Esplanada, Bahia – Brasil. 106 Figura 35: Vista superior da torre anemométrica de 150 m localizada em Esplanada, Bahia -Figura 36: Imagem da torre anemométrica e seu entorno, localizada em Colônia Eulacio, no Figura 38: Análise estatística RMSE entre a velocidade do vento medida e predita a médio Figura 39: Análise estatística Fator de 2 entre a velocidade do vento medida e predita a médio Figura 40: Análise estatística RMSE entre a velocidade do vento medida e predita a médio Figura 41: Análise estatística Fator de 2 entre a velocidade do vento medida e predita a médio Figura 42: Análise estatística RMSE entre a velocidade do vento medida e predita a médio Figura 43: Análise estatística Fator de 2 entre a velocidade do vento medida e predita a médio

Figura 44: Análise estatística RMSE entre a velocidade do vento medida e predita a médio
prazo para sítio de Colônia Eulacio, Soriano – Uruguai
Figura 45: Análise estatística Fator de 2 entre a velocidade do vento medida e predita a médio
prazo para sítio de Colônia Eulacio, Soriano – Uruguai
Figura 46: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e
predita a médio prazo para sítio de Mucuri, Bahia – Brasil
Figura 47: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e
predita a médio prazo para sítio de Mucugê, Bahia – Brasil
Figura 48: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e
predita a médio prazo para sítio de Esplanada, Bahia – Brasil
Figura 49: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e
predita a médio prazo para sítio de Colônia Eulacio, Soriano – Uruguai

LISTA DE QUADROS

Quadro 1: Características principais das escalas atmosféricas
Quadro 2: Informações das estações meteorológicas deste estudo
Quadro 3: Informações das alturas de medições das variáveis meteorológicas/climáticas
registradas93
Quadro 4: Informações cronológicas das variáveis meteorológicas/climáticas medidas e
utilizadas neste estudo94
Quadro 5: Informações estatísticas da variável meteorológica/climática medida e utilizada neste
estudo: velocidade do vento95
Quadro 6: Parâmetros da distribuição Weibull calculados para os locais selecionados neste
estudo e alturas anemométricas102
Quadro 7: Especificações técnicas das turbinas eólicas104
Quadro 8: RMSE médio e Fator de 2 médio da previsão da velocidade do vento de 1 h até 168
h a frente245
Quadro 9: Pearson médio da previsão da potência eólica de saída de 1 h até 168 h a frente. 248

LISTA DE SIGLAS

ACL: Ambiente de Contratação Livre ACR: Ambiente de Contratação Regulada ANN: Artificial Neural Network ARIMA: Auto-Regressive Integrated Moving Average ARMA: Autoregressive Moving Average **BPNN:** Backpropagation Neural Network CCEE: Câmara de Comercialização de Energia Elétrica CCEE: Câmara de Comercialização de Energia Elétrica CLP: Camada Limite Planetária CMSE: Comitê de Monitoramento do Setor Elétrico CNPE: Conselho Nacional de Política Energética DRI: Divulgação de Resultados e Informações EO: Extremal Optimization Algorithm EPE: Empresa de Pesquisa Energética GBRT – gradient boosting regression tree GEE: Gases de Efeito Estufa **GRU:** Gated Recurrent Unit IA: Inteligência Artificial KNN - K-Nearest Neighbors LSTM: Long Short-Term Memory Neural Networks MAE: Mean Absolute Error MAPE: Mean Absolute Percentage Error MCP: Mercado de Curto Prazo MLP: Multilayer Perceptron MME: Ministério de Minas e Energia

MSE: Mean Squared Error NOAA: National Oceanic and Atmospheric Administration NaN: Not a Number ONS: Operador Nacional do Sistema Elétrico PLD: Preço de Liquidação das Diferenças PPM: Partes Por Milhão PROINFA: Programa de Incentivo às Fontes Alternativas de Energia Elétrica **RMSE: Root Mean Square Error RNA:** Rede Neural Artificial **RNN: Recurrent Neural Network** SIN: Sistema Interligado Nacional SVM: Support Vector Machine SVRM: Support Vector Regression Machine TW: Transformada Wavelet TWC: Transformada Wavelet Contínua TWD: Transformada Wavelet Discreta UTE: Administración Nacional de Usinas y Trasmisiones Eléctricas WPD: Wavelet Packet Decomposition WRF: Weather Research and Forecasting

SUMÁRIO

CAPÍTULO 1				
1 I	NTRODUÇÃO E JUSTIFICATIVA DA PESQUISA	17		
1.1	Objetivos e motivação do estudo	21		
1	.1.1 Objetivo geral	22		
1	.1.2 Objetivos específicos	23		
1.2	Contribuições principais do estudo	24		
1.3	Estrutura do trabalho	26		
CAP	ÍTULO 2			
2 0	CONTEXTUALIZAÇÃO DO PROBLEMA TÉCNICO –			
CIEN	NTÍFICO			
CAP	ÍTULO 3			
3 F	UNDAMENTAÇÃO TEÓRICA			
3.1	Conceitos iniciais			
3.2	Atmosfera Terrestre e caracterização do vento			
3.3	Energia e potência eólica	42		
3.4	Fenômenos de rampas de energia eólica	44		
3.5	Wavelets	47		
3.6	Convolução matemática	54		
3.7	Inteligência computacional	56		
3.	.7.1 Redes neurais artificiais	59		
3.	.7.2 Redes neurais recorrentes	61		
3.	.7.3 Redes LSTM e GRU	66		
3	.7.4 Redes convolucionais	69		
3.8	Relações comerciais do setor elétrico no Brasil	71		
CAP	ÍTULO 4	76		
4 T	TRABALHOS RELEVANTES AO ESTUDO	76		
CAP	ÍTULO 5			

5	N	/IETODOLOGIA CIENTÍFICA87
	5.1	Tipo de pesquisa
	5.2	Delimitação do local de estudo: sítios e dados meteorológicos
	5.3	Procedimento computacional104
	5.4	Critérios de medição de erro110
C	AP	ÍTULO 6113
6	R	RESULTADOS E DISCUSSÕES113
	6.1 inte	Artigo 1: Short-term wind speed forecasting in Uruguay using computational lligence
	6.2 com	Artigo 2: Scientific and technological development in Bahia: a case study using putational intelligence
	6.3 fore	Artigo 3: An interdisciplinary machine learning approach for wind speed casting
	6.4 Wav	Artigo 4: Nowcasting prediction of wind speed using computational intelligence and velet in Brazil
	6.5	Artigo 5: An investigation on deep learning and Wavelet transform to nowcast wind
С		ÍTULO 7
7 C	E SAP	DISCUSSÕES FINAIS SOBRE PREVISÃO A MÉDIO PRAZO 239 ÍTULO 8
8	C	CONSIDERAÇÕES FINAIS
	8.1	Conclusão249
	8.2	Sugestões de trabalhos futuros250
С	AP	ÍTULO 9252
9	F	REFERÊNCIAS BIBLIOGRÁFICAS252
A	PÊ	NDICE A
	Ana	is de Congresso 1: Short-term wind speed forecasting in tropical region using Wavelets
	and	artificial intelligence

CAPÍTULO 1

1 INTRODUÇÃO E JUSTIFICATIVA DA PESQUISA

Desde a revolução industrial no século XVIII, os combustíveis fósseis são utilizados como a principal fonte energética, contribuindo, desta maneira, para o aumento exponencial da concentração de CO₂ (dióxido de Carbono) na atmosfera. Uma concentração global crescente de CO₂ na atmosfera (de 290 partes por milhão ou ppm para 414 ppm) ocorreu durante o período de 1870 a 2020, fato este que é marcado pela 2^a e 3^a revolução industrial. Este período é caracterizado por um aumento significativo no uso de combustíveis fósseis como fonte de energia para os setores industriais e de transportes. O valor de 417,07 ppm de CO₂ foi registrado no primeiro semestre de 2020 conforme *National Oceanic and Atmospheric Administration*, NOAA (2021), sinalizando um aumento da poluição do ar atmosférico. Na Figura 1 tem-se a curva exponencial representativa da concentração global média de CO₂ na atmosfera, registrado pelo NOAA, entre o período de 1959 a 2020.



Figura 1: Concentração global média de CO₂ na atmosfera no período de 1959 a 2020. Fonte: adaptado de NOAA (2021).

Devido a este aumento nas emissões de CO_2 e suas consequências (percebe-se que a integridade dos sistemas naturais já está em risco por causa das mudanças climáticas causadas pelas intensas emissões de gases de efeito estufa – GEE na atmosfera), o conceito tradicional de desenvolvimento global incorporou o desenvolvimento ambiental. Tal incorporação resultou em um conceito mais amplo, denominado "desenvolvimento sustentável", que se baseia na indissociabilidade do desenvolvimento econômico, social e ambiental. Esta situação tem contribuído para que outras fontes energéticas ampliem a sua participação na matriz energética e na matriz elétrica de muitos países, inclusive no Uruguai e no Brasil, tal como a fonte de energia eólica: os ventos.

Inserido neste contexto de geração de energia sustentável, o relatório global divulgado pela REN21 (2020) informa que a energia eólica representou cerca de 29,5% da geração de eletricidade no Uruguai e isso o colocou em 3º colocado mundialmente como um dos países representativos em utilização de energia elétrica proveniente da ação dos ventos; já o Brasil registrou, no primeiro semestre de 2021, cerca de 695 parques eólicos em operação, com um total de 18,01 GW de capacidade instalada, representando 9,7% de toda geração injetada no Sistema Interligado Nacional (SIN), conforme ABEEolica (2021). Por essa fonte de energia ter caráter intermitente, desafios operacionais têm sido observados na integração da energia eólica ao SIN. Desta forma, a fim de reduzir os efeitos negativos dessa integração, operadores do sistema de energia baseiam-se em previsões do vento a curto e médio prazo, ou seja, 1 h a 168 h à frente, para garantir um melhor despacho da energia eólica. Estudos que visam as menores incertezas na previsão de vento, podem gerar vantagens financeiras em parques eólicos, tanto comercialização quanto na gestão manutenção de aerogeradores na de seus (CANALENERGIA, 2018), isto porque, com as mudanças na comercialização da energia, a qual já ocorre em base horária no Brasil, a previsão de vento a curto e médio prazo apresenta também uma expressiva importância financeira para os agentes financiadores e geradores.

Como referência internacional, no Nordeste brasileiro, a Bahia vem se destacando no setor tecnológico das fontes de energias alternativas, em especial a eólica. Inúmeros investimentos têm sido feitos por novas empresas, gerando oportunidades de emprego e renda para a população, inclusive com impactos positivos em muitas regiões carentes do sertão. Uma nova cadeia produtiva, focada em energia eólica, foi implantada no estado baiano com bastante êxito e continua em expansão, dinamizando a economia como um todo, de acordo com Santos e

Torres (2014). Por meio da Figura 2, observa-se que a Bahia se encontra em 2º lugar no ranking nacional de potência instalada referente à energia eólica, somando um total de 189 parques (27,19% de representatividade nacional) e cerca de 4879,6 MW de potência instalada (27,09% de representatividade nacional) em 2021, ficando atrás do Rio Grande do Norte. Se analisado somente o quantitativo de parques, a Bahia ocupa o 1º lugar.



Figura 2: Capacidade instalada e número de parques eólicos por estado brasileiro. Fonte: adaptado de ABEEolica (2021).

Em termos energéticos, tem-se que para o Operador Nacional do Sistema Elétrico – ONS (no Brasil) e para a *Administración Nacional de Usinas y Trasmisiones Eléctricas* – UTE (no Uruguai), a variabilidade da direção e velocidade do vento ao longo do dia dificulta a tomada de decisão quanto ao acionamento (ou não) das usinas eólicas, isto porque, na prática, verifica-se que o recurso eólico apresenta variações temporais em várias ordens de grandeza: variações anuais (em função de alterações climáticas), variações sazonais (em função das diferentes estações do ano), variações diárias (devido ao microclima local), variações horárias (brisas terrestres e marítimas) e variações de curta duração (rajadas). A variação espacial da energia eólica também é grande. Topografia e rugosidade do solo também influenciam na distribuição da frequência de ocorrência dos ventos e de sua velocidade em um local. Entende-se que prejuízos econômicos ocorrem caso as turbinas eólicas sejam submetidas a condições de tempo desfavoráveis. Portanto, faz-se necessário e justifica-se o esforço empreendido para o

desenvolvimento de ferramentas computacionais confiáveis para prever a velocidade do vento com boa acurácia. A modelagem atmosférica e a previsão do vento aplicada ao setor energético possuem dois enfoques principais conforme Oliveira (2013), sendo eles:

- a) a estimativa dos ventos médios levando em conta dados climatológicos para um mapeamento eólico via *softwares* de modelagem matemática e simulação numérica; e
- b) a previsão de vento para tempos futuros em curto prazo (1 h a 6 h à frente) e médio prazo (6 h a 168 h à frente) via inteligência computacional.

O primeiro enfoque tem como finalidade a seleção de locais que apresentam melhores condições de vento para geração de energia eólica a fim de prover os dados necessários para avaliar a viabilidade econômica e estabelecer os parâmetros a serem adotados no desenvolvimento de unidades geradoras e fazendas eólicas. Quanto às estimativas de curto prazo, estas são particularmente úteis na identificação de períodos de maior ocorrência de vento, bem como a ocorrência de ventos que possam prejudicar o sistema. Já a previsão de vento em médio prazo é útil no gerenciamento dos recursos de energia elétrica, visando suprir as deficiências na oferta de geração eólica por energia elétrica proveniente de outras fontes (OLIVEIRA, 2013). Salienta-se que a previsão de curto prazo é base fundamental para o estabelecimento de estratégias eficazes para a inserção da fonte de energia eólica na matriz energética de um país, principalmente em se tratando de *nowcasting* (monitoramento e previsão de curto prazo, 0 até 6 h à frente).

A respeito do *nowcasting* no Brasil, é importante ressaltar a sua relevância para a formação do Preço de Liquidação de Diferenças – PLD e para o desenvolvimento comercial da Câmara de Comercialização de Energia Elétrica – CCEE. Tal preço (PLD horário em R\$/MWh) tem como função primária valorar as diferenças entre a energia contratada pelos agentes e a energia efetivamente medida, ou seja, consumida ou gerada. Além de apreciar as diferenças entre a energia que foi contratada e a que foi produzida ou consumida, o PLD também é o custo de oportunidade da energia no curto prazo: para os geradores, que podem vender energia ao PLD caso ela não esteja comprometida em contratos; e para os consumidores, que podem comprar ou vender ao PLD a diferença entre os contratos e os consumos efetivos a energia, de acordo com Castro *et al.* (2014).

Segundo publicação de CCEE (2019), foi lançado, em março/2019, o "download de dados" com as informações individualizadas em base horária da contabilização "sombra" do Mercado de Curto Prazo – MCP. Os novos relatórios já podem ser extraídos diretamente no sistema de Divulgação de Resultados e Informações – DRI, e trazem dados que consideram o preço horário "sombra" (cálculo e publicação diária do PLD do dia seguinte e em base horária), tornando possível aos agentes trabalharem com as informações necessárias para a análise completa do preço horário. CCEE (2019) afirma ainda que "o download de dados em base horária fecha um ciclo de entregas que garantem a estrutura necessária na CCEE para a implantação da operação do preço horário a partir de 2020, oferecendo também aos agentes a base de informações necessárias para que possam se preparar para essa evolução do mercado". Portanto, tem-se que *nowcasting* é fundamental para a acurácia da previsibilidade dos preços horários da energia no MCP de energia elétrica.

Diante da 4^a revolução industrial (ou indústria 4.0), a qual teve início em 2011 e está marcada pela inteligência computacional, e das perspectivas positivas para a expansão do setor de energia eólica na Bahia, Nordeste do Brasil, e no Departamento de Soriano, no Uruguai, temse a justificativa de empregar os esforços científicos nesta pesquisa de tese voltada à previsão de vento, da geração de energia eólica e rampa de energia eólica. Este é um tema atual que precisa de avanços teóricos e técnicos, seja para o desenvolvimento energético do Brasil e do Uruguai, seja para a ampliação dos conceitos de previsão por meio de inteligência computacional e decomposição Wavelets. Em suma, um modelo preditivo híbrido aplicado a um horizonte de tempo de curto e médio prazo com maior acurácia fornecerá consequentemente maior segurança na utilização e integração da fonte eólica na matriz energética do Brasil e do Uruguai, assim como contribui para o desenvolvimento energético de outras potenciais regiões. Os objetivos e a motivação deste estudo são descritos a seguir.

1.1 Objetivos e motivação do estudo

Desde 2010, início da quarta revolução industrial, tem se percebido um grande interesse no desenvolvimento e implantação de novas soluções tecnológicas aplicadas ao processo industrial utilizando inteligência computacional via aprendizado de máquina profundo (do inglês, *deep learning*), por exemplo, utilizando redes neurais artificiais. Impulsionadas pela revolução da

Indústria 4.0, as indústrias têm enxergado nisso a oportunidade de alavancarem seus processos e produtos e torná-los mais competitivos, rentáveis e atraentes tanto para seus investidores quanto para seus clientes. Para tanto, a utilização de técnicas de inteligência computacional aplicada aos problemas da indústria para o reconhecimento de padrões, classificação, predição de séries temporais (tais como a velocidade do vento e, por consequência, a energia eólica), processamento de linguagem natural, busca e otimização, dentre outros, tem se mostrada como uma excelente ferramenta para a modernização da indústria, visando melhorias nos processos produtivos e de gestão, levando à redução de custos, aumento de valor agregado e da qualidade dos produtos e serviços. Assim, tem-se a necessidade de avançar nas pesquisas sobre a previsão da potência eólica de saída a médio prazo (1 a 168 h) e dos fenômenos de rampas de energia eólica a curto prazo (1 a 6 h) aplicando modelos híbridos advindos da inteligência computacional aplicando aprendizado de máquina supervisionado via redes neurais artificiais e o processamento de sinais temporais por meio da filtragem passa baixa e passa alta usando funções Wavelets discretas. Este estudo é motivado tanto no que tange ao empirismo presente na aplicação das funções Wavelets para decomposição/filtragem dos sinais anemométricos, quanto no que tange a incipiência dos estudos de previsão de energia eólica e rampas de vento usando dados coletados de torres anemométricas de 150 m de altura em regiões tropicais e subtropicais. Portanto, lista-se o objetivo a seguir.

1.1.1 Objetivo geral

O objetivo geral deste trabalho foi: "avaliar e implementar melhorias na previsão da geração de energia eólica a curto e médio prazo, 1 h a 168 h à frente, em resolução espacial de microescala (ou escala local, a qual apresenta processos atmosféricos da ordem de 0,001 km a 1,0 km) usando modelos de previsão baseados em inteligência computacional para o estado da Bahia, região Nordeste do Brasil (região tropical), e para Colônia Eulacio, Departamento de Soriano, no sudoeste do Uruguai (região subtropical)."

Tal esforço atende à demanda do setor de produção e distribuição de energia elétrica no Brasil e no Uruguai, com a finalidade de possibilitar um melhor aproveitamento da energia eólica nos empreendimentos atuais e em futuros projetos de exploração, produção e comercialização dessa fonte energética sustentável e alternativa. Ressalta-se que um modelo de previsão híbrido, advindo da inteligência computacional, bem ajustado pode originar um ferramental de baixo custo computacional destinado a fornecer tais previsões às concessionárias, geradoras e distribuidoras de energia elétrica e, inclusive, aos operadores nacionais do sistema elétrico de cada nação.

1.1.2 Objetivos específicos

Como objetivos específicos para esta pesquisa, com a finalidade de atingir o objetivo geral, foram listados os que seguem:

- a) Investigar as melhores técnicas de previsão de séries temporais utilizando o aprendizado de máquina supervisionado por meio da inteligência computacional via redes neurais, aplicando-as a dados observacionais de torres anemométricas advindos de alturas de 80 m, 100 m, 120 m, e 150 m (dados anemométricos: velocidade, direção, temperatura, umidade e pressão atmosférica, por exemplo) coletados no Brasil (clima tropical) e no Uruguai (clima subtropical);
- b) Averiguar a utilização de um modelo híbrido por intermédio da IA e da aplicação da filtragem e decomposição dos sinais temporais usando as diferentes famílias Wavelets e a convolução matemática para a melhoria da acurácia dos modelos de previsão de séries temporais explorados;
- c) Projetar um método/modelo híbrido de previsão da geração de energia eólica e fenômenos de rampas de energia eólica utilizando a aprendizagem de máquina supervisionada via redes neurais agregado com o processamento de sinais via decomposição Wavelet e a convolução matemática;
- d) Avaliar e validar o método/modelo criado utilizando dados observacionais de torres anemométricas com anemômetros instalados em região tropical e subtropical nas alturas do *hub* (rotor) das turbinas eólicas comerciais (isto é: 80 m, 100 m, 120 m e 150 m) a fim de garantir a qualidade do modelo preditivo proposto.

As contribuições principais do estudo são listadas a seguir.

1.2 Contribuições principais do estudo

Tem-se que o avanço nas pesquisas e as principais contribuições desta tese foram motivadas pelas seguintes assertivas:

- a) A utilização do modelo híbrido de inteligência computacional e processamento de sinais permitiu uma previsão precisa e de baixo custo computacional a curto e médio prazo, 1 h a 168 h à frente, da velocidade do vento em diferentes alturas anemométricas, assim como, por consequência, a previsão da geração de energia eólica, potência de saída e rampas de energia eólica de maneira acurada nos sítios com dados anemométricos registrados (região tropical e subtropical). Isto caracteriza esta tese como pioneira na engenharia ambiental na área temática de pesquisa de poluição do ar e previsão de energia eólica, visto que os métodos numéricos (por exemplo o WRF) é o estado da arte para previsões de ventos para mais de 72 h e que os mesmo demandam um custo computacional relevante, ou seja, computação de alto desempenho (do inglês, *High-Performance Computing –* HPC) nos centros de pesquisas, quando comparado com a inteligência computacional aplicada em redes neurais artificiais (RNA) via aprendizado de máquina supervisionado.
- b) O modelo híbrido apresentado neste estudo pode ser usado para identificar locais ótimos para instalação das turbinas eólicas e para prever a energia eólica irregular, no Brasil e no Uruguai, por exemplo, para diferentes alturas anemométricas. A previsão a curto prazo da energia eólica e fenômenos de rampa podem ser melhorados com a continuidade dos trabalhos futuros usando este modelo para amplificar a qualidade da energia eólica a médio prazo e desenvolver técnicas para previsão a longo prazo.
- c) Nenhum estudo anterior aplicou o processamento de sinais de velocidade do vento via Wavelets utilizando uma metodologia científica de identificação da família Wavelet mais eficiente em conjunto com a inteligência computacional (os trabalhos registrados são empíricos) para previsões de curto e médio prazo (1 h a 168 h à frente) da velocidade do vento, potência de saída (energia eólica) e rampas de energia eólica em diferentes alturas anemométricas na Bahia, a qual é uma região de clima tropical predominantemente quente, com chuvas no inverno e verão seco; e nem em Colônia Eulacio, Departamento de Soriano, Uruguai, região que apresenta um clima subtropical úmido. Tem-se, assim, que esta tese é um avanço técnico-científico quando comparado, por exemplo, com o trabalho de Liu *et al.* (2018) que usa técnicas de redes neurais para previsão até 3 h a frente, e com as

pesquisas de Liu, Wu e Li (2020) que aplicam as Wavelets de forma empírica junto as redes neurais para prever a velocidade do vento até 7 h a frente. Portanto, os resultados constituem uma contribuição nova e significativa para a comunidade científica.

- d) Foi utilizado, neste estudo, dados observacionais anemométricos (velocidade, direção, temperatura, umidade e pressão atmosférica) de três municípios baianos (Esplanada, Mucugê e Mucuri), coletados em 3 importantes alturas anemométricas 100 m, 120 m, 150 m, o que contribui para a caracterização do estado da Bahia (564.760,427 km² de extensão territorial) que possui área da unidade territorial maior do que países europeus, tais como Espanha (505.990 km²), Suécia (450.295 km²) e Alemanha (357.386 km²). Tais municípios representam bem a variabilidade de clima e relevo do estado baiano. Além dos dados anemométricos de Colônia Eulacio (velocidade, direção e temperatura), coletados a 81.80 m e 101.80 m, no departamento de Soriano, Uruguai (176.215 km²), para representar a região de clima subtropical na América do Sul.
- e) As pesquisas sobre previsão de energia eólica geralmente se concentram em métodos de previsão em que o projeto do vetor de dados de entrada é baseado em dados anemométricos coletados a 10 m (altura comum de torres anemométricas regionais). A necessidade de usar as equações físicas (ou seja, perfil logarítmico ou lei de potência/log) para calcular/estimar a velocidade do vento em alturas superiores a 10 m adiciona erros nas previsões de vento. Portanto, a fim de minimizar os erros, este estudo utilizou medições meteorológicas registradas a 80 m, 100 m, 120 m e 150 m como dados de entrada (*input*) da RNA (fases de treinamento, validação e teste). Isso é importante devido à altura real do *hub* das turbinas eólicas comerciais instaladas em parques e fazendas eólicas. Quanto mais próximo o anemômetro é colocado da eventual altura do *hub* da turbina eólica, mais precisamente ele mede as variáveis meteorológicas às quais as turbinas eólicas estarão expostas.
- f) Em termos de potencial eólico no Brasil, existe uma variedade de regimes de vento, por exemplo, a região Sul e a região Nordeste. Na região Sul, a variabilidade do vento é maior porque esta região sofre a influência das frentes frias características do hemisfério sul. Porém, nesta região, esta dificuldade é contrabalançada por um conhecimento científico mais amplo e uma maior quantidade de sistemas de medição meteorológica. Em contraste, no Nordeste, o clima é tropical quente (com suas subdivisões regionais predominantes tropical litorâneo, tropical continental e tropical semiárido), onde existem grandes lacunas no conhecimento científico do comportamento do vento na região e são, relativamente, carentes de sistemas de medição. Nesse sentido, o fato de os ventos alísios se desenvolverem nos oceanos, impõe a necessidade da utilização de perfis de vento derivados

de sensoriamento remoto de satélites, além dos desafios de terrenos complexos e regiões costeiras. Estas são consideradas as principais fronteiras científicas na previsibilidade do vento nesta região. Já a previsão de vento no Uruguai (cujo clima é subtropical) é caracterizado como incipiente, tendo seus primeiros estudos com inteligência computacional datados de 2019 por meio dos estudos desenvolvidos nesta tese.

A estrutura desta tese é apresentada a seguir.

1.3 Estrutura do trabalho

Com base nas pesquisas e simulações computacionais realizadas, este trabalho pretendeu contribuir para o avanço técnico-científico, propondo o desenvolvimento de uma metodologia híbrida para previsão de vento, da geração de energia eólica e rampa de energia eólica para curto e médio prazo utilizando inteligência computacional e decomposição de sinais temporais via processamento Wavelets.

Para tanto, esta tese foi estruturada da seguinte forma:

- no Capítulo 2 apresenta-se o problema técnico científico da pesquisa aqui estudada;
- no Capítulo 3 é mostrado a fundamentação teórica deste estudo, buscando assim fornecer o desejável embasamento conceitual sobre o assunto e a temática do projeto;
- no Capítulo 4 está descrito a revisão bibliográfica do assunto e do tema desta tese com a apresentação dos trabalhos relevantes para este estudo científico;
- no Capítulo 5 é apresentada a metodologia científica aplicada neste projeto;
- no Capítulo 6 os resultados e as discussões das pesquisas são expostos e organizados na forma de 5 artigos científicos; ¹
- no Capítulo 7 são discutidas e apresentadas as considerações finais sobre os resultados das previsões simuladas a médio prazo;
- no Capítulo 8 as conclusões e as recomendações de trabalhos futuros são descritas;
- no Capítulo 9 as referências bibliográficas usadas para a construção desta pesquisa são enumeradas;

• no Anexo A é apresentado, advindo de anais de congresso, 1 *extended abstract* cujos resultados contribuíram para o desenvolvimento e avanço desta tese.

A seguir, é descrito a contextualização do problema técnico-científico desta pesquisa.

¹ Formatação permitida pelo Programa de Pós-Graduação em Engenharia Ambiental – PPGEA, da Universidade Federal do Espírito Santo – UFES, conforme o Regimento do PPGEA Art. 34°. e § 3°.

CAPÍTULO 2

2 CONTEXTUALIZAÇÃO DO PROBLEMA TÉCNICO – CIENTÍFICO

O debate que se trava na sociedade contemporânea sobre o aquecimento global pode ser concebido como um duelo intelectual. De um lado, há pesquisadores que defendem que este fenômeno é natural à dinâmica da Terra e que a mesma já vivenciou algo parecido há milhões de anos; de outro, há os que afirmam que o aquecimento global está ocorrendo devido ao aumento exponencial das emissões de GEE para a atmosfera. Neste âmbito, o que se observa em pesquisas e estudos científicos sobre cenários energéticos, na realidade, é um crescimento cada vez maior da demanda energética, o que acaba intensificando as emissões de GEE para a atmosfera devido, principalmente, à queima de combustíveis fósseis. É fato que a emissão de gases como o dióxido de carbono (CO₂), o óxido nitroso (N₂O) e o metano (CH₄) contribuem para a expansão do efeito estufa e, consequentemente, para o aumento da temperatura média da Terra, causando o chamado aquecimento global, o precursor das alterações climáticas globais conforme alguns especialistas.

Consoante reconhecido pelo Protocolo de Kyoto, planejar um futuro energético ecologicamente correto é o grande desafio do século XXI. Os padrões atuais de recursos energéticos e de uso de energia se mostram prejudiciais para o bem-estar da humanidade ao longo prazo. As consequências oriundas das mudanças climáticas, ocasionadas pelo aquecimento global, incluem uma redução maciça na água fornecida mundialmente pela eliminação paulatina das geleiras; pela devastação cada vez maior das enchentes, secas, incêndios, tufões e furacões; deslocamento permanente de dezenas a centenas de milhares de pessoas devido à elevação do nível do mar; alterações na distribuição espacial de alguns vetores de doenças infecciosas, especialmente onde esses vetores ou patógenos dependem da temperatura e da umidade; e perdas significativas da biodiversidade (alterações na flora e na fauna).

Chaves *et al.* (2016) destacam que o uso da energia pode ser relacionado com o desenvolvimento da humanidade, isto sob uma perspectiva antropocêntrica. Ao se fazer um retrospecto da evolução humana, pode-se destacar alguns dos principais ciclos de

desenvolvimento energético: o ciclo da madeira, o do carvão e o do petróleo juntamente com o gás natural; cada qual com sua particularidade, mas, sistematicamente, cada um destes visou gerar energia para prover, basicamente, conforto e mobilidade aos seres humanos. A gestão energética passa por novos desafios, não só pela geração e distribuição, mas também pela sustentabilidade, uma vez que a questão ambiental, recentemente, trouxe a discussão de como o uso de energia pode afetar o clima e, consequentemente, a fauna e a flora, conforme explicam Chaves *et al.* (2016). Sabe-se que este viés ambiental, aliado à necessidade de uma maior diversificação na matriz energética, faz com que a ciência, sob suas diversas formas, busque subsidiar o conhecimento para a geração e gestão de energia empregando os conceitos de eficiência energética e sustentabilidade.

Diante do exposto, registra-se que no Brasil, o estado da Bahia está consolidando a posição de 2º maior polo brasileiro de investimentos em energia eólica, bem como vem se tornando uma referência internacional nesta área tecnológica. Inúmeros investimentos têm sido feitos por novas empresas, gerando oportunidades de emprego e renda para a população, inclusive com impacto positivo em regiões carentes. Uma nova cadeia produtiva, focada em energia eólica, foi implantada no Estado com bastante êxito e continua em expansão, dinamizando a economia como um todo, conforme CREA-BA (2018). O Uruguai, conforme já mencionado, ocupa lugar de destaque mundial quando o assunto é a utilização da energia eólica na matriz energética, e as pesquisas envolvendo modelagem matemática, simulação numérica e inteligência computacional com séries temporais de vento são incipientes.

Santos (2013) destaca que fatores pertinentes à geração de energia eólica tais como a aleatoriedade da oferta de energia, o reduzido fator de capacidade e a sazonalidade, acabam prejudicando sua efetivação. Sendo assim, devem ser asseguradas as condições de análise da rede através da modelagem do desempenho elétrico dessas fontes, atendimento de requisitos de tensão, frequência, atuação de proteção, fator de potência e a observabilidade (medida quão bem podem os estados de um sistema ser inferidos a partir do conhecimento de suas saídas externas). Tal autor destaca ainda que para acelerar o aumento da participação da energia eólica na matriz energética de uma nação é necessária a composição de um sistema referencial permanente de medição, registro e previsão de velocidade e direção do vento. Huang, Henry e van Dam (2010) destacam que quando existem grandes quantidades de unidades de produção eólica inseridas na rede, a incerteza associada aos níveis de energia gerada torna-se problemática, existindo custos associados a unidades ligadas em excesso, bem como a

eficiências reduzidas e aumentos na necessidade de manutenção. Assim, previsões melhoradas a curto e médio prazo podem reduzir estes custos. Isto leva ao aprimoramento do MCP que em 2021 passou a ser precificado diariamente e em base horária no Brasil. A principal diferença é que a energia é precificada diariamente e em base horária, deixando de ser calculada em frequência semanal e em patamares. O modelo vigente foi construído para uma matriz com alta predominância das fontes hidráulicas em que há menor variação e maior previsibilidade. Para os expressivos consumidores de energia elétrica, a mudança pode representar oportunidades, desde que haja maturidade no processo de tomada de decisão na gestão de energia e um adequado planejamento estratégico que leve em consideração as variáveis do modelo.

O fato de a acurácia e a precisão das previsões da velocidade do vento diminuir, significativamente, na medida que se amplia o horizonte de tempo, como indica, por exemplo, as previsões registradas abaixo (Figura 3 e Figura 4) no horizonte de 1 h e 12 h à frente, respectivamente, utilizando redes neurais recorrentes simples com 6 neurônios para dados anemométricos de Mucuri – BA medidos a 100 m de altura, caracteriza um problema que precisa ser analisado e estudado seguindo uma metodologia científica.



Figura 3: Dispersão dos dados preditos para 1 h à frente.

Fonte: Autoria própria.



Fonte: Autoria própria.

Ao interpretar a Figura 3 e a Figura 4 acima, tem-se que para o horizonte predito de 1 h à frente o R^2 é igual a 0,88 e para 12 h é igual a 0,58, assim há uma redução de 34,09% da acurácia destes resultados. A piora na acurácia é amplificada quando se aumenta o horizonte de previsão para 24 h à frente, por exemplo. O método híbrido de inteligência computacional junto com o processamento de sinais via Wavelets, por exemplo, precisa ser bem ajustado (tanto os preditores e os hiperparâmetros das redes neurais, como a seleção da melhor função Wavelet mãe para filtragem passa alta e passa baixa) para então poder aprender com eficácia as características meteorológicas da região estudada e, portanto, prever a velocidade do vento com acurácia, assim como a energia eólica e os fenômenos de rampa de vento.

As flutuações caóticas da velocidade do vento ao longo do dia dificultam a previsão da geração de energia eólica. Alcançar previsões de energia eólica de alta precisão é, portanto, difícil, já que a energia eólica é uma função da velocidade do vento ao cubo (elevado à terceira potência). Criticamente, erros nas previsões da geração de energia eólica podem causar dificuldades na transmissão e no despacho de eletricidade em muitas regiões com os empreendimentos eólicos ativos. Assim, melhorar as previsões da velocidade do vento é fundamental para uma transição suave rumo a uma era de maior geração de energia eólica no Brasil e no Uruguai.

O custo/tempo computacional advindo da utilização de modelos numéricos de previsão (*Prediktor, Previento, LocalPred, eWind* e *WRF*, por exemplo) com malhas (*grids*) de simulação refinadas para um horizonte de curto a médio prazo em resolução espacial de microescala, acaba, muitas vezes, não justificando o custo-benefício. Estes modelos numéricos são bem utilizados para a previsão de ventos médios em uma região com resolução espacial de mesoescala e previsões com horizonte a longo prazo. O método de persistência e os métodos estatísticos (*Autoregressive Model, Autoregressive Moving Average, e Autoregressive Integrated Moving Average*, por exemplo) na maioria dos estudos são aplicados para previsão de até 1 h à frente, pois a variabilidade e flutuações aleatórias dos dados observados acabam por reduzir a acurácia da previsão. Nesta perspectiva, os modelos de inteligência computacional centrados no aprendizado de máquina supervisionado utilizando redes neurais artificiais, que marcam a IV Revolução Industrial, acabam se tornando importante alternativa para estudos de previsão de vento e, por consequência, da geração de energia eólica e fenômenos de rampas eólicas a curto e médio prazo.

Com base no que foi exposto, formulou-se o seguinte problema da pesquisa a ser respondida: "Como melhorar a previsão da geração de energia eólica com uma melhor acurácia para curto e médio prazo (1 h a 168 h à frente), utilizando mecanismos de previsão aderentes de menor custo computacional, para a resolução espacial de microescala em região tropical e subtropical?"

Desta maneira, percebe-se que a resolução da problemática deste estudo visou à implementação de uma ferramenta computacional acurada e precisa, testando em particular para a região tropical da Bahia (Brasil) e subtropical de Colônia Eulacio (Uruguai), que estão destinados a fornecerem as previsões da geração de energia eólica, a curto e médio prazo, às concessionárias, geradoras e distribuidoras de energia elétrica e, também, ao ONS e UTE. Os Capítulos 3 e 4 que seguem, fundamentação teórica e a revisão bibliográfica respectivamente, têm como objetivo disporem de informações literárias sobre a atmosfera terrestre, a caracterização de vento, energia e IA, junto com trabalhos científicos relevantes para este estudo já publicados na literatura científica.

CAPÍTULO 3

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Conceitos iniciais

Na meteorologia, a velocidade e a direção do vento, juntamente com a temperatura, a umidade e a pressão do ar atmosférico, são as variáveis mais importantes empregadas na descrição meteorológica da atmosfera terrestre. O vento, como agente meteorológico, atua nas modificações das condições do tempo, sendo responsável pelo transporte de umidade e de energia na atmosfera. A energia dos ventos pode provocar grande destruição quando associado a eventos específicos como furacões e tornados. Contudo, o vento pode ser empregado como uma fonte alternativa de energia por meio da conversão de sua energia cinética em outras formas de energia, especialmente eletricidade, conforme explicam Martins, Guarnieri e Pereira (2008).

Inserido neste contexto, sabe-se que, conforme Cheng *et al.* (2017), a preocupação com a redução da emissão dos GEE para a atmosfera tem levado muitos países a buscar, cada vez mais, o desenvolvimento de fontes alternativas de geração de energia, dentre elas, a solar e a eólica, além da implantação de políticas energéticas sustentáveis. Pinto (2014) explica que por estas questões ambientais há uma tendência à incorporação de fontes alternativas conectadas ao sistema de distribuição de energia.

De acordo com a literatura apresentada por Moreira *et al.* (2017), a energia eólica, ou energia contida nos ventos, consiste em energia cinética resultante do deslocamento das massas de ar com velocidades variáveis no tempo e no espaço, provocadas por efeitos climáticos derivados do aquecimento da Terra por radiação solar incidente, rotação e translação da Terra, bem como pelos efeitos de superfície (rugosidade do terreno, obstáculos, gradientes térmicos, dentre outros).

Vale ressaltar que para se garantir comercialmente que o operador nacional não sofrerá impactos financeiros quanto ao fornecimento da energia eólica para a rede elétrica e que os equipamentos/estruturas mecânicas não serão impactados com a variabilidade do campo de vento, é necessário empregar esforços em pesquisas sobre previsão de vento a curto e médio prazo. Assim, tem-se que a inteligência computacional junto com o processamento de sinais, com as RNA treinadas pelo aprendizado de máquina supervisionado, pode contribuir com estas pesquisas de previsão de séries temporais ampliando a precisão e a acurácia dos resultados (*outputs*).

Na literatura, autores como Cadenas (2009); Nogay, Akinci e Eidukeviciute (2012); Abhishek *et al.* (2012); Chang (2013); Dalto *et al.* (2014); Quadros (2015); Vieira, Zuben e Ballini (2016); Wasilewskia e Baczynskib (2017); Liu, Mi e Li (2018); Li, Wu e Liu (2018); Santhosh, Venkaiah e Kumar (2018); Ahmed e Khalid (2018); Zucatelli *et al.* (2019a; 2019b; 2019c; e 2019d), Zucatelli *et al.* (2020) e Zucatelli *et al.* (2021) destacam seus estudos e previsões a curto e médio prazo por meio de modelagem e simulação de baixo custo computacional com técnicas de inteligência computacional, todos com bons resultados alcançados e baixos erros associados à técnica empregada, o que justifica o esforço para aprimorá-la na Bahia (Brasil, região tropical) e em Colônia Eulacio (Uruguai, região subtropical), ambos países da América do Sul. Zhang *et al.* (2014), dentre outros, avaliam de maneira aprimorada o desempenho da previsão de rampa de energia eólica a curto prazo definindo cada caso de rampa e as métricas de avaliação estatística. O tópico a seguir retrata sobre a Atmosfera Terrestre e a caracterização do vento, com o intuito de embasar teoricamente o campo de estudo.

3.2 Atmosfera Terrestre e caracterização do vento

A Atmosfera Terrestre é apenas um dos cinco sistemas que determinam o clima da Terra, além da Criosfera, Biosfera, Litosfera e Hidrosfera. De acordo com Pinto (2014), a meteorologia faz a divisão por camadas segundo suas características térmicas, sabendo que a temperatura do ar decresce com a altitude da ordem de –6,5 °C/km. A atmosfera é dividida em quatro camadas: Troposfera, Estratosfera, Mesosfera e Termosfera. Na Figura 5 pode-se observar as camadas da atmosfera relacionadas ao perfil médio da temperatura do ar acima da superfície da Terra. A linha sólida ilustra como a temperatura média varia em cada camada.



Figura 5: As camadas da Atmosfera Terrestre. Fonte: Adaptado de Ahrens (2009).

Entende-se que, do ponto de vista meteorológico, a Troposfera é a mais importante, porque além de ser a região em que ocorre a manifestação da vida na Terra, é nesta faixa que ocorre a maior parte dos fenômenos meteorológicos. Tem cerca de 12 km de altura, mas pode alcançar 17 km na região tropical e 7 km nos polos. Sua parte mais baixa, chamada de Camada Limite Planetária (CLP), tem algumas centenas de metros, porém pode alcançar até 3 km de altura, dependendo do relevo e do horário, segundo Pinto (2014). A fronteira que separa a Troposfera da Estratosfera é chamada de Tropopausa (Figura 6). A CLP, do ponto de vista meteorológico, desempenha um papel fundamental na determinação do clima local de uma região, conectando a superfície terrestre com a Atmosfera Livre.


Figura 6: Estrutura da Troposfera, evidenciando a localização da Camada Limite Planetária e da Atmosfera Livre. Fonte: Nascimento (2016).

De acordo Stull (1988), a CLP é influenciada diretamente pelos processos que ocorrem na superfície terrestre, tais como a fricção gerada pelo arraste e cisalhamento do vento e o ciclo diário de aquecimento e resfriamento, respondendo a esses processos em uma escala de tempo que varia desde poucos minutos a várias horas (como no ciclo diário). Nascimento (2016) explica que as características e a evolução temporal da CLP são governadas pela turbulência atmosférica, que é de natureza caótica e em grande parte é gerada por forças que interagem com a superfície, gerando fluxos turbulentos que transportam matéria e energia através de turbilhões, que podem ocorrer desde uma escala milimétrica até uma escala de centenas de metros. Já quanto às escalas atmosféricas, cita-se microescala, mesoescala e macroescala (sinótica e planetária). Segundo Lutgens e Tarbuck (1995) citado por Martins, Guarnieri e Pereira (2008), os movimentos atmosféricos são enquadrados nestas escalas de tempo e espaço (Quadro 1):

Continua...

Escalas	Dimensão	Fenômenos	Duração
Microescala	Menos de 1 km	Turbulências e rajadas.	Segundos a
			minutos.
Mesoescala	1 km a 100 km	Tempestades, tornados e brisa	Minutos a dias.
		terrestre.	
Macroescala:	100 km a 5000	Ciclones de latitudes médias,	Dias a semanas.
Escala sinótica	km	anticiclones e furacões.	

Macroescala:	1000 km a	Ventos alísios e ventos do oeste.	Semanas a anos.
Escala	40000 km		
planetária			

Quadro 1: Características principais das escalas atmosféricas.

Fonte: Adaptado de Martins, Guarnieri e Pereira (2008).

O movimento de parcelas de ar, na atmosfera planetária, é denominado vento. Embora o ar possa mover-se na direção vertical, a denominação "vento" é comumente aplicada apenas ao movimento horizontal, paralelo à superfície do planeta. Algebricamente, chama-se vento à componente horizontal $\overrightarrow{V_z} = u\vec{i} + v\vec{j}$ do vetor velocidade $\vec{V} = u\vec{i} + v\vec{j} + w\vec{k}$ do ar. Em Meteorologia, as componentes u, v e w da velocidade do ar são denominadas de zonal, meridional e vertical, respectivamente. A caracterização do vento em qualquer ponto de latitude (ϕ), longitude (λ) e altitude (z) da atmosfera requer os seguintes parâmetros: módulo, direção e sentido (VAREJÃO-SILVA, 2006). A direção do vento indica a direção de onde ele provém. Ambas são grandezas instantâneas e pontuais, pois o escoamento do ar depende das condições atmosféricas (que variam no espaço e com o tempo). Nas proximidades da interface superfície-atmosfera o vento é altamente influenciado pelas características geométricas e pelo estado de aquecimento da própria superfície subjacente.

O que gera tal movimento é a circulação das camadas de ar provocada pelo aquecimento desigual do planeta. O total de radiação solar que chega à Terra é de, aproximadamente, 1,58 bilhão de TWh/ano, o que corresponde a uma média de 350 W/m² sobre a superfície do planeta, sendo distribuído bem mais próximo à linha do Equador do que nos polos. Apenas cerca de 3 a 5% da radiação que chega é convertida em energia cinética que possa provocar o movimento da atmosfera por meio de diferença de temperatura, formando a base para a fonte da energia eólica (PINTO, 2014). Desse fluxo global, atina-se que somente uma fração pode teoricamente ser capturada como energia eólica e, mesmo assim, a cerca de algumas dezenas de metros de altura.

Em níveis atmosféricos afastados da superfície terrestre, o atrito pode ser desprezado e o vento pode ser descrito pelo equilíbrio entre a força de Coriolis e do gradiente de pressão, sendo essa aproximação chamada de aproximação geostrófica. As parcelas de ar inicialmente em repouso e sujeitas a um gradiente de pressão, começam a acelerar-se em direção à pressão mais baixa.

A força de Coriolis cresce à medida que a velocidade aumenta fazendo com que as parcelas de ar sejam gradativamente defletidas até que, eventualmente, as duas forças entrem em equilíbrio e as parcelas passam a mover-se perpendicularmente ao gradiente de pressão e paralelamente às isóbaras (isolinhas de pressão constante), com velocidade constante e em trajetórias retilíneas.

Como a força de Coriolis desvia as trajetórias de ar para a direita no Hemisfério Norte e para a esquerda no Hemisfério Sul, o vento em equilíbrio resultante, para uma mesma distribuição de pressão, possui sentidos opostos em cada hemisfério, de acordo com Martins, Guarnieri e Pereira (2008). Esse movimento não-acelerado e retilíneo das parcelas de ar possui intensidade proporcional à intensidade dos gradientes de pressão, e é denominado vento geostrófico. Tong (2010) explica que a força de Coriolis tem valor zero no equador e atinge valores máximos nos polos, ou seja, depende da latitude da Terra. Em movimentos atmosféricos de grande escala, a combinação do gradiente de pressão devido à radiação solar desigual e da força de Coriolis devido à rotação da Terra faz com que a única célula meridional se fragmente em três células convectivas em cada hemisfério: a célula de Hadley, a de Ferrel e a célula Polar. Cada célula tem seu próprio padrão de circulação característico (Figura 7).



Figura 7: Circulação atmosférica idealizada. Fonte: Dereczynski e Menezes (2015).

Na região tropical (aproximadamente entre 30° N e 30° S), a radiação de onda curta proveniente do sol que penetra na Terra é superior à radiação de onda longa que parte do sistema. O aquecimento mais intenso que ocorre nas regiões equatoriais promove a formação de regiões de baixas pressões, pois o ar quente é menos denso do que o ar frio e, portanto, a pressão é menor. Para a região equatorial convergem em superfície os ventos alísios de sudeste (no Hemisfério Sul) e de nordeste (no Hemisfério Norte). À medida que os ventos alísios transportam ar para o equador, a umidade aumenta em função da evaporação da água do mar. A convergência na região equatorial proporciona o levantamento do ar, que se resfria, perdendo umidade por condensação e precipitação, e então volta em altitude (sentido contrário, contraalísios) à zona dos cinturões anticiclônicos, localizados a aproximadamente 30° de latitude, onde desce, aquecendo-se e tornando-se mais seco para alimentar os alísios. Esta célula de circulação é denominada Hadley-Walker. A circulação é dita de Hadley quando ocorre no sentido norte-sul e de Walker quando se dá no sentido leste-oeste. Na não há como separar estas duas células, pois geralmente ocorrem simultaneamente (CLIMANÁLISE, 1986 citado por DERECZYNSKI e MENEZES, 2015).

Sobre os oceanos equatoriais forma-se uma região estreita, com altos índices pluviométricos e movimento ascendente, conhecida como Zona de Convergência Intertropical (ZCIT), por ser a faixa para a qual os ventos alísios dos dois hemisférios convergem. A faixa em torno de 30° N e 30° S, caracterizada por estabilidade e ventos calmos, é conhecida como "latitude dos cavalos", pois as embarcações a vela que por lá passavam, ao se depararem com calmarias típicas dos centros de alta pressão, tinham que reduzir seu peso e racionar água, e para conseguir isso lançavam por vezes seus cavalos ao mar (BYERS, 1959 citado por DERECZYNSKI e MENEZES, 2015).

Nas faixas das zonas temperadas (em torno de 60°) convergem os ventos de sudeste e noroeste no Hemisfério Sul e de nordeste e sudoeste no Hemisfério Norte. Estes ventos sobem e voltam nos altos níveis à zona dos cinturões anticiclônicos e às calotas polares. Nesta região, em torno de 60° S e 60° N, situam-se baixas pressões que são importantes zonas de convergências extratropicais, onde o ar quente e úmido encontra-se com ar frio e seco. Desse encontro originam-se os fenômenos meteorológicos mais importantes das latitudes médias (as frentes). A célula de circulação meridional entre 30° e 60°, denominada célula de Ferrel, é uma célula de circulação indireta, pois nela o ar sobe frio e desce quente, inversamente ao que ocorre na célula de Hadley. Parte do ar que ascende próximo à latitude de 60° (sul e norte) desce nos polos (90° S e 90° N), formando a célula polar (DERECZYNSKI e MENEZES, 2015).

Enfatiza-se que o vento geostrófico é um modelo idealizado que apenas aproxima o comportamento verdadeiro do escoamento de ar em altos níveis (onde as forças de atrito não são significativas) em latitudes médias e altas (uma vez que nas proximidades do Equador a força de Coriolis é praticamente nula). Contudo, na linguagem técnica da energia eólica, o vento acima de alguns poucos quilômetros da superfície, que não sofre influência do atrito da superfície, é comumente referido como sendo vento geostrófico. Além do comportamento turbulento devido às interações superfície-atmosfera, outro aspecto importante a ser considerado é o cisalhamento do vento. A velocidade do vento é nula a alturas próximas à superfície e aproximadamente geostrófica na atmosfera livre. Na camada superficial observase um perfil vertical aproximadamente logarítmico do módulo da velocidade do vento, como apresentado graficamente na Figura 8.



Figura 8: Perfil vertical da velocidade do vento. Fonte: Martins, Guarnieri e Pereira (2008).

Moreira *et al.* (2017) deixam claro que a variação da velocidade do vento com a altura em relação ao solo influencia não apenas a avaliação do recurso eólico como também o projeto da turbina eólica e, consequentemente, a escolha da turbina mais adequada ao perfil do vento, considerando-se a velocidade média, a densidade do ar e o índice de turbulência. Em geral, os anemômetros das estações de medição são instalados em altura diferente da altura do cubo da

turbina eólica. Assim, há necessidade de se corrigir a velocidade do vento com a altura, salienta o mesmo autor.

Em estudos de aproveitamento energético da velocidade do vento, a Lei Logarítmica é comumente utilizada para representar o perfil vertical do vento. O modelo com base na Lei Logarítmica é aplicado a terrenos complexos, com orografia mais acentuada, e leva em conta que o escoamento na atmosfera é altamente turbulento, Moreira *et al.* (2017). *Prandtl* desenvolveu a seguinte expressão logarítmica empírica para a variação da velocidade do vento na vertical em uma camada limite turbulenta. A Equação 1 representa esta expressão desenvolvida por *Prandtl*,

$$v(z) = \frac{v^*}{\kappa} ln\left(\frac{z}{z_o}\right) \tag{1}$$

Em que: a variação da velocidade com a altura vertical *z*, v(z), é dada em função da velocidade de fricção (v^*) ou de atrito relacionada com a tensão de cisalhamento na superfície e a massa específica do ar, da constante de *von Karmán* ($\kappa = 0,4$), e do comprimento de rugosidade (z_o) o qual caracteriza a rugosidade do terreno. Para terreno de pasto acidentado, $z_o = 10,0$ mm, já para região com poucas árvores é igual a $z_o = 100,0$ mm, por exemplo.

Quando se desejar usar a Lei Logarítmica para estimar a velocidade do vento de uma altura de referência z_r , para outro nível de altura (z), pode-se aplicar $\frac{v(z)}{v(z_r)} = \frac{ln(\frac{z}{z_0})}{ln(\frac{z}{z_r})}$. O comprimento de rugosidade corresponde à altura em que o vento, próximo à superfície, assume valor zero, e depende do relevo e obstáculos da superfície. Contudo, o perfil real de velocidades na vertical depende também da estratificação de temperatura e pressão na atmosfera. Nesta tese, foi utilizado dados anemométricos coletados na altura do hub de turbinas eólicas comerciais para evidenciar a originalidade do projeto, visto que a utilização do equacionamento acima pode agregar erros na previsão eólica.

3.3 Energia e potência eólica

A utilização dos recursos eólicos para a produção de energia elétrica depende de diversos parâmetros que permitem predizer a viabilidade econômica e as características técnicas e operacionais do empreendimento (SANTOS, 2013). Entre eles pode-se destacar (SILVA, 2006):

- a) Velocidade do vento: o vento apresenta variação em sua velocidade, intensidade e direção, nas quais são observadas alterações em períodos curtos, médios e longos, tornando de grande importância o conhecimento do comportamento dos ventos na região em estudo, ou seja, a caracterização das diferentes formas de variação da velocidade.
- b) Rugosidade do terreno: em geral, quanto mais acentuada a rugosidade do terreno, maior será a diminuição da velocidade do vento. Dessa forma, a rugosidade do terreno onde será feito o aproveitamento eólico deve ser baixa, de modo a diminuir a menores taxas a velocidade do vento na altura do rotor. Baixas rugosidades são desejáveis no entorno do terreno, na direção principal do vento.
- c) Altura: o perfil do vento se modifica de acordo com a altura em que é medido, sendo que maiores velocidades são verificadas na medida em que se afasta do solo. Tal consideração é de grande importância quando da especificação de um aerogerador, isso porque as medidas de velocidade do vento nem sempre são feitas exatamente na altura do eixo das turbinas, sendo então necessário extrapolar a velocidade do vento.
- d) Direção do vento: uma vez que os ventos também variam a sua direção ao longo de um determinado período, é muito importante a determinação desse comportamento como forma de avaliar a possível conformidade de uma determinada turbina ao comportamento variável das direções predominantes do vento. A direção do vento é também imprescindível para o projeto do parque e a definição do *layout* das máquinas. A rosa dos ventos permite verificar as informações da distribuição da velocidade do vento e a frequência da variação de sua direção.

Em suma, a energia eólica é uma forma especial de energia cinética do ar à medida que flui. A energia advinda dos ventos pode ser convertida em energia elétrica por máquinas de conversão de energia. A energia cinética existe sempre que um objeto de uma determinada massa está em

movimento com uma velocidade de translação ou rotação. Quando o ar está em movimento, a energia cinética (E_c) no ar em movimento pode ser determinada como apresentado pela Equação (2):

$$E_c = \frac{1}{2}mu^2 \tag{2}$$

em que *m* é a massa de ar (fluido que está em movimento) e *u* é a velocidade média do vento em determinado período. A energia eólica (P_w) pode ser obtida diferenciando a energia cinética no vento em relação ao tempo, conforme Equação (3):

$$P_w = \frac{dE_c}{dt} = \frac{1}{2}\dot{m}\bar{u}^2 \tag{3}$$

No entanto, apenas uma pequena parte da energia eólica pode ser convertida em energia elétrica. Quando o vento passa por uma turbina eólica e aciona as pás para girar, a taxa de fluxo de massa (\dot{m}) do vento correspondente é mostrado na Equação (4):

$$\dot{m} = \rho A \bar{u} \tag{4}$$

em que ρ é a densidade do ar, e *A* é a área varrida pelas pás eólicas. Ao substituir (4) em (3), a energia disponível no vento (*P_v*) pode ser expresso como Equação (5),

$$P_{\nu} = \frac{1}{2}\rho A \bar{u}^3 \tag{5}$$

Esta é uma equação fundamental na análise de energia eólica. Um exame da Equação (5) revela que, para obter uma maior potência eólica, é necessária uma maior velocidade do vento, um maior comprimento de pás para obter uma maior área varrida e uma maior densidade do ar. Como a produção de energia eólica é proporcional à potência cúbica da velocidade média do vento, uma pequena variação na velocidade do vento pode resultar em uma grande mudança na energia eólica. Por isso, dobrar a velocidade do vento leva a um aumento de oito vezes em sua potência disponível. Isso explica por que a velocidade do vento ambiente é o principal fator ao se considerar a energia eólica. Como resultado da gama limitada de flutuações da densidade do ar, a densidade é de importância secundária. A dependência energética da área implica uma dependência quadrática não linear do raio de uma área varrida do aerogerador, destacando as vantagens das pás mais longas do aerogerador. Logicamente, quanto mais acurado for o modelo de inteligência computacional utilizado para prever a velocidade do vento ambiente, maior será a precisão da previsão da energia eólica e, por consequência, da rampa de energia eólica (KALMIKOV, 2017).

Neste contexto, tem-se a equação algébrica de acordo com a curva de potência da turbina eólica, velocidade de ativação e a velocidade de desativação, que pode ser formada como mostrado na Equação (6), com objetivo de prever a produção de energia eólica,

$$P_{i}(v) = \begin{cases} 0, & se \ v < v_{ci} \\ 1/2 \left(\rho \pi r^{2} v^{3} C_{p} \eta\right), & se \ v_{ci} \le v < v_{R} \\ P_{R}, & se \ v_{R} \le v < v_{co} \\ 0, & se \ v \ge v_{co} \end{cases}$$
(6)

em que v é a velocidade do vento [m/s]; v_{ci} é a velocidade do vento de *cut-in* ou de ativação [m/s]; v_R é a velocidade nominal do vento [m/s]; v_{co} é a velocidade do vento de *cut-out* ou de desativação [m/s]; P_R é a potência eólica nominal [W]; $P_i(v)$ é a potência gerada na velocidade do vento relatada [W]; ρ é a massa específica do ar [kg/m³]; r é o raio do rotor [m]; C_p é o coeficiente de potência; η é a eficiência do grupo gerador – transmissão de energia mecânica e elétrica.

3.4 Fenômenos de rampas de energia eólica

O uso crescente de forma exponencial da energia eólica como fonte de eletricidade apresenta novos desafios no que diz respeito à produção de energia e ao equilíbrio de cargas na rede elétrica. Esta fonte renovável de energia é volátil e variável. Uma maneira de integrar a energia proveniente dos ventos à rede elétrica é desenvolver sistemas confiáveis e precisos de previsão de energia eólica. A eletricidade gerada a partir da energia eólica pode ser variável em várias escalas de tempo, por exemplo: sub-horária, horária, diária e sazonal. A energia eólica, como outras fontes de eletricidade, deve ser programada e bem gerenciada pelos operadores do sistema elétrico.

Embora métodos de previsão de energia eólica sejam usados, a capacidade de prever a produção da usina eólica permanece relativamente baixa para operação de curto e médio prazo. Como a geração e o consumo de eletricidade instantâneos devem permanecer em equilíbrio para manter a estabilidade da rede elétrica, a variabilidade da energia eólica pode apresentar desafios substanciais quando "grandes" quantidades de energia eólica são incorporadas a um sistema de rede interligada. Um fenômeno natural, porém, considerado crítico no setor eólico, são os eventos de rampas de energia, que são mudanças repentinas (aumentos ou reduções) na energia eólica fornecida (OUYANG, ZHA e QIN 2013).

Este tópico apresenta uma visão geral das definições atuais de rampa provenientes de trabalhos realizados sobre energia e previsão de eventos de rampas de energia eólica. Para lidar com esses eventos, os operadores de energia eólica, concessionárias e operadores do sistema elétrico nacional devem desenvolver procedimentos que atendam à demanda de eletricidade, bem como maximizem os benefícios econômicos e ambientais regionais. Quanto antes esses eventos de rampas de energia puderem ser previstos, mais eficazes serão os procedimentos gerenciais.

As rampas ascendentes são caracterizadas por um aumento da energia eólica, que pode resultar de fenômenos como sistemas de baixa pressão intensa (ou ciclones), jatos de baixo nível, tempestades, rajadas de vento ou fenômenos climáticos semelhantes. As rampas descendentes ocorrem quando há uma redução na energia eólica (eventos que geralmente ocorrem com o abrandamento rápido de um gradiente de pressão; ou passagem de "pressure couplet" local, ou seja, área de alta pressão localizada adjacente a uma área de baixa pressão) ou quando ventos de alta velocidade fazem com que as turbinas atinjam limites de corte e sejam desligadas para proteger a turbina eólica de danos estruturais (FREEDMAN *et al.*, 2008). Para ser considerado um evento de rampa, presume-se que a duração mínima seja de 1 h em Potter *et al.* (2009); no entanto, Kamath (2010) estuda eventos em intervalos de 5 a 60 min. A magnitude de um evento de rampa é tipicamente representada pela porcentagem da energia nominal do parque eólico.

Para lidar com um evento de "up ramp" (ou rampa ascendente), o produtor de energia eólica pode desligar as turbinas para evitar a produção excessiva de energia que não pode ser compensado por uma queda repentina na geração térmica, ou pode aumentar sua geração em acordo com o operador do sistema. No último caso, as concessionárias podem negociar os custos da energia não-renovável comprando energia eólica mais barata e renovável. Em um evento "down ramp" (rampas de descida ou descendente), o operador do sistema pode ligar unidades hidrelétricas ou, se este procedimento não gerar energia suficiente para atender à demanda ou não estiver disponível, o operador pode usar turbinas de energia não-renovável para atender à demanda. Se essas medidas não forem suficientes, o corte de carga deve ser adotado – um cenário que os operadores do sistema obviamente tentam evitar (FERREIRA *et al.*, 2011).

Quatro tipos de rampas significativas são definidos com base em Zhang et al. (2014):

- i. magnitude da rampa apenas;
- ii. magnitude e duração da rampa;
- iii. taxa de variação da rampa; e
- iv. direção, magnitude e duração da rampa.

A primeira definição de uma rampa significativa é baseada na magnitude da mudança da energia eólica. Neste trabalho, uma rampa significativa é definida como a mudança na produção de energia eólica superior a 30% da capacidade eólica instalada, expressa como Equação (7):

$$|P(t + \Delta t) - P(t)| > P_{val} \tag{7}$$

em que P(t) é a potência eólica produzida no tempo t; Δt é a duração da rampa, que não é especificada na definição de rampa significativa i; e P_{val} é o valor limite predefinido, que é sugerido 30% da capacidade eólica.

A segunda definição define uma rampa significativa com base na magnitude e na duração da mudança da energia eólica. Neste estudo, a rampa significativa é definida como a variação na produção de energia eólica superior a 25% da capacidade eólica instalada e ocorre em um intervalo de tempo de 4 h ou menos, que também é expresso na Equação (7). Na equação, a duração da rampa, Δt , é menor ou igual a 4 h; e o valor limite, P_{val} , é 25% da capacidade eólica instalada.

A terceira definição de rampas significativas é baseada na taxa de variação da energia eólica. Uma taxa de rampa significativa é definida como a taxa de mudança na produção de energia eólica maior que 10% da capacidade eólica instalada, expressa como Equação (8):

$$\frac{|P(t+\Delta t)-P(t)|}{\Delta t} > R_{val}$$
(8)

Em que R_{val} é o valor limite predefinido da taxa de mudança da potência eólica de saída.

A quarta definição de rampas significativas é baseada na mudança de direção, magnitude e duração da produção de energia eólica. Nesta tese, uma rampa crescente é definida como a mudança na energia eólica superior a 20% da capacidade eólica em um período de 4 h ou menos; e uma redução significativa é definida como a mudança na energia eólica maior que 15% da capacidade eólica em um período de 4 h ou menos. A Equação (9) e (10) representa esta definição:

$$P(t + \Delta t) - P(t) > P_{val}^u \tag{9}$$

$$P(t + \Delta t) - P(t) < -P_{val}^d \tag{10}$$

Em que P_{val}^u e P_{val}^d representam os valores de limite de rampa para cima (*up ramp*) e para baixo (*down ramp*), respectivamente.

3.5 Wavelets

A transformada de Fourier é aplicada para transformar um sinal de seu domínio de tempo para seu domínio de frequência. Os picos no espectro de frequência indicam as frequências mais ocorrentes no sinal. Quanto maior e mais nítido for um pico, mais prevalente será a frequência em um sinal. A localização (valor de frequência) e a altura (amplitude) dos picos no espectro de frequência podem ser usados como entrada para classificadores como o *Random Forest* ou *Gradient Boosting*. A diferença para as Wavelets é que a transformada de Fourier tem uma resolução muito alta no domínio da frequência e resolução zero no domínio do tempo; assim, sabe-se em quais frequências o sinal oscila, mas não em que momento essas oscilações ocorrem.

A saída de uma transformada Wavelet tem alta resolução no domínio da frequência e no domínio do tempo; em suma, são mantidas as informações sobre o domínio do tempo. A transformada Wavelet é a mais adequada para analisar os sinais com um espectro de frequência

dinâmico, ou seja, o espectro de frequência que muda ao longo do tempo, ou tem um componente com uma frequência diferente localizada no tempo (a frequência muda abruptamente por um curto período, por exemplo). Já a transformada de Fourier usa uma série de ondas senoidais com frequências diferentes para analisar um sinal. Ou seja, um sinal é representado por uma combinação linear de ondas senoidais. A transformada Wavelet usa uma série de funções chamadas Wavelets, cada uma com uma escala diferente. A palavra Wavelet significa uma "pequena onda" ou "onduleta", e isso é exatamente o que uma Wavelet é. A principal diferença é que a onda senoidal não está localizada no tempo (ela se estende de $-\infty$ a $+\infty$), enquanto uma Wavelet está localizada no tempo. Isso permite que a transformada Wavelet obtenha informações de tempo, além de informações de frequência.

Reis e Silva (2004) explicam que as Wavelets são utilizadas para lidar com o problema de nãoestacionariedade dos sinais temporais, por exemplo os sinais de vento registrados em torres anemométricas. De acordo com Silveira e Kozakevicius (2016) as funções Wavelets e suas transformadas são ferramentas matemáticas para análise e decomposição hierárquica de funções, ou seja, representação da função em diferentes níveis de resolução, ou escalas. Huang e Wang (2018) salientam que a transformada Wavelet é uma abordagem matemática amplamente utilizada que permite extrair informação de padrões escondidos na série temporal original. Isso se deve ao fato de as Wavelets fornecerem uma boa representação local do sinal tanto no domínio do tempo quanto no domínio da frequência. Diferentemente das bases de Fourier, as Wavelets podem ser mantidas em um intervalo fechado arbitrariamente pequeno (MALLAT, 1989), e, assim, a transformada Wavelet é considerada uma ferramenta poderosa para tratar com fenômenos transitórios. Sabe-se que a série de Fourier é a expansão de um sinal em uma série de senos e cossenos. Os coeficientes resultantes desta operação revelam quais frequências compõem o sinal, porém são ineficazes em fornecer uma informação concisa sobre a ordenação na qual ocorrem diferentes eventos oscilatórios. Isto decorre da utilização de uma base de duração e energia infinitas. Portanto, como forma de tentar corrigir esta deficiência pode-se calcular os coeficientes da série de Fourier em partes do sinal, selecionadas sistematicamente por uma sequência de janelamentos neste. Assim, a perda da variável original não é total, mesmo que ao sacrifício da informação em frequência. A esta técnica é dado o nome de transformada de Fourier em tempo restrito (do inglês, short time Fourier transform). A transformada Wavelet é a expansão de um sinal em uma série de pequenas ondas (Wavelets), e visa ser o próximo passo lógico neste raciocínio (LOUREIRO, 2004).

As famílias Wavelets discretas, como chamadas em Chuanan e Yongchang (2011) e Haque *et al.* (2013), aplicadas à decomposição dos sinais temporais são *Biorthogonal, Biorthogonal Reversa, Coiflet, Daubechies, Meyer discreta e Symlet.* Na literatura, modelos híbridos de previsão de velocidade do vento, energia eólica e rampas de energia são propostos e investigados (SUN *et al.*, 2017). As principais tecnologias para esses dois tipos de modelagem são os algoritmos de decomposição e de previsão de séries temporais (TASCIKARAOGLU e UZUNOGLU, 2014). Por intermédio da Figura 9 pode-se observar, graficamente, famílias de Wavelets discretas representadas por algumas ordens previamente selecionadas e representativas de suas funções.





Figura 9: Famílias Wavelets discretas. Fonte: Autoria própria.

Daubechies (1992) explica que uma transformada Wavelet é uma ferramenta que decompõe dados, funções ou operadores em diferentes componentes de frequência, e então estuda cada componente com uma resolução compatível com sua escala. A transformada Wavelet de um sinal que evolui no tempo depende de duas variáveis: frequência (ou escala) e tempo. As Wavelets fornecem uma ferramenta matemática para localização no domínio do tempo e da frequência, se diferenciando em alguns quesitos, por exemplo, da transformadas de Fourier. Em muitas aplicações, dado um sinal f(t) (no momento, assumindo que t é uma variável contínua), está interessado em seu conteúdo de frequência localmente no tempo. A transformada de Fourier padrão é dada pela seguinte Equação (11):

$$(\mathcal{F}f)(\omega) = \frac{1}{\sqrt{2\pi}} \int dt \, e^{-i\omega t} f(t) \tag{11}$$

também dá uma representação do conteúdo de frequência de f, mas as informações relativas à localização no tempo de, por exemplo, rajadas de alta frequência não pode ser lidas facilmente de $\mathcal{F}f$ (em que \mathcal{F} é o operador tranformada de Fourier). A localização no tempo pode ser alcançada primeiro colocando em janelas o sinal f, de modo a cortar apenas uma fatia bem localizada de f e, em seguida, tomar sua Equação de transformada de Fourier (12):

$$(T^{win}f)(\omega,t) = \int ds f(s)g(s-t)e^{-iws}$$
⁽¹²⁾

Em que f = função; t = tempo; $\omega =$ frequência; g = função janela.

Esta é a transformada de Fourier em janela, que é uma técnica padrão para localização de frequência – tempo. É ainda mais familiar para os analistas de sinais em sua versão discreta, onde $t \in \omega$ são atribuídos a valores regularmente espaçados: $t = nt_0$, $\omega = m\omega_0$, onde m, n variam sobre $\mathbb{Z} \in \omega_0$, $t_0 > 0$ são fixos. Então a Equação (12) se torna a Equação (13):

$$T_{mn}^{win}(f) = \int ds f(s)g(s - nt_0)e^{-im\omega_0 s}$$
⁽¹³⁾

para *n* fixado, $T_{m,n}^{win}(f)$ corresponde aos coeficientes de Fourier de $f(\bullet)g(\bullet -nt_0)$. Se, por exemplo, *g* for compactamente suportado, então com ω_0 apropriadamente escolhido, os coeficientes de Fourier $T_{.,n}^{win}(f)$ são suficientes para caracterizar e, se necessário, reconstruir $f(\bullet)g(\bullet -nt_0)$. Alterar *n* equivale a deslocar as "fatias" em etapas de t_0 e seus múltiplos, permitindo a recuperação de todas as *f* de $T_{m,n}^{win}(f)$. A transformada de Fourier em janela fornece, portanto, uma descrição de *f* no plano tempo-frequência.

A ideia da transformada Wavelet, apresentada pela primeira vez pelo geofísico Jean Moret em 1982 para a análise de ondas sísmicas (DAUBECHIES, 1992), pode ser categorizada como a transformada Wavelet contínua – TWC (em inglês, *continuous Wavelet transform* – CWT) e a transformada Wavelet discreta – TWD (em inglês, *discrete Wavelet transform* – DWT),

(CONEJO et al., 2005 e AMJADY, DARAEEPOUR e KEYNIA, 2010). A Wavelet contínua envolve a escala contínua e a mudança no tempo da Wavelet mãe. A escala alta (advinda do filtro passa-baixa) fornece informações aproximadas sobre o sinal $(A_1, A_2, ..., A_n)$, enquanto a escala baixa (advinda do filtro passa-alta) fornece informações detalhadas do sinal (d_1 , d_2 , ..., d_n). Neste contexto, a escala aproximada revela a tendência do sinal, enquanto as escalas detalhadas tendem a estar relacionadas a influências sazonais e efeitos de variáveis exógenas. A transformada Wavelet fornece uma descrição de tempo-frequência semelhante, com algumas diferenças importantes. Contextualizando, tem-se que redes neurais como aproximadores gerais têm capacidades limitadas na aproximação de sistemas altamente não-lineares, conforme Amjady, Keynia e Zareipour (2011). A transformadas Wavelet tem a capacidade de exibir funções e detectar seus recursos locais no domínio de tempo e frequência de maneira simultânea. Wavelets de baixa e alta resolução podem aproximar comportamentos gerais (baixa frequência) e comportamentos locais (alta frequência) da função, respectivamente. O uso desses recursos leva ao treinamento conveniente junto com a rede neural, precisamente para modelar sinais altamente não-lineares (AMJADY e KEYNIA, 2008). Em uma TWC se os parâmetros de escala e deslocamento forem contínuos a transformada será muito lenta devido à sobreposição de recursos e à duplicidade de dados vizinhos. Além disso, terá dados adicionais e inúteis, de acordo com Mandal, Zareipour e Rosehart (2014). Portanto, a função Wavelet mãe pode ser dimensionada e transladada usando certas escalas e posições conhecidas como TWD.

A TWD usa valores de escala e posição baseados em potências de 2, chamados dilatações diádicas e translações, que são obtidos por discretização dos parâmetros de escala e de translação, denotados como explicado em Amjady e Keynia (2009) e Catalao, Pousinho e Mendes (2011). Esta técnica é composta de dois passos principais: decomposição e reconstrução. Dois tipos de filtros são usados para decompor o sinal original. O filtro passa-alta e o filtro passa-baixa são usados para reduzir a resolução do sinal original. Os componentes decompostos do sinal Wavelet podem ser montados de volta no sinal original sem perda de qualquer informação. Isso é chamado de reconstrução de Wavelets. Como a decomposição Wavelet, o filtro passa-alta e o filtro passa-baixa são usados, e o sinal decomposto é ampliado para obter o sinal original (MANDAL, ZAREIPOUR e ROSEHART, 2014). Na etapa de decomposição, o sinal é dividido em componentes de alta e baixa frequência. Então, altas frequências são mantidas; enquanto as baixas frequências são chamadas de detalhes do sinal e as baixas frequências são aproximações do sinal (AGHAJANI, KAZEMZADEH e

EBRAHIMI, 2016). As fórmulas de transformação Wavelet análogas a (12) e (13) são as Equações (14) e (15):

$$(T^{wav}f)(a,b) = |a|^{-1/2} \int dt f(t)\psi\left(\frac{t-b}{a}\right)$$
(14)

$$T_{m,n}^{wav}(f) = a_0^{-m/2} \int dt f(t) \psi(a_0^{-m}t - nb_0)$$
(15)

em ambos os casos, assumimos que ψ satisfaz, $\int dt \psi(t) = 0$. A Equação (15) é novamente obtida de (14) restringindo *a*, *b* apenas a valores discretos: $a = a_0^m$, $b = nb_0a_0^m$, neste caso, com *m*, *n* variando no conjunto $\mathbb{Z} e a_0 > 1$, $b_0 > 0$ fixos. Uma semelhança entre as transformadas Wavelet e de Fourier em janela é clara: ambos (12) e (14) tomam os produtos internos de *f* com uma família de funções indexadas por dois rótulos, $g^{w,t}(s) = e^{iws}g(s-t)$ em (12) e $\psi^{a,b}(s) = |a|^{-1/2}\psi\left(\frac{s-b}{a}\right)$ em (14). As funções $\psi^{a,b}$ são chamadas de "Wavelets"; a função ψ às vezes é chamada de "Wavelet mãe". Daubechies (1992) observa que ψ e *g* são implicitamente assumidos como reais, embora isso não seja de forma alguma essencial; se não forem, os conjugados complexos devem ser introduzidos em (12) e (14). Existem tipos diferentes de transformada Wavelet, mas todos partindo das fórmulas básicas (14), (15). Assim, é distiguido entre: *i*) a transformada Wavelet contínua (14); e *ii*) a transformada Wavelet discreta (15). A Wavelet de Meyer ($\hat{\psi}$) e a função de escala ($\hat{\phi}$) são definidas no domínio da frequência. Daubechies (1992) explica que tanto $\hat{\psi}$ quanto $\hat{\phi}$ são definidos no domínio da frequência, começando com uma função auxiliar (ν). Então, a função Wavelet de Meyer é representada pelas Equações (16) a (18):

$$\hat{\psi}(\omega) = (2\pi)^{-1/2} e^{i\omega/2} \sin\left[\frac{\pi}{2}\nu\left(\frac{3}{2\pi}|\omega| - 1\right)\right] \quad if \quad \frac{2\pi}{3} \le |\omega| \le \frac{4\pi}{3}$$
(16)

$$\hat{\psi}(\omega) = (2\pi)^{-1/2} e^{i\omega/2} \cos\left[\frac{\pi}{2}\nu\left(\frac{3}{4\pi}|\omega| - 1\right)\right] \quad if \quad \frac{4\pi}{3} \le |\omega| \le \frac{8\pi}{3} \tag{17}$$

$$\hat{\psi}(\omega) = 0 \quad if \quad |\omega| \notin \left[\frac{2\pi}{3}, \frac{8\pi}{3}\right] \tag{18}$$

e função de escala pelas Equações (19) a (21),

$$\hat{\phi}(\omega) = (2\pi)^{-1/2} \quad if \quad |\omega| \le \frac{2\pi}{3}$$
 (19)

$$\hat{\phi}(\omega) = (2\pi)^{-1/2} \cos\left[\frac{\pi}{2}\nu\left(\frac{3}{2\pi}|\omega| - 1\right)\right] \quad if \quad \frac{2\pi}{3} \le |\omega| \le \frac{4\pi}{3}$$
(20)

$$\hat{\phi}(\omega) = 0 \quad if \quad |\omega| > \frac{4\pi}{3} \tag{21}$$

Entende-se que a sutil diferença entre o processo de decomposição e um processo de filtragem está no fator associado à variável de deslocamento da convolução, significando o descarte alternado de metade das amostras resultantes. A estrutura recursiva de decomposição dos coeficientes de aproximação recebe o nome de árvore ou expansão diádica (MALLAT, 1989). A partir de um conjunto de amostras, outros dois são obtidos, resultantes de uma filtragem seguida de decimação ou sub-amostragem. A quantidade de amostras gerada é praticamente a mesma (dobra-se o número de amostras com a aplicação de dois filtros, e depois corta-se metade com a decimação), só não o sendo devido à característica do processo de convolução de adicionar uma quantidade de amostras de acordo com o tamanho do filtro utilizado. A perda de informação (amostras) causada pela decimação propicia o falseamento (do inglês, *aliasing*) no espectro de freqüência do sinal filtrado mas, uma vez satisfeitas as condições impostas aos filtros, a informação aparentemente perdida em uma banda está armazenada na outra e esta é a ideia por trás da reconstrução perfeita na teoria de bancos de filtros (LOUREIRO, 2004). Como já explicado, a transformada de Wavelets tem qualidades atraentes que a fazem um método muito útil para séries temporais, exibindo características que poderiam variar tanto em tempo como em freqüência (ou escala). Entre as aplicações das Wavelets no setor elétrico, pode-se mencionar proteção de sistemas de potência, qualidade de potência, previsão de carga, medidas de um sistema de potência, e transientes de sistemas de potência (surto de tensão elétrica que ocorre num intervalo de tempo muito pequeno).

3.6 Convolução matemática

A operação de convolução é aplicada em várias situações na matemática e na engenharia, fazendo uso de diferentes ferramentas para a sua solução. Esta operação opera com duas funções ou com dois sinais, x(t) e h(t), para gerar uma terceira função ou sinal como resultado

da operação, y(t). A interpretação para a função h(t), na engenharia, é que esta é a resposta impulsiva de um sistema linear e invariante no tempo, mas também não deixa de ser uma função matemática que descreve as características intrínsecas de um sistema. O princípio da superposição é válido em sistemas lineares. Nos sistemas invariantes no tempo, um atraso no sinal de entrada, provoca o correspondente atraso no sinal de saída (SOVIERZOSKI, 2010).

A operação de convolução para sinais de tempo contínuo é definida pela Equação (22) e Equação (23), na qual o símbolo * em (22) é a representação gráfica da operação de convolução entre as funções x(t) e h(t), e a integral em (23) é denominada de integral da convolução. Lê-se que o sinal y(t) é o sinal x(t) convoluido com o sinal h(t). A variável de integração é alterada para τ (*letra grega* – *tal*). Na integral de convolução, uma das funções sofre apenas a mudança de variável $x(\tau)$, enquanto a outra função sofre a mudança de variável $h(\tau)$, seguida pela operação de reflexão $h(-\tau)$, e por um deslocamento pela variável t, resultando em $h(t - \tau)$.

$$y(t) = x(t) * h(t)$$
⁽²²⁾

$$y(t) = \int_{-\infty}^{+\infty} x(\tau) \cdot h(t-\tau) d\tau$$
⁽²³⁾

Assim, entende que a operação de convolução é um operador linear possuindo as propriedades matemáticas de comutatividade, de distributividade e de associatividade. A convolução de dois sinais contínuos finitos, por exemplo, x(t) com duração L_x e y(t) com duração L_y , resultará num sinal convoluido com duração $L_x + L_y$. Considerando o sinal x(t) contido no intervalo $[I_x, F_x]$, e o sinal y(t) contido no intervalo $[I_y, F_y]$, e devido às operações de reflexão e deslocamento o resultado da convolução dos sinais contínuos finitos estará contida no intervalo $[I_x + I_y, F_x + F_y]$.

A definição matemática da convolução para sinais de tempo discreto é semelhante à de sinais de tempo contínuo, sendo que as variáveis envolvidas agora são variáveis discretas, e a integral transforma-se em um somatório, conforme é apresentado na Equação (24) e, por conseguinte, na Equação (25).

$$y[n] = x[n] * h[n] \tag{24}$$

$$y[n] = \sum_{k=-\infty}^{+\infty} x[n] * h[n-k]$$
⁽²⁵⁾

A convolução é denominado de soma da convolução. As propriedades matemáticas de comutatividade, distributividade e associatividade também se aplicam à convolução de funções discretas. Para o caso da convolução de sinais discretos finitos, por exemplo, x[n] com L_x amostras e y[n] com L_y amostras, o sinal convoluido possuirá $L_x + L_y - 1$ amostras. Com as amostras significativas de x[n] estando no intervalo $[I_x, F_x]$, e as amostras significativas de y[n] estando no intervalo $[I_y, F_y]$, devido às operações de reflexão e deslocamento, o sinal convoluido estará restrito ao intervalo $[I_x + I_y, F_x + F_y]$, conforme explica Sovierzoski (2010).

3.7 Inteligência computacional

Entende-se que as redes neurais formalizam um campo de pesquisas e estudos da inteligência computacional a qual, por sua vez, é um subcampo da Ciência da Computação. Uma definição concisa do campo da inteligência computacional, por Chollet (2018), seria a seguinte: "o esforço para automatizar tarefas intelectuais normalmente realizadas por humanos". Chollet (2018) explica ainda que "um sistema de aprendizado de máquina (do inglês machine learning) é treinado em vez de programado explicitamente. É apresentado com muitos exemplos relevantes para uma tarefa e encontra uma estrutura estatística nesses exemplos que eventualmente permite que o sistema crie regras para automatizar a tarefa desejada". Este autor define que "o aprendizado profundo (do inglês deep learning) é um subcampo específico do aprendizado de máquina: uma nova abordagem sobre a aprendizagem de representações a partir de dados que enfatiza o aprendizado de camadas sucessivas de representações cada vez mais significativas". Para Chollet (2018), "a aprendizagem profunda não é uma referência a qualquer tipo de compreensão mais profunda alcançada pela abordagem; em vez disso, representa essa ideia de camadas sucessivas de representações". Outras definições encontradas na literatura, não menos importantes, são destacadas na Figura 10, onde há uma ilustração da relação entre inteligência computacional ou artificial, aprendizado de máquina e aprendizado profundo. Os algoritmos de aprendizado de máquina podem ser classificados em diferentes tipos, conforme mostrado na Figura 11.



Figura 10: Relação entre inteligência computacional ou artificial, aprendizado de máquina e

aprendizado profundo.

Fonte: Autoria própria.



Figura 11: Tipos de aprendizado de máquina. Fonte: Autoria própria.

- a) Aprendizado supervisionado: "Consiste em aprender a mapear dados de entrada para alvos conhecidos (também chamados de anotações), dado um conjunto de exemplos (muitas vezes anotados por humanos)".
- b) Aprendizado semisupervisionado: "Esta é uma instância específica de aprendizagem supervisionada, mas é diferente o suficiente para merecer sua própria categoria. O aprendizado semisupervisionado é o aprendizado supervisionado sem rótulos anotados por humanos. Ainda há rótulos envolvidos, mas eles são gerados a partir dos dados de entrada, normalmente usando um algoritmo heurístico".
- c) Aprendizado não-supervisionado: "Este ramo do aprendizado de máquina consiste em encontrar transformações interessantes dos dados de entrada sem a ajuda de quaisquer alvos, para fins de visualização de dados, compressão de dados ou remoção de ruído de dados, ou para melhor compreender as correlações presentes nos dados em mãos".
- d) Aprendizado por reforço: "Na aprendizagem por reforço, um agente recebe informações sobre seu ambiente e aprende a escolher ações que irão maximizar alguma recompensa. Por exemplo, uma rede neural que "olha" para a tela de um videogame e emite ações do jogo para maximizar sua pontuação pode ser treinada por meio de aprendizado por reforço. Atualmente, a aprendizagem por reforço é principalmente uma área de pesquisa e ainda não teve sucessos práticos significativos além dos jogos".

Russel e Norvig (2010, p.16) explicam que o primeiro trabalho reconhecido como inteligência artificial foi realizado por Warren McCulloch e Walter Pitts em 1943. Eles se basearam em três fontes: o conhecimento da fisiologia básica e da função dos neurônios no cérebro; uma análise formal da lógica proposicional criada por Russell e Whitehead; e a teoria da computação de Turing. Esses dois pesquisadores propuseram um modelo de neurônios artificiais, no qual cada neurônio se caracteriza por estar "ligado" ou "desligado", com a troca para "ligado" ocorrendo em resposta à estimulação por um número suficiente de neurônios vizinhos. O estado de um neurônio era considerado "equivalente em termos concretos a uma proposição que definia seu estímulo adequado". Por exemplo, eles mostraram que qualquer função computável podia ser calculada por certa rede de neurônios conectados e que todos os conectivos lógicos (e, ou, não etc.) podiam ser implementados por estruturas de redes simples. McCulloch e Pitts também sugeriram que redes definidas adequadamente seriam capazes de aprender. Donald Hebb em 1949 demonstrou uma regra de atualização simples para modificar as intensidades de conexão

entre neurônios. Sua regra, chamada aprendizado de Hebb, continua a ser um modelo influente até hoje. A seguir, é apresentada a teoria das redes neurais.

3.7.1 Redes neurais artificiais

Sabe-se que as RNA são implementadas através de camadas com os nós interconectados, também chamados de neurônios, e a definição do número de camadas é muito variável, dependendo das características de cada problema a ser resolvido. Em estudos como o desta tese, elas exigem pelo menos três camadas, sendo uma camada de entrada com os nós que recebem os inputs (entradas do sistema, exemplo: variáveis meteorológicas), uma camada oculta onde localizam os neurônios, e uma camada de saída com os nós que fornecem os outputs, os quais representam as saídas do sistema, por exemplo, pode-se citar a velocidade do vento predita (RUSSEL e NORVIG, 2010, p.729). A Figura 12 apresenta um modelo matemático simples do neurônio desenvolvido por McCulloch e Pitts em 1943. Em síntese, o neurônio "dispara" quando uma combinação linear de suas entradas excede algum limiar (rígido ou suave), ou seja, ele implementa um classificador linear. Uma rede neural é apenas uma coleção de unidades conectadas; as propriedades da rede são determinadas pela sua topologia (se refere às diferentes composições estruturais possíveis com diferentes quantidades de neurônios nas camadas de entrada, intermediária e de saída da rede) e pelas propriedades dos neurônios. Neste modelo matemático, a ativação de saída da unidade é $a_i = g(\sum_{i=0}^n w_{i,i}a_i)$, onde a_i é a ativação de saída da unidade i e $w_{i,i}$ é o peso sobre a ligação da unidade *i* com essa unidade.



Figura 12: Modelo matemático simples de um neurônio. Fonte: Adaptado de Russel e Norvig (2010, p.728)

As redes neurais são compostas por nós ou unidades conectadas por ligações direcionadas. Uma ligação da unidade *i* para a unidade *j* serve para propagar a ativação a_i de *i* para *j*. Cada ligação também tem um peso numérico $w_{i,j}$ associado a ele, que determina a força e o sinal de conexão. Assim como em modelos de regressão linear, cada unidade tem uma entrada fictícia $a_0 = 1$ com peso associado $w_{0,j}$. Russel e Norvig (2010, p.728) explica que cada unidade *j* primeiro calcula uma soma ponderada de suas entradas como na Equação (26):

$$in_j = \sum_{i=0}^n w_{i,j} a_i \tag{26}$$

Em seguida, aplica uma função de ativação g a essa soma para obter a saída como na Equação (27):

$$a_j = g(in_j) = g(\sum_{i=0}^n w_{i,j}a_i)$$
⁽²⁷⁾

A ativação da função *g* tipicamente é tanto um limiar rígido, caso em que a unidade é chamada de *perceptron*, como uma função logística, caso em que por vezes é utilizado o termo *perceptron sigmoide*. Ambas as funções de ativação não linear garantem a propriedade importante de que toda a rede de unidades pode representar uma função não linear. A função de ativação logística tem a vantagem adicional de ser diferenciável. Tem-se que a função de ativação é um componente matemático incluído na estrutura da rede a fim de permitir a solução dos problemas complexos estudados. Pode-se citar como exemplos:

- i. Função de Etapa Binária (Binary Step Function);
- ii. Função Linear;
- iii. Sigmóide (função de ativação amplamente utilizada);
- Tangente sigmóide hiperbólica ou Tanh (a função tanh é muito semelhante à função sigmóide, sendo uma versão escalonada desta);
- v. *Rectified Linear Unit activation function* ou ReLU (a função ReLU é a unidade linear retificada);
- vi. Leaky version of a Rectified Linear Unit ou Leaky ReLU (a função Leaky ReLU é uma versão aprimorada da função ReLU);

- vii. Softmax (a função softmax também é um tipo de função sigmóide, mas é útil quando se trabalha com problemas de classificação);
- viii. Dentre outras, tais como é implementado no Keras: PReLU ou Parametric Rectified Linear Unit; ELU ou Exponential Linear Unit; Thresholded Rectified Linear Unit ou Thresholded ReLU.

Tendo decidido sobre o modelo matemático para os neurônios individuais, a próxima tarefa é conectá-los para formar uma rede neural. Existem duas formas fundamentalmente distintas para se fazer isso. A primeira, é por meio de uma rede com alimentação para a frente a qual tem conexões somente em uma direção, isto é, forma um grafo acíclico dirigido. Cada nó recebe a entrada de nós "para cima" e libera a saída de nós "para baixo"; não há laços. Uma rede com alimentação para a frente representa uma função de sua entrada atual; portanto, não tem estado interno que não seja os próprios pesos *bias* (Figura 13). A segunda maneira é descrita a seguir.



Figura 13: RNA do tipo *multilayer perceptron*. Fonte: Autoria própria.

3.7.2 Redes neurais recorrentes

A rede recorrente ou RNN, do inglês *recurrent neural network*, (Figura 14), por outro lado, alimenta suas saídas de volta às suas próprias entradas. Isso significa que os níveis de ativação da rede formam um sistema dinâmico que pode atingir um estado estável ou apresentar

oscilações, ou até mesmo um comportamento caótico. Além disso, a resposta da rede para determinada entrada depende do seu estado inicial, o qual pode depender das entradas anteriores. Portanto, as redes neurais recorrentes (ao contrário das redes com alimentação somente para a frente) podem suportar memórias de curto prazo.



Figura 14: RNN do tipo multilayer perceptron.

Fonte: Autoria própria.

Como toda RNA precisa ser treinada, validada e testada, Pelletier, Masson e Tahan (2016) descrevem que o treinamento de uma rede neural ocorre em duas fases nas quais cada fase percorre a rede em um sentido. Essas duas fases, já citadas anteriormente, são chamadas de *forward* e *backward*. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada. Já a fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. Em suma, o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem e as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido. O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar o objetivo do projeto desejado (HAYKIN 1998, p.72).

Para se desenvolver um modelo de RNA, por meio de aprendizado supervisionado, é necessário que se tenha um conjunto de parâmetros de entrada (*inputs*), os valores registados da variável que se pretende prever (*targets*), e um conjunto de saída (*outputs*). Esses conjuntos serão

subdivididos para aplicação e análises em 3 etapas diferentes: treinamento da rede e validação das estimativas produzidas, e o teste propriamente dito (o qual ocorre após o treinamento e a validação da rede). A correta seleção dos preditores (atributos mais importantes para o treinamento, o que permite simplificar os modelos e reduzir o tempo de cálculo) e dos hiperparâmetros (por ex.: quantidade de neurônios, taxa de aprendizado, épocas, *momentum*, *batch*) é fundamental para um bom desempenho do modelo computacional, conforme explicam Mori e Umezawa (2009). Vale ressaltar que durante a etapa de treinamento, o cientista deve ficar atento pois pode ocorrer os fenômenos de *overfitting* e *underfitting*. O *overfitting* ocorre quando o modelo se ajusta em demasia aos dados de treino, mas perde a sua capacidade de obter boas generalizações em dados inéditos; já o *underfitting* ocorre quando o modelo não consegue se ajustar aos dados de nenhuma maneira, ou seja, a rede apresenta baixa *performance* e apresenta resultados ruins na base de treinamento.

O conjunto de validação é um conjunto de dados através do qual, durante o treinamento, será também calculado o erro cuja finalidade é monitorar o nível de ajuste da RNA aos dados de treinamento. Já "generalização" é a capacidade de a RNA responder corretamente aos padrões nunca vistos, ou seja, conjunto de dados para teste. Diversas são as possibilidades de estruturação de uma RNA, uma vez que é necessário selecionar o tipo de neurônio, o número de parâmetros de entrada, o número de camadas ocultas, o tipo de treinamento, sendo que testes com diferentes configurações são geralmente empregados para a definição de sua arquitetura, de acordo com Haykin (1998, p.179). Na Figura 15 observa-se o fluxograma das etapas para previsão usando RNA via aprendizado de máquina supervisionado.



Figura 15: Fluxograma das etapas para previsão usando RNA via aprendizado de máquina supervisionado.

Fonte: Autoria própria.

O stochastic gradient descent é um algoritmo de otimização mais eficiente descoberto para treinar redes neurais artificiais, onde os pesos são os parâmetros do modelo e a função de perda de destino é o erro de predição calculado sobre um subconjunto (*batch*) de todo o conjunto de dados de treinamento. Existem muitas extensões para a o *stochastic gradient descent* projetadas para melhorar o processo de otimização (isto é, perda igual ou menor em menos iterações computacionais), como *Momentum, Root Mean Square Propagation (RMSProp)* e *Adaptive Movement Estimation (Adam)*. O algoritmo Adam foi projetado para acelerar o processo de otimização, por exemplo, diminuir o número de avaliações de função necessárias para atingir o estado ótimo, ou para melhorar a capacidade do algoritmo de otimização, por exemplo, resultar em um melhor resultado final. Um desafio ao usar o *stochastic gradient descent* para treinar uma rede neural é como calcular o gradiente para os nós em camadas ocultas na rede, por exemplo, nós uma ou mais etapas de distância da camada de saída do modelo. Isso requer uma técnica específica de cálculo chamada regra da cadeia e demanda de um algoritmo eficiente que implemente a regra da cadeia que pode ser usada para calcular gradientes para qualquer

parâmetro na rede. Este algoritmo é denominado de *backpropagation* ou retropropagação em português. Um algoritmo genérico (também chamado de *pseudocódigo*) de retropropagação, para a aprendizagem em redes multicamadas, pode ser exemplificado como a seguir:

```
entradas: exemplos, um conjunto de exemplos, cada um com vetor de entrada x
e vetor de saída y rede, uma rede multicamadas com L camadas, pesos w<sub>i,i</sub>,
função de ativação q
variáveis locais: A, um vetor de erros, indexado por nó de rede
repetir
       para cada peso w<sub>i,j</sub> na rede faça
              w<sub>i,i</sub> \leftarrow um número randômico pequeno
       para cada exemplo (x,y) em exemplos faça
               /*propagar as entradas para a frente para computar as saídas*/
              para cada nó i na camada de entrada faça
                      a_i \leftarrow x_i
              para 1 = 2 até L faça
              para cada nó j na camada l faça
                      in<sub>j</sub> \leftarrow Σ<sub>i</sub> w<sub>i,j</sub> a<sub>i</sub>
                      a_i \leftarrow g(in_i)
/*propagar deltas retrocedendo da camada de saída para a camada de entrada*/
para cada nó j na camada de saída faça
       \Delta[j] \leftarrow g'(in_j)x(y_i-a_j)
para 1 = L - 1 até 1 faça
       para cada nó i na camada l faça
              Δ[i] ← g'(in<sub>i</sub>)Σ<sub>j</sub>w<sub>i,j</sub> Δ[j]
/*atualiza cada peso na rede usando deltas*/
para cada peso w<sub>i,j</sub> na rede faça
       w_{i,j} \leftarrow w_{i,j} + a \times a_i \times \Delta[j]
até que algum critério de parada seja satisfeito
retorno rede
```

Conforme Cao, Farnham e Lall (2017), Liu, Mi e Li (2018) e Chen *et al.* (2018), as redes neurais recorrentes são as mais usuais em estudos de previsão de séries temporais e a evolução de sua arquitetura tem se desenvolvido rapidamente. Sua aplicação de forma híbrida, junto a decomposição *Wavelets*, por exemplo, também tem sido realizada, como se pode verificar em Aghajani, Kazemzadeh e Ebrahimi (2016). Cao, Farnham e Lall (2017) e Jones (2017) descrevem que o algoritmo Levenberg–Marquardt *backpropagation* é o principal algoritmo de

treinamento de redes neurais recorrentes. Porém, outros algoritmos de otimização do modelo também são aplicados na literatura, tais como *stochastic gradiente descendente* – SGD, RMSprop, Adam, Adadelta, Adagrad, Adamax, Nadam, e Ftrl, ambos implementados na biblioteca do *Keras como* otimizadores.

3.7.3 Redes LSTM e GRU

Chen *et al.* (2018) informam que como uma variante da RNN tradicional e mais simples, a *long short-term memory neural network* (LSTM) pode aprender profundamente as dependências temporais de longo prazo a partir de dados de séries temporais e, assim, resolver o problema do "gradiente de desaparecimento" (do inglês, *vanishing gradient*) de forma eficaz em comparação com a RNN tradicional. Jones (2017) explica que a *gated recurrent unit* (GRU) é mais simples do que a LSTM, pode ser treinada com mais rapidez e pode ser mais eficiente em sua execução. No entanto, a LSTM pode ser mais expressiva e, com mais dados, pode levar a resultados melhores (mais acurados e precisos).

A LSTM surgiu das arquiteturas de rede neurais típicas baseadas em neurônios, e introduziu o conceito de célula de memória. A célula de memória pode manter seu valor por um tempo curto ou longo como uma função de suas entradas, o que permite que a célula se lembre daquilo que é importante e não apenas de seu último valor computado. A célula de memória da LSTM contém três portões que controlam como as informações fluem para dentro e para fora da célula. O portão de entrada (*input gate*) controla quando as novas informações podem entrar na memória. O portão de esquecimento (*forget gate*) controla quando uma parte existente das informações deve ser esquecida, permitindo que a célula se lembre de novos dados. Finalmente, o portão de saída (*output gate*) controla quando as informações contidas na célula são usadas na saída da célula. A célula também contém pesos, que controlam cada portão. O algoritmo de treinamento tem a função de otimizar esses pesos com base no erro de saída da rede resultante (JONES, 2017). Na Figura 16 pode ser observado um esquema da LSTM e sua célula de memória.



Figura 16: Esquema da rede LSTM e sua célula de memória. Fonte: Chen *et al.* (2018).

A implementação de atualização do estado da célula LSTM e o cálculo da saída pode ser seguido conforme Equações (28) a (34):

Portão de entrada (input gate):

$$i_t = \sigma \Big(W_{ix} x_t + W_{ip} p_{t-1} + W_{ie} e_{t-1} + b_i \Big)$$
(28)

Portão de saída (output gate):

$$o_t = \sigma (W_{ox} x_t + W_{op} p_{t-1} + W_{oe} e_t + b_o)$$
⁽²⁹⁾

Portão de esquecimento (forget gate):

$$f_t = \sigma \Big(W_{fx} x_t + W_{fp} p_{t-1} + W_{fe} e_{t-1} + b_f \Big)$$
(30)

Célula de estado temporário:

$$\widetilde{e}_t = g(W_{ex}x_t + W_{ep}p_{t-1} + b_e) \tag{31}$$

Célula de estado:

 $e_t = i_t \odot \tilde{e_t} + f_t \odot e_{t-1} \tag{32}$

Saída:

$$p_t = o_t \odot h(e_t) \tag{33}$$

Camada de saída:

$$y_t = \varphi \Big(W_{yp}. p_t + b_y \Big) \tag{34}$$

Em que: x_t é o vetor de entrada; y_t é o vetor de saída; i_t é a saída do portão de entrada; o_t é o portão de saída; f_t é o portão de esquecimento; $\tilde{e_t}$ e e_t é o estado temporário e de acabamento da célula de memória no bloco de memória, respectivamente; p_t é a saída do bloco de memória; σ denota o portão da função de ativação (geralmente, função sigmoide logística); g e h são, respectivamente, a função de ativação de entrada e de saída (usualmente, função tangente hiperbólica); \odot é o produto Hadamard entre dois vetores; φ é a função de ativação de saída da LSTM (função linear); W_{ix} , W_{ip} , W_{ie} , W_{ox} , W_{op} , W_{oe} , W_{fx} , W_{fp} , W_{fe} , W_{ex} , W_{ep} e W_{yp} representam os pesos matriciais; b_i , b_o , b_f , b_e e b_y são os vetores de *bias* relacionados.

A GRU inclui dois portões: um portão de atualização e um portão de reconfiguração (*update gate* e *reset gate*). O portão de atualização indica quanto deve ser mantido do conteúdo da célula anterior. O portão de reconfiguração define como incorporar a nova entrada ao conteúdo da célula anterior. Uma GRU pode modelar uma RNN padrão simplesmente configurando o portão de reconfiguração para 1 e o portão de atualização para 0. Na Figura 17 verifica-se a arquitetura da GRU.



Figura 17: Arquitetura da Rede GRU. Fonte: Li *et al.* (2019).

Já a implementação de atualização do estado da célula GRU e o cálculo da saída pode ser seguido conforme Equações de (35) a (38):

$$\mathbf{z}_t = \sigma(\mathbf{W}_{xz}\mathbf{x}_t + \mathbf{U}_{hz}\mathbf{h}_{t-1} + \mathbf{b}_z) \tag{35}$$

$$\mathbf{r}_{t} = \sigma(\mathbf{W}_{xr}\mathbf{x}_{t} + \mathbf{U}_{hr}\mathbf{h}_{t-1} + \mathbf{b}_{r})$$
(36)

$$\mathbf{c}_{t} = tanh(\mathbf{W}_{xc}\mathbf{x}_{t} + \mathbf{U}_{hc}(\mathbf{r}_{t} \odot \mathbf{h}_{t-1}) + \mathbf{b}_{c})$$
(37)

$$\mathbf{h}_t = (1 - \mathbf{z}_t) \odot \mathbf{h}_{t-1} + \mathbf{z}_t \odot \mathbf{c}_t \tag{38}$$

Em que: \mathbf{z}_t é a saída do portão de atualização; \mathbf{r}_t é a saída do portão de reconfiguração; \mathbf{x}_t é a t-ésima amostra dos dados de entrada $\mathbf{x} = {\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_t, ..., \mathbf{x}_m}$; σ é a função sigmoide logística, frequentemente usada como as funções de ativação do *update gate* e *reset gate*, e *tanh* é a função tangente hiperbólica e é usada como a função de ativação do estado candidato; \mathbf{c}_t é o estado candidato; \mathbf{h}_t é a saída da GRU; \odot é o produto Hadamard entre dois vetores; \mathbf{W}_{xz} , \mathbf{W}_{xr} e \mathbf{W}_{xc} são denotados como os pesos matriciais entre a camada de entrada e o portão de atualização, portão de reconfiguração e estado candidato, respectivamente; \mathbf{U}_{hz} , \mathbf{U}_{hr} e \mathbf{U}_{hc} representam os pesos matriciais das conexões de ciclo, e \mathbf{b}_z , \mathbf{b}_r e \mathbf{b}_c são os correspondentes vetores de *bias*.

3.7.4 Redes convolucionais

Já as redes neurais convolucionais (do inglês, *convolutional neural network* ou CNN) são um tipo especializado de rede neural para processamento de dados. Os exemplos incluem dados de séries temporais, que podem ser considerados como um vetor obtendo amostras em intervalos de tempo regulares, e dados de imagem, que podem ser considerados como uma matriz de pixels. As redes neurais convolucionais têm sido extremamente bem-sucedidas em aplicações práticas. O nome rede neural convolucional indica que a rede emprega uma operação matemática chamada convolução. As redes convolucionais são simplesmente redes neurais que usam convolução no lugar da multiplicação geral da matriz em pelo menos uma de suas camadas, de acordo com Goodfellow, Bengio e Courville (2017, p.326). Na Figura 18 observase um exemplo de topologia da rede neural convolucional. Já a Figura 19, tem-se um exemplo de convolução matemática.



Figura 18: Exemplo de topologia da rede neural convolucional.

Fonte: Autoria própria.



Figura 19: Exemplo de convolução matemática.

Fonte: Adaptado de Goodfellow, Bengio e Courville (2017, p.330).

Em aplicações de aprendizado de máquina, a entrada é geralmente uma matriz multidimensional de dados, e o kernel é geralmente uma matriz multidimensional de parâmetros

que são adaptados pelo algoritmo de aprendizagem. Como cada elemento da entrada e do kernel deve ser explicitamente armazenado separadamente, geralmente assume-se que essas funções são zero em todos os lugares, exceto no conjunto finito de pontos para os quais armazenamos os valores. Isso significa que, na prática, podemos implementar a soma infinita como uma soma sobre um número finito de elementos da matriz. Camadas de rede neural tradicionais usam multiplicação de matriz de dados por uma matriz de parâmetros com um parâmetro separado que descreve a interação entre cada unidade de entrada e cada unidade de saída. Isso significa que cada unidade de saída interage com cada unidade de entrada. Redes convolucionais, no entanto, geralmente têm interações esparsas (também chamadas de conectividade esparsa ou pesos esparsos). Isso é feito tornando o kernel menor do que a entrada. Por exemplo, ao processar uma imagem, a imagem de entrada pode ter milhares ou milhões de pixels, mas podese detectar recursos pequenos e significativos, como bordas com kernels que ocupam apenas dezenas ou centenas de pixels. Isso significa que se precisa armazenar menos parâmetros, o que reduz os requisitos de memória do modelo e melhora sua eficiência estatística.

3.8 Relações comerciais do setor elétrico no Brasil

Uma discussão que merece destaque quando se trata de previsão de energia é sobre as relações comerciais do setor elétrico no Brasil. CCEE (2021) explica que as relações comerciais no atual modelo do setor elétrico brasileiro se estabelecem no Ambiente de Contratação Regulada – ACR e no Ambiente de Contratação Livre – ACL. No Mercado de Curto Prazo – MCP, são contabilizadas e liquidadas as diferenças entre os montantes gerados, contratados e consumidos. A Câmara de Comercialização de Energia Elétrica – CCEE zela pelo bom funcionamento destes três ambientes. Os leilões de energia elétrica realizados pela CCEE, por delegação da Agência Nacional de Energia Elétrica – Aneel, constituem-se um dos principais mecanismos de comercialização no Brasil. Como instituição responsável pelo equilíbrio operacional do mercado de comercialização de energia, a CCEE atua sempre em sintonia com as demais instituições do setor elétrico brasileiro. Por meio da Figura 20 observa-se a estrutura do setor de energia elétrica no Brasil.


Figura 20: Estrutura do setor de energia elétrica no Brasil. Fonte: CCEE (2021).

O Conselho Nacional de Política Energética – CNPE está interligado ao Ministério de Minas e Energia – MME e o mesmo se comunica com o Comitê de Monitoramento do Setor Elétrico – CMSE e a Empresa de Pesquisa Energética – EPE. A Aneel tem as atribuições de regular e fiscalizar a produção, transmissão, distribuição e comercialização de energia elétrica, e esta agência reguladora se interliga com o Operador Nacional do Sistema Elétrico – ONS e com a CCEE.

CCEE (2021) relata que os leilões de compra de energia elétrica realizados pela CCEE, por delegação da Aneel, ocupam papel essencial no ACR. Os compradores e vendedores de energia participantes dos leilões formalizam suas relações comerciais por meio de contratos registrados no âmbito do ACR. Nos leilões estruturantes definidos pelo Conselho Nacional de Política Energética – CNPE, os leilões são realizados diretamente pela Aneel. Os contratos desse ambiente têm regulação específica para aspectos como preço da energia, submercado de registro do contrato e vigência de suprimento, os quais não são passíveis de alterações bilaterais por parte dos agentes. Apesar de não ser contratada em leilões, a energia gerada pela usina binacional de Itaipu e a energia associada ao Programa de Incentivo às Fontes Alternativas de Energia Elétrica – Proinfa são enquadradas no ACR, pois sua contratação é regulada, com condições específicas definidas pela Aneel.

Todos os contratos de compra e venda de energia celebrados no mercado – tanto no ACR como no ACL – devem ser registrados na CCEE, que realiza a medição dos montantes efetivamente produzidos/consumidos por cada agente. As diferenças apuradas, positivas ou negativas, são contabilizadas para posterior liquidação financeira no MCP e valoradas ao Preço de Liquidação das Diferenças – PLD. Assim, o MCP pode ser definido como o segmento da CCEE onde são contabilizadas as diferenças entre os montantes de energia elétrica contratados pelos agentes e os montantes de geração e de consumo efetivamente verificados e atribuídos aos respectivos agentes. No MCP não existem contratos, ocorrendo a contratação multilateral, conforme as Regras de Comercialização (CCEE, 2021).

A CCEE (2021) informa que a partir de janeiro de 2021, o PLD passou a ser calculado pela CCEE diariamente para cada hora do dia seguinte com base no custo marginal de operação, considerando a aplicação dos limites máximos e mínimo vigentes para cada período de apuração e para cada submercado. Na CCEE são utilizados os mesmos modelos adotados pelo ONS para determinação da programação e despacho de geração do sistema, com as adaptações necessárias para refletir as condições de formação de preços. No cálculo do PLD não são consideradas as restrições elétricas internas que não impactam a capacidade de intercâmbio entre os submercados, de forma que a energia comercializada seja tratada como igualmente disponível em todos os seus pontos de consumo e que, consequentemente, o preço seja único dentro de cada uma dessas regiões. Como exemplo, para o dia 18/01/2021, teve-se um valor mínimo de R\$/MWh 207,33 registrado às 5h da manhã, máximo igual a R\$/MWh 236,71 às 21h, com um valor médio igual à R\$/MWh 224,62. A Figura 21 demonstra a cotação horária deste dia registrado pela CCEE para as regiões brasileiras.



Fonte: adaptado de CCEE (2021).

No cálculo do preço são consideradas apenas as restrições de transmissão de energia entre os submercados (limites de intercâmbios). O cálculo do preço baseia-se no despacho "*ex-ante*", ou seja, é apurado com base em informações previstas, anteriores à operação real do sistema, considerando-se os valores de disponibilidades declaradas de geração e o consumo previsto de cada submercado. O processo de cálculo do PLD consiste na utilização dos modelos computacionais NEWAVE, DECOMP e DESSEM, os quais produzem como resultado o custo marginal de operação de cada submercado, respectivamente em base mensal, semanal e diária. Anteriormente a entrada do cálculo do PLD com granularidade horário, até dezembro de 2020, o PLD era calculado pela CCEE semanalmente para cada patamar de carga com base no custo marginal de operação, limitado por um preço máximo e mínimo vigentes para cada período de apuração e para cada submercado.

Portanto, diante do modelo estratégico adotado no Brasil para comercialização de energia, fazse importante a desenvoltura de estudos científicos sobre previsão de energia a curto e médio prazo com baixo custo computacional e alta performance, incluindo as previsões das energias renováveis as quais já demostram efetiva participação na matriz energética e na matriz de energia elétrica brasileira e uruguaia, tal como a energia eólica. Uma revisão da bibliografia com trabalhos relevantes desta pesquisa é apresentada no próximo capítulo.

CAPÍTULO 4

4 TRABALHOS RELEVANTES AO ESTUDO

Os resultados desta tese contribuem diretamente para analisar e tornar-se mais eficiente a previsibilidade da geração de vento, potência de saída ou energia eólica e rampa de energia eólica a curto e médio prazo, na Bahia, região tropical representado pelos sítios brasileiros definidos em Mucuri, Mucugê e Esplanada, e em Colônia Eulacio, região subtropical representado pelo sítio uruguaio, por intermédio das técnicas de inteligência computacional correlacionadas à decomposição Wavelet e à convolução. Salienta-se que o desenvolvimento desta metodologia contribui com as perspectivas de se atingir futuras metas do desenvolvimento de novos parques eólicos nestes sítios e, por consequência, em todas as regiões do Brasil e do Uruguai propícias para estes investimentos de energia sustentável. Pesquisas científicas desenvolvidas no último quadriênio (2017 a 2020) abordaram a relevância da tecnologia e dos frameworks de inteligência computacional destacando a aplicação de RNA para previsão da velocidade do vento em curto e médio prazo, o que é base importante para previsão da potência de saída e fenômenos de rampa de energia eólica. Pesquisadores como Cao, Farnham e Lall (2017), Chen et al. (2018), Liu et al. (2018), Qin et al. (2019), Yu et al. (2019) e Zucatelli et al. (2019a, 2019b, 2019c, 2019d), Zucatelli et al. (2020) e Zucatelli et al. (2021) desenvolveram estudos a respeito do assunto supracitado, discutiram e publicaram os resultados das simulações computacionais por meio de artigos científicos. Teses e dissertações que correlacionam esta temática também já foram elaboradas por pesquisadores em importantes institutos de pesquisas e universidades brasileiras, tais como SENAI Cimatec - Bahia, UFES, MCT/INPE, UFSC, UFRN, UFPE, UFPB, PUC-Rio, dentre outras. No texto que segue, é apresentado uma síntese destes recentes trabalhos científicos que enriquecem a bibliografia sobre esta tecnologia e assunto.

Cao, Farnham e Lall (2017) propõem um modelo composto de RNA para prever a velocidade média do vento em 6 h e 24 h à frente em uma área de aproximadamente 3,15.10⁶ km² nos EUA. Os dados utilizados neste estudo foram coletados da NASA GSFC MERRA. O modelo de RNA sugerido pelos autores consiste em uma camada de entrada convolucional, uma camada oculta com a técnica de LSTM e uma camada convolucional transposta como camada de saída.

Eles comparam o modelo de RNA com dois modelos não paramétricos, um modelo de persistência nulo e um modelo de valor médio, e descobriram que o modelo de RNA possui erros substancialmente menores do que cada um desses modelos de referência. Além disso, o modelo de RNA também, geralmente, apresenta um desempenho melhor do que os modelos ARIMA, que são treinados para desempenho ideal em locais específicos.

Chen et al. (2018) explicam que como uma questão essencial na indústria de energia eólica, a previsão da velocidade do vento desempenha um papel vital na melhoria do gerenciamento e do controle da geração e da conversão da energia eólica. Neste artigo, um novo método chamado EnsemLSTM é proposto pelos autores, isto usando um conjunto de técnicas de deep learning não linear para a previsão de séries temporais baseado em LSTM, SVRM (support vector regression machine) e EO (extremal optimization algorithm). Em primeiro lugar, a fim de evitar a desvantagem da fraca capacidade de generalização de uma única abordagem de aprendizagem profunda quando se deparam com dados diversiformes, um conjunto de LSTM com diversas camadas ocultas e neurônios são empregados para explorar e explotar as informações implícitas das séries temporais da velocidade do vento. Em seguida, as previsões advindas das LSTM são agregadas em uma camada superior de regressão de aprendizado não linear composta por SVRM e o EO é introduzido para otimizar os parâmetros da camada superior. Por último, a previsão final do conjunto para a velocidade do vento é dada pela camada superior de giro fino. O EnsemLSTM proposto é aplicado a dois estudos de caso coletados em um parque eólico na Mongólia Interior, na China, para realizar a previsão da velocidade de vento a curto prazo em 1 h à frente. Testes estatísticos de resultados experimentais comparados com outros modelos populares de previsão (ARIMA, SVR, KNN, ANN e GBRT - gradient boosting regression tree) demonstraram que o EnsemLSTM proposto pôde alcançar um melhor desempenho de previsão.

Liu *et al.* (2018) escrevem sobre um novo modelo híbrido de previsão da velocidade do vento baseado na transformada Wavelet empírica (EWT), LSTM e a rede neural recorrente de Elman (ENN). Os dados de vento foram coletados em uma fazenda eólica na China. No modelo EWTLSTM – Elman híbrido proposto neste trabalho, o EWT é adotado para decompor os dados brutos de velocidade do vento em várias subcamadas, a rede LSTM e a ENN são empregadas para prever a subcamada de baixa frequência e as subcamadas de alta frequência, respectivamente. Para validar o desempenho de previsão do modelo *Backpropagation (BP)*, o modelo

General regression neural network (GRNN), o modelo LSTM, o modelo Elman, o modelo EWT-BP, a rede RNN. Os autores destacam que a rede LSTM possui a forte capacidade de processamento não linear e é adequada para a simulação computacional de previsão da velocidade de vento não estacionário. Com base na combinação bem-sucedida desses algoritmos supracitados, o modelo EWT-LSTM-Elman proposto tem resultados satisfatórios de previsão da velocidade do vento até 3 h à frente.

Qin et al. (2019) propuseram um método baseado em treinamento para a previsão de sinais de turbinas eólicas. Este modelo proposto emprega as Redes Convolucionais, as LSTMs (conv-LSTM) e SVM (support vector machine) como ideia de aprendizagem com múltiplas tarefas dentro de um quadro de sinal. Este método utilizou a rede convolucional para exploração de propriedades espaciais do campo de vento. Além disso, a LSTM mencionada é usada para treinar recursos dinâmicos do campo de vento. Já o SVM é utilizado para classificação. As ideias declaradas em conjunto têm sido utilizadas para modelar os impactos da construção espaço-dinâmica do campo de vento nas respostas das turbinas eólicas de interesse. Assim, foi implementado este método de treinamento multitarefas para prever a energia e a demanda da turbina eólica ao mesmo tempo através de um único método de previsão em até 1 min, que é caracterizada pela rede neural profunda. O desempenho deste modelo sugerido é confirmado por uma informação real do campo de vento que é produzida pela aplicação do LES (large eddy simulation). O LES é utilizado para simulação de áreas de vento turbulento (correlação espacial / temporal de áreas de vento) com a implementação de um filtro passa-baixa para modelar as menores escalas de turbulência da área de vento no caso de dados de entrada. Esses dados também incluem informações de reação de turbinas eólicas que são simuladas usando software de análise de construção de aerogeradores aeroelásticos. Os resultados comparados com a multilayer perceptron (MLP) e as redes neurais com função de base radial, mostram que o método sugerido pode prever duas saídas com um erro de 5% para uma previsão de curto prazo.

Yu *et al.* (2019) descrevem que em meio ao aumento da geração de energia eólica, como aliviar a pressão de carga de pico e regulação de frequência para o sistema de energia por previsão de energia eólica para fazê-lo funcionar de forma constante torna-se uma questão fundamental a ser respondida. Conforme os autores, devido ao desenvolvimento contínuo do campo da inteligência artificial, a rede neural artificial, como uma tecnologia de aprendizado de máquina, mostrou um bom efeito preditivo na previsão de dados de séries temporais, e destacam que a LSTM é um tipo de rede neural recorrente que é adequada para processar e prever eventos com

intervalos relativamente longos em séries temporais. Este artigo propôs um modelo melhorado da LSTM, abreviado como LSTM-EFG (*long short-term memory-enhanced forget-gate*), usado para prever energia eólica até 2 h a frente. Os dados utilizados são do *national renewable energy laboratory* (NREL), nos EUA. Com base na correlação, os dados de características dos grupos de turbinas em determinada distância são filtrados para otimizar ainda mais o efeito de previsão na energia eólica por agrupamento. Os resultados mostram que o método com clusterização espectral tem uma precisão maior com um aumento de 18,3% do que os dos outros modelos de previsão (LSTM, SVR e algoritmo *K-nearest neighbor*), e ao mesmo tempo o processo de convergência foi acelerado.

Zucatelli *et al.* (2019a) abordaram uma pesquisa pioneira sobre a utilização de inteligência computacional para prever a velocidade do vento em regiões de clima subtropical. O sítio estudado pelos autores foi Colônia Eulacio, localizado no departamento de Soriano, no Uruguai. Os dados anemométricos, coletados a 10.0 m, 25.7 m, 81.8 m e 101.8 m de altura, foram velocidade e direção do vento, e temperatura do ar. Estes dados foram utilizados para treinar, validar e testar as redes neurais tipo MLP utilizada no estudo. Diferentes topologias foram treinadas com a finalidade de encontrar a mais eficiente na previsão da velocidade do vento 1 h a frente. Posteriormente, a melhor rede treinada foi aplicada para previsão de 1 h a 12 h à frente utilizando inferência estatística. O estudo destacou que o modelo de inteligência computacional por intermédio do aprendizado de máquina supervisionado via RNA tipo MLP é mais eficiente do que o modelo estatístico de persistência.

Zucatelli *et al.* (2019b) propuseram amplificar as análises dos estudos de previsão da velocidade do vento no Uruguai utilizando IA com inferência estatística. Os autores compararam os resultados previamente publicados usando MLP com os novos resultados de velocidade do vento predito por RNN, LSTM e GRU. As alturas anemométricas e os dados climáticos utilizados foram os mesmos do trabalho apresentado por Zucatelli *et al.* (2019a). Por meio da estatística descritiva, os autores mostraram que as previsões da velocidade do vento a curto prazo foram mais eficientes ao se aplicar a MLP, seguido da LSTM.

Zucatelli *et al.* (2019c) discutem uma análise hibrida aplicando inteligência computacional junto a decomposição Wavelets para previsão da velocidade do vento em regiões tropicais. Os autores apresentaram a previsão da velocidade do vento a curto prazo na região tropical de Mucuri, Bahia, Brasil, aplicando algoritmo de aprendizado de máquina supervisionado por

meio da MLP, RNN e decomposição Wavelet, isto para a série temporal horária representativa deste local. Para treinar a RNA e validar a técnica, dados anemométricos de um mês foram coletados por uma torre anemométrica com altura de 100 m. Diferentes famílias de Wavelets e diferentes topologias de RNA foram aplicadas para este local e altura. Com base nos resultados alcançados, pode-se concluir que o método proposto caracterizado por RNN + Wavelet de Meyer discreta apresentou os melhores resultados no horizonte de previsão de curto prazo, isto é, 1 h a 12 h à frente. Isto sinalizou a importância da utilização da decomposição Wavelets em sinais detalhados e aproximados da velocidade do vento com a finalidade de aumentar a eficiência da rede em realizar previsões.

Liu, Wu e Li (2020) mostram um modelo de predição de velocidade do vento a curto prazo (1 h a 7 h) com base na análise de Wavelet e estrutura híbrida. As séries temporais da velocidade do vento de quatro locais de observação na província de Xinjiang (China) são utilizadas como dados experimentais. Os resultados experimentais indicaram que a Wavelet de Meyer discreta fornece os melhores resultados entre todas as funções de Wavelet mãe incluídas no estudo. Este trabalho vai ao encontro do trabalho executado por Zucatelli *et al.* (2019c) discutido anteriormente.

Zucatelli et al. (2019d) estudaram um comparativo da previsão da velocidade do vento em região tropical (Bahia, Brasil) e subtropical (Colônia Eulacio, Uruguai). Os autores definiram a topologia da RNA mais eficiente para predizer a velocidade do vento por 1 h e, a partir daí, aplicá-la por 6 h à frente, usando como referência dados observacionais coletados de duas torres anemométricas, com anemômetros instalados a 100,0 e 101,8 m de altura, localizados, respectivamente, em uma região tropical (Mucuri, Bahia, Nordeste do Brasil) e em uma região subtropical (Colonia Eulacio, Departamento de Soriano, Uruguai). Foi mostrado graficamente e verificado através de simulações numéricas que a RNN foi melhor que a MLP em Mucuri e pior em Colônia Eulacio. Diante dos resultados estatísticos registrados neste trabalho, a aplicação de inteligência computacional é destacada pelos autores como uma alternativa viável para a previsibilidade da velocidade do vento e, dessa forma, da geração eólica, principalmente devido ao baixo custo computacional; entretanto, deve-se escolher a arquitetura de RNA que melhor se adapte ao projeto, bem como analisar quantitativa e qualitativamente os dados disponíveis que irão alimentar a rede, uma vez que essas variáveis impactam diretamente nos resultados da previsão. Os resultados da previsão de velocidade do vento a curto prazo mostraram boa precisão em todas as alturas anemométricas testadas. Portanto, o método proposto de previsão da velocidade do vento a curto prazo é uma importante contribuição científica para a previsão confiável de energia eólica em grande escala e integração em regiões tropicais e subtropicais, como no Brasil e no Uruguai.

Zucatelli *et al.* (2020) desenvolveram e publicaram uma metodologia para análise da acurácia da filtragem de séries temporais anemométricas de velocidade do vento registradas a 100 m, 120 m e 150 m, em região tropical no Brasil, sítios de Esplanada, Mucugê e Mucuri (região Nordeste, estado da Bahia). O trabalho teve a finalidade de verificar a melhor função Wavelet (ou seja, com menor erro associado) na decomposição dos sinais temporais da velocidade do vento, com o objetivo de aplicar os sinais decompostos pelos filtros passa alta (sinais detalhados) e passa baixa (sinais aproximados) como *input* das redes neurais artificiais e, assim, prever a velocidade do vento em 6 h a frente (ação chamada de *nowcasting*). Os autores destacaram que a metodologia científica utilizada para previsão da velocidade do vento aplicando inteligência computacional e decomposição Wavelet vai ao encontro dos resultados empíricos registrados por Zucatelli *et al.* (2019c) e por Liu, Wu e Li (2020), em que ambos encontraram que a família Wavelet dmey (ou Wavelet de Meyer discreta) é a mais eficiente para filtragem dos sinais de velocidade do vento.

Aly (2020) propõe modelos híbridos para a previsão (1 h a frente) da velocidade do vento para melhorar a precisão geral do sistema. Os modelos híbridos do trabalho envolveram várias combinações de Wavelet e rede neural artificial (WNN e ANN), séries temporais (TS) e filtro de kalman recorrente (RKF). Os dados de velocidade do vento são de Halifax, oficialmente conhecida como Município Regional de Halifax, que é a capital da província canadense da Nova Escócia. Três modelos híbridos principais foram propostos e testados. Destes três modelos, o melhor modelo com o melhor desempenho é o híbrido de WNN, RKF, TS. O autor salienta que a ordem das técnicas utilizadas nos modelos híbridos foi muito importante. Diferentes combinações com diferentes ordens foram testadas no trabalho. O trabalho proposto foi validado usando diferentes conjuntos de dados não vistos com os modelos propostos e comprova sua eficácia. Todos os modelos propostos são precisos, mas o melhor modelo é o modelo híbrido de WNN, TS e RKF em sequência. A nova contribuição em Aly (2020) são os modelos híbridos de diferentes técnicas baseadas em inteligência artificial, bem como os sinais de feedback dos resíduos para melhorar a precisão geral do sistema para dados pré-processados. Este estudo é muito importante porque a energia eólica gerada é altamente dependente da velocidade do vento, que é intermitente e de natureza variável, o que levaria a problemas como flutuações de tensão, qualidade de energia e problemas de estabilidade. A previsão precisa e acurada, logicamente, permite uma melhor preparação da operação do sistema de energia para gerenciar esses problemas na produção eólica. As informações imprecisas podem levar à instabilidade na rede elétrica e isso causa flutuações de tensão e mau funcionamento dos transformadores e queda de energia, o que gera uma enorme perda financeira. Assim, um modelo de previsão mais preciso da velocidade do vento é parte essencial na rede do sistema de energia de um país.

Alipour et al. (2020) estudaram um modelo de rede neural profunda para prever a carga de energia da rede elétrica. A estrutura da rede neural profunda usada no modelo de previsão proposto foi constituída por vários autoencoders e uma rede neural em cascata. A previsão de carga líquida 48 h a frente foi feita na presença de incertezas decorrentes da geração eólica e fotovoltaica e do consumo de carga elétrica. Para melhorar a precisão da previsão a curto e médio prazo da carga líquida, a transformada Wavelet foi aplicada às entradas do modelo proposto. A previsão da carga líquida em diferentes cenários é realizada em um conjunto de dados aberto de 37 países da Europa Central, a partir da perspectiva de diferentes tipos de estratégias de previsão e mudanças na arquitetura da rede neural. A altura da medição dos dados anemométricos foi de 10 m. No modelo proposto, o treinamento dos autoencoders é supervisionado ao contrário da rede neural em cascata, de forma que o modelo possui aprendizagem supervisionada e não supervisionada em seu treinamento. A adição de recursos históricos por meio da transformação Wavelet aos recursos de entrada do modelo, melhorou a precisão do modelo. Os autores destacam que determinar o número apropriado de autoencoders e neurônios da camada oculta aumenta à precisão do modelo em comparação com outros modelos de previsão.

Um sistema de previsão híbrido para velocidade do vento a curto prazo é proposto em Duan *et al.* (2021) que inclui técnicas de decomposição efetiva de dados, algoritmos de previsão usando rede neural recorrente (BPNN, LSTM e GRU) e métodos de correção do erro associado a decomposição dos sinais (decomposição de sinais e ARIMA). Neste estudo, uma nova abordagem de decomposição é usada para primeiro decompor a série de velocidade do vento original em um conjunto de subséries, em seguida, prevê a velocidade do vento por rede neural recorrente e, finalmente, decompor o erro para corrigir a velocidade do vento prevista anteriormente. A eficácia do modelo proposto é verificada usando dados de quatro diferentes parques eólicos na Região Autônoma de Ningxia Hui, China. A altura de medição da velocidade

do vento foi de 70 m, a série contemplou 1000 amostras, e o intervalo de amostragem foi de 15 minutos. Os resultados mostram que o sistema híbrido proposto baseado na rede GRU é superior a outros modelos individuais e modelos tradicionais, realizando previsões precisas da velocidade do vento. O sistema proposto pode ser uma ferramenta útil para a operação e gestão de redes inteligentes de energia elétrica, visto que a previsão da velocidade do vento é a base fundamental para previsão de energia eólica.

Com relação aos modelos aplicados para previsão de rampa de energia eólica, algoritmos de previsão publicados na literatura foram propostos usando, por exemplo, o modelo ARIMA, método de análise de regressão, método de média móvel, método de suavização exponencial e método de decomposição, entre outros, como os trabalhos de Hwang et al. (2011), Raffi e Rajagopal (2012), e Taylor (2017). Na faixa temporal de segundos a minutos, as técnicas autorregressivas ou de persistência podem lidar bem com flutuações dos sinais de energia a curto prazo, mas péssimas com tendências de médio a longo prazo. O modelo ARIMA, por exemplo, pode processar uma etapa integral, mas não captura mudanças abruptas relacionadas aos eventos de rampa de energia eólica. Sabe-se que o evento de rampa representa uma cena, e não um ponto. Portanto, alguns pesquisadores categorizam os eventos de rampa em classes e apresentam o método SVM como classificadores e um modelo elaborado que pode usar os dados disponíveis para prever as classes de rampas futuras, como em Zareipour, Dongliang e Rosehart (2011), e Dhiman, Deb e Balas (2020). Por conseguir capturar a influência de algumas características meteorológicas complexas, a cadeia de Markov é considerada adequada para modelagem de variáveis meteorológicas, como as ocorrências diárias de chuva citadas em Robertson, Kirshner e Smyth (2003) ou campos de vento citados em Ailliot e Monbet (2012). Assim, para o caso específico das flutuações da geração eólica, alguns autores usam esses modelos de Markov para descrever características meteorológicas e prever a cena de rampa de vento que não pode ser determinada apenas a partir de valores anteriores da produção de energia medida, como em Ouyang et al. (2019). Trabalhos recentes aplicaram modelos com inteligência computacional via redes neurais profundas para previsão de rampa de energia eólica, como descrito por Dorado-Moreno et al. (2020) que aplicaram redes neurais profundas com aprendizado multitarefa e por Zhou et al. (2021) que usaram redes neurais adversárias generativas profundas com aprendizado semisupervisionado.

Ahmadi e Khashei (2021) realizaram uma revisão da literatura sobre este assunto e dissertou que a energia eólica é uma das mais importantes energias sustentáveis e alternativas aos

combustíveis fósseis. Tais autores citaram Zucatelli *et al.* (2019a) e declararam que, atualmente, mais atenção tem sido dada a este recurso renovável devido à evolução da consciência pública, preocupações com as emissões de gases de efeito estufa para atmosfera, dentre outras questões ambientais. Previsões precisas da velocidade do vento e da energia eólica são os fatores mais críticos e influentes na tomada de decisões gerenciais e operacionais desejadas e eficientes na área de energia eólica. A energia eólica e a previsão de velocidade desempenham um papel essencial no planejamento, controle e monitoramento de sistemas inteligentes de energia eólica em uma nação. Portanto, vários modelos diferentes foram desenvolvidos na literatura do assunto com a finalidade de prever essa fonte de energia com mais precisão. No entanto, não há um consenso geral sobre o modelo que deve ser selecionado e usado em uma situação específica de horizonte de tempo, tamanho da amostra, complexidade, incertezas, etc. Os autores deste trabalho destacam que os modelos híbridos são os mais aplicados e os modelos de previsão mais assertivos na literatura energética.

Zucatelli et al. (2021) simularam a previsão de energia eólica e rampas de energia eólica utilizando dados anemométricos de sítios com clima tropical e subtropical, junto às informações de turbinas eólicas comerciais. Para isto, foi aplicado a metodologia híbrida via inteligência computacional por meio do aprendizado de máquina supervisionado agregado à transformada Wavelet. Os autores destacam que grandes variações na produção de energia eólica em um período de minutos até horas é um desafio para os gestores do sistema elétrico nacional. O uso de ferramentas confiáveis para a previsão de eventos de energia eólica e rampa de energia eólica é essencial para os operadores do sistema elétrico e para os empreendedores das fazendas eólicas. Destaca-se que o objetivo principal deste trabalho foi analisar a previsão da energia eólica e da rampa de energia eólica nos sítios do Brasil e do Uruguai. Para atingir este objetivo, a decomposição Wavelet (filtragem passa baixa e passa alta) aplicando 48 diferentes funções Wavelet mãe e técnicas de aprendizado profundo foram usadas. A rede neural recorrente foi treinada para realizar a previsão 1 h à frente e, em seguida, a partir dela, a rede treinada foi aplicada para inferir recursivamente a previsão para as próximas horas da velocidade do vento. Após este procedimento computacional, a energia eólica e a rampa de energia eólica foram previstas. Os resultados mostraram boa precisão e podem ser usados como uma ferramenta para auxiliar os operadores da rede nacional no fornecimento de energia elétrica advinda da fonte eólica. A família Wavelet discreta de Meyer (dmey) demonstrou maior precisão na decomposição dos sinais de velocidade do vento, mantendo a energia do sinal. Portanto, os autores comprovaram que a função Wavelet *dmey* é a mais precisa na decomposição de sinais temporais de vento, seja utilizando dados de regiões tropicais ou subtropicais.

Sabe-se que a energia eólica é uma das mais importantes energias sustentáveis e alternativas aos combustíveis fósseis. Mais atenção tem sido dada a este recurso renovável devido ao aumento da consciência pública, preocupações com as emissões dos gases de efeito estufa para atmosfera e seus impactos ambientais na fauna e flora, além da real necessidade de se utilizar o petróleo e o gás natural de maneira mais nobre, do que simplesmente para a combustão. Previsões precisas e acuradas da velocidade do vento, da energia eólica e do fenômeno de rampa de vento são os fatores mais críticos e influentes, desejados e eficientes, na tomada de decisões gerenciais e operacionais na indústria de energia eólica. A previsão da velocidade já desempenha um papel essencial no planejamento, controle e monitoramento de sistemas inteligentes de energia eólica. Assim, vários modelos diferentes foram desenvolvidos na literatura do assunto a fim de prever essa fonte de energia com mais precisão. No entanto, não há um consenso sobre o modelo que deve ser selecionado e usado em uma situação específica de horizonte de tempo, tamanho da amostra, complexidades, incertezas etc., o que existe são estudo que publicam seus resultados para casos específicos. Os modelos híbridos são frequentemente os mais usados e os modelos de previsão mais populares na literatura energética, porém na maioria das vezes o processamento de sinais de vento é aplicado de maneira empírica, o que difere desta tese.

Diante do exposto na literatura, teve-se a elaboração desta tese com propósito de aplicar uma metodologia eficiente e de baixo custo computacional, quando comparado com os métodos numéricos, para prever a velocidade do vento em até 168 h a frente (ou 1 semana) utilizando dados anemométricos registrados em alturas iguais a 80 m, 100 m, 120 m e 150 m, o que não é visto na literatura para regiões tropicais e subtropicais na América Latina. Estas alturas anemométricas são importantes pois estão de acordo com as alturas do rotor das turbinas eólicas comerciais empregados em fazendas eólicas. Por conseguinte, é predito a energia eólica e rampa de energia eólica. Os detalhes dos *frameworks* já utilizados pelos autores supracitados, formulações matemáticas, resultados alcançados, as discussões e as literaturas citadas anteriormente agregaram valores positivos para este projeto. O ferramental híbrido de previsão marcado por inteligência computacional e decomposição de sinais via Wavelets de forma não empírica, a curto e médio prazo, é uma contribuição importante para a integração confiável da energia eólica em grande escala em diversos sítios operantes, em especial, nas áreas potenciais

localizadas no Brasil e no Uruguai. A metodologia científica aplicada neste estudo é descrita a seguir.

CAPÍTULO 5

5 METODOLOGIA CIENTÍFICA

5.1 Tipo de pesquisa

Para o desenvolvimento desta tese, quanto a abordagem, foi empregado uma abordagem quanti e qualitativa (pois é aplicada a interpretação do pesquisador junto aos artifícios estatísticos e simulação computacional), com um método científico indutivo (no qual, pela indução experimental o pesquisador pode chegar a uma lei geral por meio da observação de certos casos particulares sobre o objeto – fenômeno/fato – observado) e um objeto de estudo exploratório. Tal método se constitui no caminho de construção do discurso científico. Ele é a trajetória que o pesquisador percorre para conhecer o objeto (fenômeno/fato investigado) em busca de construir um conhecimento racional e sistemático. O exercício do método indutivo requer alguns procedimentos por parte do pesquisador, os quais podem ser citados (DINIZ e SILVA, 2008):

- i. Observação sistemática dos fenômenos;
- Elaboração de classificações a partir da descoberta de relação entre os fenômenos observados;
- iii. Construção de hipóteses (verdades provisórias) a partir das relações observadas;
- iv. Verificação das hipóteses por meios de experimentações e testes;
- v. Construção de generalizações, a partir dos resultados experimentados e testados, servindo como explicação para outros estudos que apresentem casos similares;
- vi. Confirmação das hipóteses para se estabelecer as leis gerais sobre os fenômenos investigados.

Quanto aos objetivos, conforme Gil (2002, p.41), esta tese se classifica como pesquisa exploratória. Este tipo de pesquisa tem como objetivo proporcionar maior familiaridade com o problema, com vistas a torná-lo mais explícito ou a construir hipóteses. Pesquisas desta natureza podem envolver: (a) levantamento bibliográfico; (b) entrevistas com pessoas que tiveram experiências práticas com o problema pesquisado; e/ou (c) análise de exemplos que estimulem

a compreensão. Essa pesquisa pode ser classificada como pesquisa bibliográfica e estudo de caso. Isto é devido à insipiência do processo de previsibilidade do vento, da geração de energia eólica, e do fenômeno de rampa de energia eólica no estado da Bahia e no Uruguai.

Portanto, embasou-se esta pesquisa na revisão bibliográfica o que permitiu sustentar com clareza e precisão o problema proposto. Foram utilizados artigos, teses e livros para compor o cenário necessário ao estudo. A pesquisa documental e a definição da delimitação do local de estudo, ou seja, estudo de caso, foram os procedimentos técnicos adotados. A pesquisa documental, por sua própria definição, é composta por material oriundo de arquivos de órgãos públicos, instituições privadas, associações, leis, regulamento, relatórios de instituições dentre outros, sendo, portanto, diversificada e dispersa, como explica Gil (2002, p.45). O método de estudo é uma forma de pesquisa empírica, normalmente aplicada para estabelecer critério de qualidade em pesquisas de caráter científico-social, dando maior credibilidade, conformidade e confiança à pesquisa. Os resultados empíricos alcançados são complementados pelo método indutivo aplicado nesta tese, em que para chegar a uma conclusão, esse tipo de raciocínio parte do específico para o geral. Assim, de uma premissa particular há uma generalização até chegar no universal.

Nesta tese, através da seleção de um caso de estudo, buscou-se, por meio de toda metodologia computacional, avaliar e implementar melhorias na previsão da geração de energia eólica a curto e médio prazo, 1 h a 168 h à frente, em resolução espacial de microescala (ou escala local, a qual apresenta processos atmosféricos da ordem de 1 m a 1 km) usando modelos de previsão baseados em inteligência computacional por intermédio do aprendizado de máquina supervisionado, decomposição Wavelet e a convolução, contribuindo, assim, com os órgãos gerenciadores do sistema nacional de energia elétrica.

5.2 Delimitação do local de estudo: sítios e dados meteorológicos

Paixão *et al.* (2017) afirmam que a energia eólica se tornou uma boa alternativa à diversificação e expansão da matriz elétrica brasileira. Deve-se notar que o avanço da tecnologia em energia eólica permitiu a instalação de turbinas em altos níveis, exigindo conhecimento do potencial eólico em alturas cada vez maiores (120 e 150 m por exemplo). Para validar as estimativas e divulgar a instalação de parques eólicos no estado da Bahia, foram instaladas quatro torres

anemométricas de 150 m de altura em locais com ventos promissores, nas cidades de Esplanada, Mucugê, Mucuri e Casa Nova pelo Sistema da Federação das Indústrias do Estado da Bahia (FIEB). As torres anemométricas instaladas em Esplanada, Mucugê e Mucuri são as mais importantes, seus dados anemométricos registrados (anemômetros a 80 m, 100 m, 120 m e 150 m) representam bem a diversidade climática do estado da Bahia e, portanto, contemplam este estudo de caso (Figura 22). A base de dados de vento que será utilizada neste estudo é caracterizada pelos dados de velocidade [m/s], direção [°], temperatura [°C], umidade relativa [%] e pressão barométrica [mBar].



Figura 22: Localização das torres anemométricas na Bahia, Nordeste brasileiro. Fonte: Google Earth 2020.

A cidade de Esplanada está localizada na microrregião do litoral norte da Bahia com altitude de 140 m em relação ao nível do mar e possui uma área territorial de 1.299,35 km² (IBGE, 2019) com clima zonal caracterizado pelo Clima Tropical Nordeste Oriental e compartimento de relevo marcado por planícies. Seu bioma característico é a mata atlântica. A torre anemométrica de Esplanada fica a 40 km do mar, com latitude 11°47'45" S e longitude 37°56'42" O. O município fica a cerca de 170 km da capital Salvador.

O município de Mucugê está a uma altitude de 984 m em relação ao nível do mar e é um dos municípios pertencentes à Chapada Diamantina, região central do estado da Bahia, caracterizada por ser uma região montanhosa com compartimento de relevo marcado por serras e chapadas. Seu bioma característico é a caatinga. Possui uma área territorial de 2.462,15 km² (IBGE, 2019) com clima zonal caracterizado pelo Clima Tropical Brasil Central. A torre anemométrica de Mucugê está localizada, aproximadamente, a 280 km da costa da Bahia, com uma latitude de 13°00'18" S e longitude de 41°22'15" O. O município fica a cerca de 450 km da capital Salvador.

Já a cidade de Mucuri está localizada a uma altura de 7 m em relação ao nível do mar e tem uma área territorial de 1.787,62 km² (IBGE, 2019) com clima zonal caracterizado pelo Clima Tropical Brasil Central e compartimento de relevo marcado por planícies. Seu bioma característico é a mata atlântica. A torre anemométrica de Mucuri está localizada em uma planície costeira, a uma distância de 340 m do mar, com latitude 18°05'09" S e longitude 39°33'03" O. O município fica a cerca de 900 km da capital Salvador. A torre anemométrica da cidade de Casa Nova (também do sistema FIEB), município brasileiro no semiárido nordestino, estado da Bahia, não dispôs de dados anemométricos para este estudo.

A estação de medição uruguaia utilizada nesta tese é composta por uma torre de seção triangular, com 100,8 metros de altura, 0,45 metros de largura e está localizada conforme coordenadas UTM em 451405 E e 631752 S conforme sistema de coordenadas WGS-84 (ou latitude 33°16' S e longitude 57°31' W). A elevação do terreno onde a mesma se encontra instalada é de aproximadamente 100 m, conforme o que apresentam Lucas *et al.* (2016). A localidade onde se encontra a torre é denominada de Colônia Eulacio e está localizada no departamento de Soriano, na região sudoeste do Uruguai. Soriano possui área total de 9.008,00 km², correspondente a 5,11% do território do país, e sua capital Mercedes fica cerca de 285 km de Montevidéu, capital do Uruguai. É um departamento de planícies com poucas elevações, banhado pelos rios San Salvador, Negro, rio Grande e Uruguai. O clima é subtropical, quente e úmido, caracterizado pela zona temperada. A referida estação é de propriedade da UTE, à qual é uma empresa pública do Uruguai que se dedica as atividades de geração, distribuição e comercialização de energia elétrica, assim como prestação de serviços. Os dados observacionais anemométricos deste sítio foram coletados nas alturas de 81,8 e 101,8 metros. Por meio da Figura 23 pode-se observar a localização do sítio uruguaio, representado por Colônia Eulacio.



Figura 23: Localização da torre anemométrica de Colônia Eulacio, em Soriano, no Uruguai. Fonte: Google Earth 2020.

Os dados anemométricos brutos da Bahia foram registrados em um intervalo de tempo de 20 em 20 segundos e os dados de Colônia Eulacio de 10 em 10 minutos. O tratamento destes dados obedeceu às seguintes tratativas:

- i. Se faltavam dados, foi adicionado *NaN* (acrônimo em inglês para *Not a Number*) que é um valor ou símbolo usado para representar um valor numérico indefinido.
- ii. Se houvesse mais de 20 dados consecutivos iguais, foi adicionado NaN em todos eles.
- iii. Feito esse processamento, foram calculadas médias horárias.
- iv. No caso em que a hora continha mais de 60% dos valores de NaN, assim, NaN era atribuído ao valor da hora.
- v. Nos demais casos, a média foi atribuída.

A seguir, tem-se que no Quadro 2 são apresentadas as informações das estações meteorológicas; no Quadro 3 é exposto as informações das alturas de medições das variáveis meteorológicas/climáticas registradas; no Quadro 4, as informações cronológicas das variáveis meteorológicas/climáticas medidas podem ser lidas. Já no Quadro 5, as informações estatísticas das variáveis meteorológicas/climáticas medidas são descritas. Apesar de conter medição a 80 m no Brasil, neste estudo foram aplicados os dados medidos acima de 100 m.

Região	Sítio	Latitude	Longitude	Elevação do terreno [m]	Altura dos anemômetros [m]			Variáveis meteorológicas/climáticas medidas	
					Ι	II	III	IV	
Região tropical (Bahia – Brasil)	Esplanada	11°47'45" S	37°56'42'' W	140,0	80,0	100,0	120,0	150,0	velocidade [m/s], direção [º] temperatura [ºC], umidade relativa [%] e pressão barométrica [mBar]
	Mucugê	13°00'18" S	41°22'15" W	984,0	80,0	100,0	120,0	150,0	
	Mucuri	18°05'09" S	39°33'03" W	7,0	80,0	100,0	120,0	150,0	
Região subtropical (Departamento de Soriano – Uruguai)	Colônia Eulacio	33°16' S	57°31' W	100,0	81,80	101,80	-	-	velocidade [m/s], direção [º], temperatura [ºC]

Quadro 2: Informações das estações meteorológicas deste estudo.

Instrumento	Região tropical: Esplanada, Mucugê e Mucuri, Estado da Bahia, Brasil						
instrumento	Variável	Altura de medição [m]					
Anemômetro	Velocidade [m/s]	80,0	100,0	120,0	150,0		
Windvane (sensor de direção)	Direção [°]	98,0	98,0	118,0	148,0		
Termômetro	Temperatura [°C]	140,0	140,0	140,0	140,0		
Higrômetro	Umidade relativa [%]	140,0	140,0	140,0	140,0		
Barômetro	Pressão barométrica [mBar]	140,0	140,0	140,0	140,0		
Instrumento	Região subtropical: Colônia Eulacio, Departamento de Soriano, Uruguai						
	Variável	Variável Altura de medição [m]					
Anemômetro	Velocidade [m/s]	81,80	101,80	-			
Windvane (sensor de direção)	Direção [º]	60,80	60,80	-			
Termômetro	Temperatura [°C]	100,80	100,80	-			

Quadro 3: Informações das alturas de medições das variáveis meteorológicas/climáticas registradas.

Região	Sítio / Altura de medição	Quantidade de horas registradas	Data de início	Horário de início	Data de fim	Horário de fim
Bahia –	Esplanada 100 m, 120 m e 150 m	744	28/04/2016	9:00	29/05/2016	8:00
ropical (l Brasil)	Mucugê 100 m, 120 m e 150 m	744	07/09/2016	0:00	07/10/2016	23:00
Região	Mucuri 100 m, 120 m e 150 m	744	30/11/2015	14:00	31/12/2015	13:00
Região subtropical (Departamento de Soriano – Uruguai)	Colônia Eulacio 81,80 m e 101,80 m	8760	08/08/2014	00:00	07/08/2015	23:00

Quadro 4: Informações cronológicas das variáveis meteorológicas/climáticas medidas e utilizadas neste estudo.

Região	Sítio / Altura de medição	Amplitude da	Média horária da	Variância da	Desvio padrão da
Regiau	Shio / Altura ut înculçao	velocidade [m/s]	velocidade [m/s]	velocidade [(m/s) ²]	velocidade [m/s]
as	Esplanada 100 m	8,159	4,956	2,333	1,527
t hor	Esplanada 120 m	8,408	5,285	2,382	1,543
- 742 Jra	Esplanada 150 m	9,629	5,673	2,518	1,587
asil - ɔ/altı	Mucugê 100 m	13,710	8,159	6,158	2,481
– Bra	Mucugê 120 m	13,735	8,090	6,021	2,453
ical - cada	Mucugê 150 m	14,170	8,192	6,254	2,501
trop. em	Mucuri 100 m	14,194	7,905	8,534	2,921
gião	Mucuri 120 m	14,407	8,127	8,066	2,840
Re	Mucuri 150 m	14,101	8,440	7,586	2,754
Região subtropical – Uruguai – 8760 horas em cada altura	Colônia Eulacio 81,80 m	23,977	6,811	7,521	2,742
	Colônia Eulacio 101,80 m	24,975	7,214	9,017	3,003

Quadro 5: Informações estatísticas da variável meteorológica/climática medida e utilizada neste estudo: velocidade do vento.



As figuras apresentadas abaixo, Figura 24 a Figura 31, demonstram os gráficos das séries temporais da velocidade do vento e sua distribuição normal para os sítios tropicais e subtropical.

Figura 24: Série temporal da velocidade do vento em Espanada, a) 100 m, b) 120 m, c) 150 m. Fonte: Autoria própria.





Figura 25: Distribuição normal da velocidade do vento em Espanada, a) 100 m, b) 120 m, c) 150 m.



Figura 26: Série temporal da velocidade do vento em Mucugê, a) 100 m, b) 120 m, c) 150 m. Fonte: Autoria própria.



c)

m/s

Wind

Figura 27: Distribuição normal da velocidade do vento em Mucugê, a) 100 m, b) 120 m, c)

150 m.







Figura 28: Série temporal da velocidade do vento em Mucuri, a) 100 m, b) 120 m, c) 150 m.



Fonte: Autoria própria.



Figura 29: Distribuição normal da velocidade do vento em Mucuri, a) 100 m, b) 120 m, c) 150

m.



Figura 30: Série temporal da velocidade do vento em Colônia Eulacio, a) 81,8 m, b) 101,8 m. Fonte: Autoria própria.



Figura 31: Distribuição normal da velocidade do vento em Colônia Eulacio, a) 81,8 m, b) 101,8 m.

Fonte: Autoria própria.

Neste contexto, a distribuição Weibull é importante, especialmente, para análises de confiabilidade e capacidade de manutenção. A função de distribuição cumulativa F(v) e a função de densidade de probabilidade f(v) é dada pelas seguintes Equações (39) e (40):

$$F(v) = 1 - e^{\left[-\left(\frac{v}{c}\right)^k\right]}$$
(39)

$$f(v) = \frac{k}{c} \left(\frac{v}{c}\right)^{k-1} \cdot e^{\left[-\left(\frac{v}{c}\right)^k\right]}$$
(40)

Em que: v = é a velocidade do vento [m/s]; k = é o fator de forma Weibull [sem unidade]; c = é o parâmetro escala de Weibull [m/s].

Neste trabalho, para determinar os parâmetros de forma (k) e escala (c) da função de densidade de probabilidade de Weibull, aplicou-se o *Método Empírico Justus* seguindo as *Equações de Lysen*, representadas por (41) e (42):

$$k = (\sigma/\bar{\nu})^{-1.086}$$
(41)

$$c = \bar{\nu}(0.568 + 0.433/k) - 1/k \tag{42}$$

Em que: σ é o desvio padrão da velocidade [m/s] e \overline{v} é a velocidade média [m/s].

O parâmetro de forma determina a forma da curva de distribuição de Weibull. Isso revela a regularidade dos ventos, ou seja, quanto maior o valor de k, maior a regularidade dos ventos em termos de velocidade e mais estreita a curva de distribuição, visto que o parâmetro de escala c é o fator característico da distribuição. A função de densidade acumulada indica a probabilidade de encontrar um valor de velocidade entre zero e v. Multiplicando esse valor pelo número de horas no período em que os dados foram coletados, há uma fração do tempo em que a velocidade permaneceu entre os dois valores. No Quadro 6 observa-se o fator de forma de Weibull e o parâmetro de escala de Weibull. A Figura 32 a) a d) mostra a densidade de distribuição Weibull em relação à velocidade do vento para todos os sítios e todas as alturas anemométricas, onde é apresentado a função densidade de probabilidade. Locais caracterizados por ventos muito constantes (como ambientes de ventos alísios tropicais) podem ter um valor de fator de forma de Weibull tão alto quanto 3,0 ou 4,0.

Continua...

Sítios	Altura anemométrica [m]	k [sem unidade]	<i>c</i> [m/s]
	100,0	3,590	3,134
Esplanada	120,0	3,806	3,340
	150,0	3,988	3,587
Mucugê	100,0	3,642	5,329
muougo	120,0	3,653	5,280

	150,0	3,627	5,355
	100,0	2,947	5,312
Mucuri	120,0	3,132	5,420
	150,0	3,374	5,581
Colônia Eulacio	81,80	2,686	4,594
	101,80	2,591	4,918

Quadro 6: Parâmetros da distribuição Weibull calculados para os locais selecionados neste estudo e alturas anemométricas.

Fonte: Autoria própria.



b)



Figura 32: Função densidade de probabilidade para a) Esplanada, b) Mucugê, c) Mucuri e d) Colônia Eulacio.

Fonte: Autoria própria.

Pode-se observar que os resultados registrados na tabela anterior caracterizam bem uma região tropical e subtropical. O Quadro 7 apresenta as especificações técnicas dos aerogeradores considerados neste estudo. Estas especificações técnicas foram recolhidas pelo portal da energia eólica (*wind-turbine-models.com*).

Características técnicas	Dados das turbinas eólicas comerciais					
Altura anemométrica [m]	81,80	100,0	101,80	120,0	150,0	
Potência nominal [kW]	1.500,0	2.000,0	2.000,0	4.500,0	5.000,0	
Altura do rotor (<i>hub</i>) [m]	80,0	100,0	100,0	120,0	140,0	
Diâmetro rotor [m]	77,0	80,0	80,0	128,0	128,0	
Área varrida [m ²]	3.848,0	5.027,0	5.027,0	12.868,0	12.868,0	
Número de hélices	3	3	3	3	3	
Velocidade do vento de entrada (<i>v_{ci}</i>) [m/s]	3,0	3,5	3,5	1,0	2,0	
Velocidade do vento nominal (<i>v_R</i>) [m/s]	11,8	12,0	12,0	12,0	14,0	
Velocidade do vento de saída (v _{co}) [m/s]	20,0	25,0	25,0	27,0	27,0	

Quadro 7: Especificações técnicas das turbinas eólicas.

Fonte: Autoria própria.

A seguir, apresenta-se o procedimento computacional adotado nesta pesquisa científica.

5.3 Procedimento computacional

Uma vez que o propósito principal do trabalho foi avaliar e implementar melhorias na previsão da geração de energia eólica a curto e médio prazo, 1 h a 168 h à frente, em resolução espacial de microescala, no Brasil e no Uruguai, as etapas desta pesquisa foram divididas em 4 fases, conforme Figura 33: Planejamento, Modelagem, Experimentação e, por fim, Decisão e Conclusão, o que caracteriza uma metodologia adequada para os projetos que envolvam modelagem e simulação computacional.



Figura 33: Metodologia para modelagem e simulação com planejamento e divisão das etapas de trabalho.

Fonte: Autoria própria.

Na fase de planejamento, os passos a) a c) foram executados por intermédio de uma revisão bibliográfica acerca do tema previsão do vento, inteligência computacional, *machine learning, deep learning*, redes neurais artificiais, pré e pós-processamento de sinais meteorológicos, filtragem passa baixa e passa alta dos dados de vento via Wavelets, assim como o entendimento das regiões da Bahia e do Uruguai, no que diz respeito às pesquisas já desenvolvidas sobre previsão de energia eólica. O passo d) se concretizou pelo fornecimento de informações e dos dados anemométricos das torres do sistema de medição da Federação das Indústrias do Estado da Bahia (FIEB) localizadas nos municípios de Mucuri, Mucugê e Esplanada por intermédio da parceria com o centro de pesquisas do SENAI Cimatec de Salvador – BA, além das informações e dados anemométricos da torre de Colônia Eulacio, localizada no Departamento uruguaio de Soriano, por intermédio da parceria com a *Universidad de la República* (Udelar) e a

Administración Nacional de Usinas y Trasmisiones Eléctricas (UTE) no Uruguai. As figuras a seguir, Figura 34, Figura 35, e Figura 36, ilustram as torres de registro dos dados atmosféricos.



Figura 34: Base da torre anemométrica de 150 m localizada em Esplanada, Bahia – Brasil. Fonte: Arquivos online do canal Senai Cimatec.



Figura 35: Vista superior da torre anemométrica de 150 m localizada em Esplanada, Bahia – Brasil.

Fonte: Arquivos online do canal Senai Cimatec.



Figura 36: Imagem da torre anemométrica e seu entorno, localizada em Colônia Eulacio, no Departamento de Soriano, Uruguai. Fonte: Lucas *et al.* (2016).

A fase de modelagem (fase II) foi caracterizada pela tradução do modelo a qual refere-se à codificação do modelo em uma linguagem de simulação apropriada, tal como Python e Matlab usados neste estudo; e pela verificação e validação que foi necessário para a confirmação de que o modelo estava operando de acordo com a intenção inicial do estudo, sem erros de conceito, sintaxe ou lógica de operação. Os dados anemométricos (velocidade e direção do vento, pressão, umidade e temperatura atmosférica) foram projetados como *input* junto com as informações de tempo (dia, mês, ano, hora) para o acionamento do aprendizado de máquina supervisionado utilizando redes neurais artificiais. As redes neurais foram projetadas contendo os nós de entrada, a(s) camada(s) oculta(s), e o nó de saída (target), contendo, portanto, no mínimo 3 camadas variando a quantidade de neurônios de cada camada oculta entre 1 e 9. Os hiperparâmetros das redes neurais foram ajustados objetivando minimizar o erro entre o dado real e o dado predito. A divisão dos dados de entrada entre conjunto de treino, validação e teste seguiu em média 40% para treino, 30% para validação e 30% para teste. Após o treinamento da rede neural para prever o *target* 1 h a frente, a mesma foi aplicada para realizar a previsão das próximas horas por inferência recursiva. Foram implementadas e testadas redes neurais tipo MLP e RNN, utilizando o algoritmo de otimização Levenberg-Marquardt backpropagation, e redes do tipo GRU e LSTM aplicando otimizador Adam com a técnica de gradiente descendente estocástico. As funções de ativação aplicadas foram função tangente hiperbólica e função
softplus nas camadas densas e função linear na camada de saída. A filtragem passa baixa e passa alta dos sinais de velocidade do vento foi aplicada utilizando 48 funções dentre as famílias Wavelets discretas. Após a filtragem, analisou-se a manutenção da energia do sinal decomposto no nível A1 perante o sinal original. Quanto menor o erro, mais eficiente é a função Wavelet com relação a manutenção das características do sinal. O cálculo do *level* máximo da função para ser trabalhado na ação da decomposição do sinal leva em consideração o quantitativo de dados registrados. A decomposição Wavelet foi aplicada na velocidade do vento devido ser a variável de maior impacto no cálculo de previsão da energia eólica e da rampa de energia para todos os sítios.

Na fase III ou de experimentação, teve-se marcado o projeto experimental final que consistiu na elaboração de um conjunto de experimentos com a finalidade de produzir a informação desejada; a experimentação, que se referiu à execução das simulações propriamente ditas, culminando com a geração das saídas desejadas e a realização das análises; e, por fim, a interpretação e geração das análises da estatística descritiva, representada pela reflexão em cima dos resultados alcançados. A partir da otimização da rede neural minimizando o erro de previsão da velocidade do vento, continuou-se com os cálculos para previsão da potência eólica de saída e, por fim, da rampa de energia eólica para cada sítio tropical e para o sítio subtropical. A Figura 37 representa um fluxograma técnico para execução da simulação, desde a coleta dos dados brutos em campo (*in situ*) até publicação do artigo científico ou arquivamento dos resultados gerados pela pesquisa.

Já na última fase do processo, nomeada como fase IV ou de decisão e conclusão, teve-se a comparação de sistemas e identificação das melhores soluções cujo objetivo foi verificar as diferenças existentes entre as várias alternativas de solução; a etapa de documentação, a qual serve como guia para que outros possam replicar os experimentos realizados ou utilizar os resultados já alcançados, sendo que futuras modificações podem ser facilitadas com a devida documentação das simulações já feitas anteriormente; e a implementação e apresentação dos resultados alcançados, a qual reflete a decisão tomada em função das alternativas testadas, verificação dos objetivos traçados no planejamento e as possibilidades de melhorias no modelo e no processo de simulação.



Figura 37: Fluxograma de simulação para previsão neste estudo. Fonte: Autoria própria.

A seguir, é discutido sobre os critérios de medição de erro nas simulações desenvolvidas nos estudos.

5.4 Critérios de medição de erro

A estatística descritiva empregada neste estudo resulta em valores de *Erro*, *Mean Absolute Error* – MAE (Erro Absoluto Médio), *Mean Squared Error* – MSE (Erro Quadrático Médio), *Root Mean Square Error* – RMSE (Raiz do Erro Quadrático Médio), *Mean Absolute Percentage Error* – MAPE (Erro Percentual Absoluto Médio), Coeficiente de determinação R^2 , Coeficiente de correlação de *Pearson r* e Fator de 2 ou Fac2 (tal medida analisa o percentual de dados pertencentes ao intervalo $0,50 \le x \le 2,0$). Conforme Chen *et al.* (2018), estes critérios estatísticos são empregados para avaliar o desempenho de predição dos modelos de previsão da velocidade do vento. Para estes indicadores estatísticos são adequados valores próximos de 0,0 (zero) para o Erro, MAE, MSE, RMSE; 0,0% para o MAPE; 100% para o Fac2 e valores próximos de 1,0 (um) para os coeficientes R^2 e *r*. As Equações de 43 a 50 representam tais indicadores. Por início, tem-se o erro amostral sendo demonstrado na Equação 43:

$$e_t = o_t - f_t \tag{43}$$

Em que: e_t é o erro no período de tempo t; o_t é a atual observação no período de tempo t; f_t é a previsão no período de tempo t.

O MAE (Equação 44) mede a magnitude média do erro em um conjunto de previsões. Para ser mais específico, é a média sobre a amostra de verificação dos valores absolutos da diferença entre o valor observado e a previsão correspondente. O MAE é uma medição linear, o que significa que todas as diferenças estão recebendo o mesmo peso igualmente na média.

$$MAE = \frac{1}{n} \sum_{t=1}^{n} |e_t| \tag{44}$$

Em que: *MAE* é o Erro Absoluto Médio; *n* é o número de períodos de tempo.

Definimos o Erro Quadrático Médio, ou MSE, (Equação 45) como sendo o valor esperado do erro amostral ao quadrado:

$$MSE = \frac{1}{n} \sum_{t=1}^{n} e_t^2$$
(45)

Em que: MSE é o Erro Quadrático Médio.

O RMSE (Equação 46) é uma medição quadrática, que mede a magnitude média do erro. Como os erros são elevados ao quadrado antes de ser calculada a média, o RMSE fornece um peso maior aos erros maiores. Isso significa que o RMSE é mais útil quando grandes erros são particularmente indesejáveis.

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n} e_t^2}$$
(46)

Em que: RMSE é a raiz quadrada do Erro Quadrático Médio.

O MAPE (Equação 47) é a diferença entre o valor atual e o previsto dividido pelo valor atual. O módulo deste cálculo é então somado para cada previsão e dividido pelo número total de pontos previstos. Por fim, para que o resultado seja em porcentagem, multiplica-se o mesmo por 100%, como observa-se abaixo:

$$MAPE = \frac{1}{n} \sum_{t=1}^{n} \frac{|e_t|}{o_t} x 100\%$$
(47)

Em que: MAPE é o Erro Percentual Absoluto Médio.

O coeficiente de determinação (Equação 48), também chamado de R², é uma medida de ajustamento de um modelo estatístico linear generalizado, como a regressão linear, em relação aos valores observados.

$$R^{2} = \frac{\sum_{t=1}^{n} (f_{t} - \bar{o})^{2}}{\sum_{t=1}^{n} (o_{t} - \bar{o})^{2}}$$
(48)

Em que: R^2 é o Coeficiente de determinação (ou "*R* quadrado"); o_t é o valor observado; \bar{o} é a média das observações; f_t é o valor estimado (previsão) de o_t .

Em estatística descritiva, o coeficiente de correlação de Pearson (Equação 49), também chamado de "coeficiente de correlação produto-momento" mede o grau da correlação (e a direção dessa correlação – se positiva ou negativa) entre duas variáveis de escala métrica (intervalar ou de razão).

$$r = \frac{\sum_{t=1}^{n} (o_t - \bar{o})(f_t - \bar{f})}{\sqrt{\sum_{t=1}^{n} (o_t - \bar{o})^2 \sum_{t=1}^{n} (f_t - \bar{f})^2}}$$
(49)

Em que: r é o Coeficiente de correlação de *Pearson*; o_t são os dados observados; f_t são os dados preditos; \bar{o} é a média dos dados observados; \bar{f} é a média dos dados da preditos.

Na Equação 50 é apresentado o cálculo do Fator de 2,

$$x = \frac{f_t}{o_t} \tag{50}$$

se $0,50 \le x \le 2,0$, então o valor é contabilizado dentro do Fator de 2. Ao final, soma-se a quantidade de valores dentro do Fator de 2 e registra-se a representação percentual diante do número de amostras. Desta maneira, para comparar o desempenho dos *frameworks*, foram utilizados os indicadores estatísticos de desempenho supracitados. A seguir, são apresentados os resultados alcançados da tese.

CAPÍTULO 6

6 **RESULTADOS E DISCUSSÕES**

Neste Capítulo 6 são apresentados os resultados e as discussões obtidos por essa pesquisa de tese na forma de 5 artigos e 1 *extended abstract*. ² O *extended abstract* está descrito no ANEXO A. Todos os trabalhos aqui apresentados foram importantes e fundamentais para se atingir os objetivos específicos e, assim, o objetivo geral do projeto proposto.

6.1 Artigo 1: Short-term wind speed forecasting in Uruguay using computational intelligence

O artigo "*Short-term wind speed forecasting in Uruguay using computational intelligence*" foi submetido e publicado na revista Heliyon Volume 5, Issue 5, May 2019, e01664 (DOI: https://doi.org/10.1016/j.heliyon.2019.e01664). Esta pesquisa de previsão da velocidade do vento no horizonte de tempo de 1 h a 12 h aplicando inteligência computacional via redes neurais artificiais com algoritmo de aprendizado de máquina supervisionado foi pioneira na região subtropical da América do Sul, sítio de Colônia Eulacio, Departamento de Soriano, Uruguai. Os dados atmosféricos utilizados no estudo para treinar, validar e testar as redes neurais foram coletados nas alturas anemométricas de 10,0 m, 25,7 m, 81,8 m e 101,8 m. Diferentes configurações de rede foram testadas com a finalidade de encontrar a mais eficiente para a previsão. Os resultados alcançados corroboram com o desenvolvimento energético do Uruguai que vivencia uma era de ampliação da participação da energia eólica em sua matriz energética. A análise estatística deste artigo vai ao encontro da análise registrada na simulação do sítio de Mucuri na Bahia (região tropical).

² Formatação permitida pelo Programa de Pós-Graduação em Engenharia Ambiental – PPGEA, da Universidade Federal do Espírito Santo – UFES, conforme o Regimento do PPGEA Art. 34°. e § 3°.

Heliyon 5 (2019) e01664



Short-term wind speed forecasting in Uruguay using computational intelligence



P.J. Zucatelli^a, E.G.S. Nascimento^b, G.Y.R. Aylas^b, N.B.P. Souza^a, Y.K.L. Kitagawa^a, A.A.B. Santos b, A.M.G. Arce , D.M. Moreira

^a Federal University of Expérito Santo-UFES, ES, Brazil
^b Manufacturing and Technology Integrated Campus – SENAI CIMATEC, BA, Brazil
^c Universidad de la República – UDELAR, Montevidao, Uruguay

ARTICLE INFO

Keywords:

Energy

Atmospheric science

Computer science

ABSTRACT

Short-term wind speed forecasting for Colonia Eulacio, Soriano Department, Uruguay, is performed by applying an artificial neural network (ANN) technique to the hourly time series representative of the site. To train the ANN and validate the technique, data for one year are collected by one tower, with anemometers installed at heights of 101.8, 81.8, 25.7, and 10.0 m. Different ANN configurations are applied for each site and height; then, a quan titative analysis is conducted, and the statistical results are evaluated to select the configuration that best predicts the real data. This method has lower computational costs than other techniques, such as numerical modelling. For integrating wind power into existing grid systems, accurate short-term wind speed forecasting is fundamental. Therefore, the proposed short-term wind speed forecasting method is an important scientific contribution for reliable large-scale wind power forecasting and integration in Uruguay. The results of the short-term wind speed forecasting showed good accuracy at all the anemometer heights tested, suggesting that the method is a powerful tool that can help the Administración Nacional de Usinas y Transmissiones Eléctricas manage the national energy supply.

1. Introduction

Renewables are sources of clean, plentiful, and potentially competitive energy sources (GE Renewable Energy, 2019). These types of energy differ from fossil fuels in their diversity and abundance and in their potential for use anywhere on the planet; above all, they produce neither greenhouse gases-which cause climate change-nor polluting emissions. Despite the present volatility of renewables, their costs are decreasing; in contrast, the costs of fossil fuels are increasing (Acciona, 2019). Currently, environmental pollution is a global issue that is receiving considerable attention, and alternative renewable resources to reduce pollution must be developed (Cheng et al., 2017). As a burgeoning type of renewable energy, wind energy has developed rapidly in the past decade (Jiang et al., 2016; Lia et al., 2018). Huang et al. (2015) reported that wind power has the largest market share among renewable energy sources and is expected to maintain its rapid growth in the coming years.

The country of Uruguay, which is in Latin America, surprisingly obtains 94% of its electricity from renewable sources (Watts, 2015). In addition to old hydropower plants, large investments in solar, wind, and biomass have increased the proportion of these sources to 55% of the total energy, significantly exceeding the global average of 12% and the European average of approximately 20%. In this sense, wind power has attracted attention, and various wind farms have been constructed in Uruguay to harness wind energy. Among the countries of the world, Uruguay ranks 4th in the generation of wind energy, according to the Renewables 2017 Global Status Report (REN21, 2017). Additionally, Uruguay has good relationships with Argentina and Brazil, which contribute to its excellent growth with regard to wind and solar energy.

Wind speed for ecasting is fundamental in the planning, controlling, and monitoring of intelligent wind power systems. However, owing to the stochastic and intermittent nature of wind, it is difficult to make satisfactory predictions (Liu et al., 2018). Accurate short-term wind speed forecasting (1-12 h ahead) plays a substantial role in addressing this challenge. A correct forecast of the wind speed can reduce the risk of wind energy breaking in hybrid energy systems. According to Haupt and Kosovic (2017), accurate wind speed prediction is a challenging problem that requires disparate data and multiple models that are each applicable for a specific timeframe, as well as computational-intelligence techniques

https://doi.org/10.1016/j.heliyon.2019.e01664

Received 18 October 2018; Received in revised form 22 February 2019; Accepted 2 May 2019

2405-8440/© 2019 The Authors. Published by Elsevier Ltd. This is an open access article under the CC BY-NC-ND license (http://creativecommons.org/licenses/by-

^{*} Corresponding author.

E-mail address: davidson.moreira@gmail.com (D.M. Moreira).

P.J. Zucatelli et al.

Heliyon 5 (2019) e01664



Fig. 1. Location of the Colonia Eulacio tower in Soriano department, Uruguay.

Table 1

Height [m]	Hourly average speed [m/s]	Standard deviation [m/s]
101.8	7.214	3.002
81.8	6.811	2.742
25.7	4.980	2.216
10.0	4.016	2.081

for successfully blending the models and observational information in real time and delivering the results to decision makers and grid operators.

Regarding wind energy, the variability of the wind direction and speed throughout the day makes it difficult to decide whether to drive wind turbines, because in practice, wind exhibits temporal variations of several orders of magnitude, e.g. annual variations (owing to climatic changes), seasonal variations, daily variations (owing to the local microclimate), hourly variations (owing to land and sea breezes), and short-duration variations (bursts). Esmaeili and Twomey (2012) explained that the large fluctuations in the wind speed make forecasting the power generated by wind turbines difficult. The spatial variation of wind energy is also very large. The topography and soil roughness significantly influence the distribution and velocity of winds. Economic losses occur if wind turbines are subjected to unfavourable weather conditions. Therefore, it is necessary to develop reliable tools to predict the wind speed, even in the short term, i.e., 1 h to several hours ahead, for economic load dispatch planning, making reasonable load decisions, and operational security in electricity markets (Chang, 2014)

Many studies have focused on the development of reliable wind speed and wind power forecasting models, and numerous models have been recently proposed (particularly in the last five years: 2014 to 2019). The mainstream models used by scientific researchers can be divided into several categories (Jiang et al., 2016): physical forecasting models (e.g. Prediktor, Previento, LocalPred, eWind, and WRF); conventional statistical forecasting models (e.g. autoregressive model, autoregressive moving average, and autoregressive integrated moving average (ARIMA)); artificial-intelligence forecasting models (e.g. feed-forward multilayer perceptron, recurrent neural network, long short-term memory, gated recurrent unit, radial basis function, Bayesian network, and extreme learning machine); statistical machine-learning models (e.g. support vector machine, least-squares support vector machine, and Gaussian process); fuzzy logic-based models (e.g. genetic algorithm optimised fuzzy model, adaptive neuro-fuzzy inference system, Markov-switching model, and Kalman filtering); spatial-correlation forecasting models (which consider the wind speed at not only the target site but also several adjacent sites); and hybrid models. Hybrid models can be divided into two types: the first type involves the combination of individual models (e.g. ARIMA + ANN and ARIMA + extreme learning machine), and the second type employs algorithms to enhance the forecasting capacity of models (e.g. wavelet packet decomposition + ANN and genetic algorithms + ANN).

Computational methods have been used to evaluate the wind behaviour and thus obtain valuable information for the electro-energy sector in several parts of the world. Interest in applications of mathematical modelling and numerical simulation of the atmosphere for the estimation of wind power potential is growing, and it already drives an important market. Computational models can be useful for the identification of locations with high wind potential and, when used operationally in daily integrations, short-term energy generation forecasting (Peng et al., 2013). Ren et al. (2014), Wasilewskia and Baczynski (2017), and Alencar et al. (2017), among others, obtained good results with small error via mathematical modelling and numerical simulation for short-term prediction using computational-intelligence techniques. especially multilayer perceptron neural networks with feed-forward and back-propagation training algorithms. Alencar et al. (2017) developed ultra-short, short, medium, and long-term prediction models for the wind speed based on artificial-intelligence and computational-intelligence techniques, including artificial neural network (ANN), ARIMA, and hybrid models, e.g. time-series forecasting using wavelets.

The use of wind power generation for fuelling society and industries is very challenging for current power system operations. One reason for this is that wind power is an intermittent energy source with a high degree of randomness and instability (Zhang et al., 2017). Another reason is that wind power is a non-dispatchable energy source that cannot be controlled by operators in the same way as other resources (Erdem and Shi, 2011). These challenges can be effectively resolved if the wind speed can be forecasted accurately and precisely (Liu et al., 2010). Therefore, improving the accuracy of short-term wind speed forecasting and developing improved methods are crucial for the operation of wind power plants (Li et al., 2011; Akinci, 2011; Nogay et al., 2012; Okumus and Dinler, 2016). Recent studies on short-term wind speed forecasting,



Fig. 2. Schematic of the procedure used for wind-speed forecasting for 1, 3, 6, 9, and 12 h after the start time.

Table 2

Best ANN configuration for Colonia Eulacio, Soriano Department, Uruguay.					
101.8 m	81.8 m	25.7 m	10.0 m		
Best ANN configu	nation	-			

e.g. those of Alencar et al. (2017), Sun et al. (2018), and Khosravi et al. (2018), revealed an increase in the forecasting error with the increase of the forecast time horizon.

López-Manrique et al. (2018) presented a work that was conducted using climatic data from Cuauhtemotzin, Mexico: wind speed, wind direction, solar radiation, air temperature, relative humidity, rain precipitation, and atmospheric pressure measured at 26, 33, and 54 m.a.g.l. From a computational methodology, a time series exogenous model was developed to forecast wind speed in 10-min intervals (very short-term wind speed forecast), using multi-gene genetic programming and global sensitivity analysis. The forecasting model considered the four previous values of the wind speed and as exogenous parameters the solar radiation, air temperature, atmospheric pressure, and relative humidity. The main difference between this work and ours relies on the fact that we are applying artificial neural networks, instead of genetic algorithms, to predict the wind speed in a time horizon of 1-12 hours ahead (short-term wind speed forecasting). Additionally, we are using meteorological data collected by anemometers from Colonia Eulacio, Soriano Department, Uruguay (a humid subtropical climate region), and not climatic data from global circulation models. It can be observed that the forecast horizon studied here is longer than what was targeted in their work, and the higher height studied here comes closer to the height of a typical wind

turbine (100 m) commonly used in the largest wind farms, which justifies the effort employed in this work.

Therefore, the objective of this study was to identify the most efficient ANN configuration using Multilayer Perceptrons with the Levenberg-Marquardt Backpropagation training algorithm for wind speed forecasting 1 h ahead. The algorithm was also applied for 3, 6, 9, and 12 h forecasts by using observational data collected from one tower, which was located in Colonia Eulacio, Soriano Department, Uruguay, as a reference. Anemometers were installed at heights of 101.8, 81.8, 25.7, and 10.0 m, during the period between August 08, 2014 and August 07, 2015. In the literature, there are no published short-term forecasts of the wind speed for 1, 3, 6, 9, and 12 h at four different an emometric heights in subtropical regions (south temperate zone), such as Uruguay. Therefore, this study is a novel investigation related to the operation of wind power plants for Colonia Eulacio in Soriano Department. The main contributions of the study are as follows. a) The proposed model elucidates the behaviour of the wind speed and allows accurate wind speed prediction at different anemometric heights, e.g. 101.8, 81.8, 25.7, and 10.0 m. The model can be used to identify optimal locations of wind turbines and forecast irregular wind energy, for different anemometric heights. Short-term wind energy forecasting can be improved using this model to enhance the wind power quality 12 h ahead. b) No previous studies applied computational intelligence for short-term wind speed forecasting for such heights in Uruguay, which is a humid subtropical climate region. Therefore, the results constitute a significant contribution to the scientific community. c) The short-term wind speed forecasting model is an important contribution for reliable large-scale wind power forecasting and integration in Uruguay.

This paper is organised as follows: Section 2 presents the

P.J. Zuanelli et al.

Table 3

imulation results:	1, 3,	6.	and,	12-h wind	-speed forecasting	for Colonia I	Eulacio usir	g the ANN model.	
								0	

Anemometer at 101.8 m						
Prediction horizon [h]	MAE	MSE	RMSE	Coefficient: r	Coefficient: R-squared	MAPE (%)
1	0.892	1.406	1.185	0.921	0.849	15.840
3	1.678	4.683	2.164	0.730	0.534	30.137
6	2.241	7.954	2.820	0.549	0.302	39.190
9	2.595	10.380	3.221	0.432	0.186	43.658
12	2.872	12.385	3.519	0.346	0.119	47.104
Anemometer at 81.8 m						
Prediction horizon [h]	MAE	MSE	RMSE	Coefficient: r	Coefficient: R-squared	MAPE (%)
1	0.840	1.241	1.114	0.913	0.833	17.173
3	1.482	3.668	1.915	0.717	0.514	31.863
6	1.845	5.456	2.335	0.548	0.300	40.783
9	2.025	6.433	2.536	0.445	0.198	44.668
12	2.159	7.155	2.674	0.364	0.132	47.296
Anemometer at 25.7 m						
Prediction horizon [h]	MAE	MSE	RMSE	Coefficient: r	Coefficient: R-squared	MAPE (%)
1	0.690	0.854	0.924	0.902	0.813	18.954
3	1.147	2.370	1.539	0.696	0.484	32.494
6	1.409	3.500	1.870	0.502	0.252	39,206
9	1.517	4.091	2.022	0.379	0.144	41.735
12	1.574	4.461	2.112	0.292	0.085	42.800
Anemometer at 10.0 m						
Prediction horizon [h]	MAE	MSE	RMSE	Coefficient: r	Coefficient: R-squared	MAPE (%)
1	0.632	0.724	0.851	0.906	0.821	24.141
3	1.085	2.124	1.457	0.689	0.476	42.594
6	1.371	3.230	1.797	0.459	0.211	53.500
9	1.461	3.683	1.919	0.328	0.107	57.530
12	1 497	3.858	1 966	0 264	0.070	58 858



Fig. 3. Graphical comparison of the Pearson correlation coefficient at different heights.

methodology, Section 3 presents the numerical results and discussions, and Section 4 presents the conclusions.

2. Methodology

Regarding the computational procedure, we adopted a computational-intelligence model using a Multilayer Perceptron ANN with Levenberg-Marquardt Backpropagation and a training algorithm for short-term wind speed forecasting (1, 3, 6, 9, and 12 h) in Colonia Eulacio, Soriano Department, Uruguay. The mean wind diurnal cycle in different seasons for this location was described by Lucas et al. (2016), whose analysis employed the same data used in the present study. According to More and Deo (2003), Wang et al. (2014), Chang (2013), and

Qin et al. (2015), this is the most commonly used type of neural network for studies of this nature. Esen and Esen (2008), Mendes and Marengo (2010), Martins et al. (2012), and Cervone et al. (2017) reported that the aforementioned algorithm is the most effective neural network training algorithm. ANN models are implemented through layers of interconnected nodes, which are called neurons, and the definition of the number of layers is variable, depending on the characteristics of the problem. At least three layers are required: an input layer, a hidden layer, and an output layer (Russel and Norvig, 2010).

All ANNs must be trained, validated, and tested. Pelletier et al. (2016) reported that network training occurs in two phases, and each phase runs through the network in one direction. These two phases are called the forward and backward phases. The forward phase is used to define the

Heliyon 5 (2019) e01664

P.J. Zuanelli et al.

Heliyon 5 (2019) e01664



Fig. 4. Graphical comparison of the Root Mean Square Bror (RMSE) at different heights.

network output for a given input pattern. The backward phase uses the desired output and the output provided by the neural network to update the weights of its connections. Knowledge is acquired by the network from its environment through a learning process, and the connecting forces between neurons, which are called synaptic weights, are used to store the acquired knowledge. The procedure used for the learning process is called a learning algorithm, and its function is to modify the synaptic weights of the network in an orderly way to achieve the project goal (Haykin, 1999).

Validation employs a set of data used to calculate the error during training, for monitoring the fit level of the ANN to the training data. Generalisation is the ability of the network to respond correctly to conditions never experienced before, that is, the testing dataset. According to Haykin (1999), there are different possibilities for structuring an ANN, because it is necessary to select the type of neuron, the number of input parameters, the number of hidden layers, the type of training, and the architecture configurations. To develop an ANN model, a set of input parameters and a set of output parameters are necessary. These sets are subdivided for use in two different steps: network training and validation of the produced estimates. The correct selection of the predictors is fundamental for a satisfactory performance of the model (Mori and Umezawa, 2009).

The advancement of wind-energy technology has allowed for the installation of turbines at high altitudes; thus, knowledge of the wind potential at these heights is required. To validate the estimates and increase the number of wind farms installed in Soriano Department, anemometric towers with a height of 100.8 m were installed at locations with promising winds in Colonia Eulacio, which is the region considered in this study (see Fig. 1).

As previously mentioned, the measuring station used for this study is located in the southwestern region of Uruguay (Colonia Eulacio, Soriano Department) and is composed of a triangular tower 100.8 m in height and 0.45 m wide. According to Datum WGS84, it is located at 33° 16 'S, 57° 31 'W (Lucas et al., 2016). The altitude of the installation location is approximately 100 m, and the location is surrounded by fields with plains; thus, it is characterised by non-complex terrain. The station is owned by the Administración Nacional de Usinas y Transmissiones Eléctricas (UTE), which is a state-owned company in Uruguay that is responsible for the generation, distribution, and commercialisation of electrical energy in the country.

As reported by Lucas et al. (2017), to verify the quality of the data observed by the anemometers of interest in the Colonia Eulacio tower, the data were pre-processed. The data were obtained by the datalogger via measurements every 2 s, and the values were stored and a statistical average was calculated every 10 min. Additionally, the standard deviation and maximum and minimum values of the measured variables were presented. The values of interest were the average wind speeds recorded every 10 min. The configuration of the assembly and the tower on which the measuring instruments are installed significantly affect the quality and reliability of the data. After ensuring that the measurements were not affected by the tower mat, the presence or absence of missing data was verified and, after verification of the magnitudes, possible anemometer reading problems, such as "locking," were identified. Finally, the data for one year observed at intervals of 10 in 10 min were converted to hourly values, being realised the means of the original measures measured in the interval of 60 min (1 h).

The software used to program and perform this computational procedure was MATLAB version 7.10.0 2010, together with the NNTool (Neural Network Toolbox) graphical interface. The proposed ANN configurations to be analysed are as follows.

Configuration 1: Three layers, seven input nodes, nine hidden neurons, and one output node.

Configuration 2: Three layers, seven input nodes, six hidden neurons, and one output node.

Configuration 3: Three layers, seven input nodes, three hidden neurons, and one output node.

Configuration 4: Three layers, seven input nodes, one hidden neuron, and one output node.

Configuration 5: Four layers, seven input nodes, nine hidden neurons $(1^{\pi}$ hidden layer), six hidden neurons $(2^{nd}$ hidden layer), and one output node.

Configuration 6: Four layers, seven input nodes, six hidden neurons (1st hidden layer), three hidden neurons (2nd hidden layer), and one output node.

Configuration 7: Four layers, seven input nodes, one hidden neuron $(1^{st}$ hidden layer), one hidden neuron $(2^{nd}$ hidden layer), and one output node.

Each training and forecast simulation took, on average, 3 s (personal computer, 8 GB RAM). The inputs for each ANN were the hour, day, month, year, and average hourly values of the wind speed, wind direction, and temperature. Wind is the result of the displacement of air masses. It is caused by the effects of atmospheric pressure (or barometric pressure) differences between two regions (Alencar et al., 2017) and is



Fig. 5. Wind speed forecasting at 1 h: a) The results of one-step predictions of the wind speed series. b) Comparison data of a factor of two (wind predicted/ wind anemometer versus time) of the results obtained with the forecast model (one-step predictions) and the real data. c) Comparison data of a factor of two (wind predicted/wind anemometer versus wind anemometer) of the results obtained with the forecast model (one-step predictions) and the real data.

influenced by natural effects such as solar radiation, continentality (a measure of the difference between continental and marine climates characterised by the increased range of temperatures that occurs over land compared with water), sea level, latitude, altitude, soil roughness, and humidity (Arya, 2001; Santos et al., 2018). Therefore, the insertion of these meteorological parameters as input data contributes to efficient training of the ANN. In this sense, a descriptive statistic regarding the wind speed at different heights is shown in Table 1.



Fig. 6. Wind speed forecasting at 3 h: a) The results of three-step predictions of the wind speed series. b) Comparison data of a factor of two (wind predicted/ wind anemometer versus time) of the results obtained with the forecast model (three-step predictions) and the real data. c) Comparison data of a factor of two (wind predicted/wind anemometer versus wind anemometer) of the results obtained with the forecast model (three-step predictions) and the real data.

The output vector is the predicted wind speed for the next hour. The measuring height for the wind speed and wind direction is divided into four cases: 101.8 and 60.8 m; 81.8 and 60.8 m; 25.7 and 60.8 m; and 10.0 and 60.8 m. The total amount of data is $8.760 \times 7 = 61.320 (100\%)$, and the amount of data used for training and validation is $6.133 \times 7 = 42.931$ (70.01%). Once the best model for reproducing the real data is obtained, it is important to verify its accuracy by utilising data outside the training sample. Thus, the last 2.627 h are not considered during the training of



Fig. 7. Wind speed forecasting at 6 h: a) The results of six-step predictions of the wind speed series. b) Comparison data of a factor of two (wind predicted/wind anemometer versus time) of the results obtained with the forecast model (sixstep predictions) and the real data. c) Comparison data of a factor of two (wind predicted/wind anemometer versus wind anemometer) of the results obtained with the forecast model (six-step predictions) and the real data.

Fig. 8. Wind speed forecasting at 9 h: a) The results of nine-step predictions of the wind speed series. b) Comparison data of a factor of two (wind predicted/ wind anemometer versus time) of the results obtained with the forecast model (nine-step predictions) and the real data. c) Comparison data of a factor of two (wind predicted/wind anemometer versus wind anemometer) of the results obtained with the forecast model (nine-step predictions) and the real data.

the ANN. Therefore, the amount of data used for the forecast simulation is $2.627\times7=18.389$ (29.99%).

Each of the aforementioned ANN configurations was trained, validated, and tested to determine which was the most efficient for shortterm (1, 3, 6, 9, and 12 h) wind speed forecasting. The activation functions, which define the outputs of the neurons in terms of their activity levels, that were inserted in this simulation were the sigmoidal function, in the form of the hyperbolic tangent function (continuous, increasing, differentiable, and nonlinear), for the hidden layers, and the linear function for the output layer. The presence of nonlinearity in the activation function of the hidden layer is important because without nonlinearity the input-output relation of the network can be reduced to that of a single-layer perceptron, as the use of the linear function in the output layer stems from the need to obtain a linear output.

To perform the prediction, the first step is to identify what ANN architecture can best perform the 1 h forecasting of the wind speed for each height. Then, this predicted wind speed value is assigned as the input for the second hour of forecasting, while the other input parameters used at







Fig. 9. Wind speed forecasting at 12 h: a) The results of twelve-step predictions of the wind speed series. b) Comparison data of a factor of two (wind predicted/ wind anemometer versus time) of the results obtained with the forecast model (twelve-step predictions) and the real data. c) Comparison data of a factor of two (wind predicted/wind anemometer versus wind anemometer) of the results obtained with the forecast model (twelve-step predictions) and the real data.

the start of the forecasting are kept unchanged (e.g. wind direction and air temperature). Thus, the forecast of the wind speed for the second hour is calculated. This procedure, which is shown in Fig. 2, is repeated until the nth hour of forecasting is reached.

Results obtained using the Persistence model were used for reference. Glebel et al. (2011) explained that the Persistence (also called the Naïve Predictor) is the model most frequently used to evaluate the performance of a forecasting model. It is one of the simplest prediction models, second only to predicting the mean value for all times, which is known as Heliyon 5 (2019) e01664

Table 4 Percentage of the data of a factor of two (fraction of data [%] for $0.5 \le$ Wind predicted/Wind anemometer \le 2.0).

Height of observed data	Prediction horizon	Percentage of the data of a factor of two
101.8 m	1 h	98.44%
	3 h	93.29%
	6 h	88.29%
	9 h	82.43%
	12 h	77.44%
81.8 m	1 h	98.02%
	3 b	93,94%
	6 h	91,22%
	9 h	89.95%
	12 h	89.48%
25.7 m	1 h	97.94%
	3 h	94.25%
	6 h	91.57%
	9 h	89.95%
	12 h	88.99%
10.0 m	1 h	95.51%
	3 h	89.41%
	6 h	84.74%
	9 h	81.93%
	12 h	81.64%

climatology prediction. In the Persistence model, the forecast for all times ahead is set to the current value. Mathematically, this is expressed as $v(t+\Delta t) = v(t)$, where v is the wind speed [m/s] and t is time [s]. Hence, the error (e) for t = 0 (zero) time steps ahead is e = 0 (zero). For short-time prediction horizons (e.g. a few minutes or 1 h), this model is the benchmark for all other prediction models (Giebel et al., 2011). As the prediction horizon increases, the quality of the predicted wind speed is expected to decrease, which is evaluated in the next section.

3. Results & discussion

The statistical indicators employed to analyse the results are the rootmean-square error (RMSE), mean squared error (MSE), mean absolute error (MAE), mean absolute percentage error (MAPE), coefficient of determination (\mathbb{R}^2 or R-squared), and Pearson's correlation coefficient (r or Pearson's r). Values close to 0.0 are adequate for the MAE, MSE, and RMSE, values close to 0.0% are adequate for the MAPE, and values close to 1.0 are adequate for the R-squared. The Pearson's correlation coefficient ranges from -1.0 to 1.0. A value of 1.0 implies that a linear equation perfectly describes the relationship between matrices A and B, with all the data points on a line for which B increases as A increases. A value of -1.0 implies that all the data points are on a line for which B decreases as A increases. A value of 0.0 implies that there is no linear correlation between the variables.



Fig. 10. Comparison between the ANN model and the Persistence reference model for wind speed forecasting 1 h ahead.

P.J. Zucatelli et al.

Each ANN architecture presented in Section 2 was trained, validated, and tested using the input vector for each hour, with the wind speed of the next hour as the desired output vector. The use of a large number of hidden layers is not recommended, because the error measured during training is propagated to the previous layer. The number of neurons in the hidden layers is generally defined empirically and depends strongly on the distribution of the training and validation patterns of the network. McGovern et al. (2017) explained that when connected and trained in multiple layers, the ANN model can represent any nonlinear function. Quan et al. (2013) affirmed that an advantage of the ANN model is that it can learn the relationship between complex, nonlinear inputs and outputs.

The best ANN configurations for Colonia Eulacio are presented in Table 2. The aforementioned ANN architectures that were identified as the most efficient for the 1 h forecast for each height were applied in the computational simulation to predict the wind speed for 3, 6, 9, and 12 h in Colonia Eulacio at all the heights tested.

The results for the MAE, MSE, RMSE, MAPE, R-squared, and Pearson coefficients for 1, 3, 6, 9, and 12 h wind speed forecasting in Colonia Eulacio are presented in Table 3. The lowest values of the MAE, MSE, RMSE, and MAPE, as well as the highest Pearson's correlation coefficient and R-squared values, were recorded for the 1 h forecast for all the analysed heights (101.8, 81.8, 25.7, and 10.0 m). The mean R-squared and Pearson's r for 1 h wind speed forecasting were 0.829 and 0.910, respectively. The lowest MAPE value was 15.840%, for a height of 101.8 m and a prediction horizon of 1 h.

The results in Table 3 indicate that as the wind speed forecasting load increases, the quality of the output data of the ANN prediction decreases. Thus, a longer forecasting time yields a larger error. As explained in the previous section, these results were expected, as the adopted procedure uses input data from the start of the forecasting, in addition to the wind speed computed in each forecast hour, to predict the wind speed for the n^{th} hour, leading to an accumulated error. This result is in accordance with the literature, e.g. Kusiak et al. (2009), Blonbou (2011), Carpinone et al. (2015), and Filik and Filik (2017).

Fig. 3 presents a graphical comparison of the Pearson coefficient for different heights and Fig. 4 presents a graphical comparison of the RMSE for different heights. The graph lines of 101.8 and 81.8 m are approximate (Fig. 3). The graph indicates that as the anemometric height increases, the RMSE increases, indicating that the error between the actual and predicted values increases (see Fig. 4).

Figs. 5, 6, 7, 8, 9 presents a comparison of the results of the ANN wind speed forecasting at 1, 3, 6, 9, and 12 h with real data, which were recorded at Colonia Eulacio with an anemometer height of 101.8 m. The ratio between the wind speed predicted by the ANN model and that measured by the anemometer can be observed with respect to time and the measured wind speed. The middle lines in the plots indicate one-toone correspondence, and the outer lines indicate difference by a factor of two.

The degradation of the forecast can also be observed by noting that as the forecast horizon increases, the predicted curve moves away from the real curve. Table 4 presents the percentage of data between 0.5 and 2.0. In this table, the worst values are observed for the height of 10.0 m. This result is explained by the inherently increased turbulence near the Earth's surface and its influence on the wind speed. It is assumed that as the height increases, the influence of the surface on the wind speed decreases.

The results in Fig. 10 indicate that on average, the ANN has better results than the Persistence model for a prediction horizon of 1 h.

The computational-intelligence model implemented in this study is applicable at different locations. The investigation of mechanisms that aid the short-term wind speed forecasting, as performed in this study for 1, 3, 6, 9, and 12 h for the generation of energy in wind farms, has been critical to ensure the proper functioning of traditional energy systems. Accurate prediction of the short-term wind speed output helps system Heliyon 5 (2019) e01664

operators to adjust scheduling plans in a timely manner, make correct decisions, reduce the standby capacity, reduce the operational costs of the power system, and mitigate the adverse effects of wind power fluctuation.

The computational cost of using computational intelligence in studies such as the present one increases as the expected workload increases, but the cost is still lower than that of numerical simulation and mathematical modelling for wind speed forecasting using atmospheric models such as Weather Research and Forecasting (WRF) (Lucas et al., 2017). This is because in the WRF model, equations of transport phenomena and fluid mechanics are implemented and solved, such as the Euler equations for compressible and nonhydrostatic fluid in the form of fluxes using conservative variables (Skamarock et al., 2008), which demand a longer computation time. Additionally, the outputs include several meteorological parameters besides the wind speed, such as the wind direction, solar radiation, air pressure, and air temperature for every vertical layer. In comparison, neural networks and other computational-intelligence techniques require considerably less computational power, although they are limited by the need to be trained and validated against observational data for each location and height, which is not always feasible.

4. Conclusions

The objective of the present study was to identify the most efficient ANN configuration for predicting the wind speed 1 h ahead and then use this model to predict the wind speed 3, 6, 9, and 12 h ahead. Observational data collected from an anemometric tower, with anemometers installed at heights of 101.8, 81.8, 25.7, and 10.0 m, were used as a reference. The study was performed for a subtropical region in Colonia Eulacio, Soriano Department, Uruguay for a period of 1 year (8760 h).

According to the statistical results of this study, the application of computational intelligence is a viable alternative for the prediction of wind speed and thus wind power generation, mainly owing to the low computational cost. However, an ANN architecture that is appropriate for the project must be selected, and the data fed to the network must quantitatively and qualitatively analysed, as these variables directly impact the results of the forecast.

This work is relevant because it is a first step in the application of the ANN model to wind speed prediction, and there are no published studies on the application of computational intelligence through neural networks for this region. Additionally, Uruguay is a country with subtropical characteristics (temperate zone) and excellent wind technology development, and it is highly ranked internationally with regard to wind energy. The statistical results for the prediction horizons of 1–12 h, for each anemometric height, exhibited predictable behaviour similar to that for short time ranges. These results are novel because no other studies have used this computational model to predict the wind speed for 1, 3, 6, 9, and 12 h in Uruguay.

The application of the ANN for wind speed prediction at different heights was adequate. The 1 and 3 h forecasts were particularly accurate, and as the forecast time increased, the accuracy of the results decreased, as expected. However, this degradation did not make the forecasting results for longer prediction horizons useless; thus, the proposed technique can produce satisfactory short-term wind speed forecasts (up to 12 h) with low computational costs to help wind-farm operators with decision making.

There are two main approaches for atmospheric modelling and prediction of wind fields, as applied to the energy sector: 1) the estimation of average wind speeds, taking into account climatological data, and 2) short- and medium-term wind forecasts. The first approach involves selecting sites that exhibit good wind conditions for wind power generation to provide the necessary data for evaluating the economic feasibility and to establish the parameters to be adopted in the development of generating units and wind farms. The short-term estimates are particularly useful for identifying periods of high wind occurrence, as well as the

P.J. Zuanelli et al.

occurrence of winds that can damage the system. Medium-term wind forecasting is useful for the management of electrical energy resources and aims to resolve deficiencies in wind power generation by providing electricity from other sources.

This study contributes to the scientific community by providing wind speed forecasting information for a country of South America with high wind power potential (Uruguay), considering the interest of private companies and UTE in the energy sector.

Declarations

Author contribution statement

Pedro J. Zucatelli: Conceived and designed the experiments; Performed the experiments.

- Erick G.S. Nascimento: Conceived and designed the experiments; Wrote the paper.
 - Georgynio Y.R. Aylas: Performed the experiments.

Noéle B.P. Souza: Analyzed and interpreted the data.

Yasmin K.L. Kitagawa, Alex A.B. Santos: Contributed reagents, materials, analysis tools or data.

Alejandro G. Arce, Davidson M. Moreira: Conceived and designed the experiments; Analyzed and interpreted the data.

Funding statement

This work was supported by SENAI CIMATEC and FAPESB.

Competing interest statement

The authors declare no conflict of interest.

Additional information

No additional information is available for this paper.

Acknowledgements

We thank SENAI CIMATEC, FAPESB and UTE.

References

- Acciona, 2019. Renewable Energy. Link to access: https://www.acciona.com/renewabl
- Acciona, 2019. Renewable Energy. Link to access: https://www.acciona.com/renewable-e-nergy/. (Accessed 29 January 2019).
 Akinci, T.C., 2011. Short term wind speed forecasting with ANN in Batmam, Turkey. Electron. Electrical Engineering 107 (1), 41–45. Kaunas: Technologija, 2011.
 Alencar, D.B., Afonso, C.M., Oliveira, R.C.L., Rodriguez, J.L.M., Leite, J.C., Riho, J.C.R., 2017. Different models for forecasting wind power generation: case study. Energies 10 (12):1076. 10 (12), 1976.
- Arya, S.P., 2001. Introduction to Micrometeorology. S. Pal Arya, second ed. Academic
- Press. xxv + 420 pp. Bionbou, R., 2011. Very short-term wind power forecasting with neural networks and adaptive Bayesian learning. Renew. Energy 36, 1116–1124. Carpinone, A., Giorgio, M., Langella, R., Testa, A., 2015. Markov chain modeling for very-
- Carpinone, A., Giorgin, M., Langella, R., Texh, A., 2015. Markov chain modeling for ver-short term wind power forecasting. Electr. Power Syst. Res. 122, 152-158.
 Cervone, G., Clemente-Harding, L., Alessandrini, S., Morache, L.D., 2017. Short-term photovoltaic power forecasting using artificial neural networks and an analog ensemble. Renew. Energy 108, 274-286.
 Chang, W.Y., 2013. Application of Inckpropagation neural network for wind power generation forecasting. Int. J. Digit. Content Technol. Its Appl. 7, 502-509.
 Chang, W.Y., 2014. A literature review of wind forecasting methods. J. Power Energy Eng. 2, 161-168.
- Cheng, W.Y.Y., Liu, Y., Bourgeois, A.J., Wu, Y., Haupt, S.E., 2017. Short-term wind
- forecast of a data assimilation/weather forecasting system with wind turbine
- torecast of a data assimulation/ weather torecasting system with wind turbine ane momenter measurement assimilation. Renew. Energy 107, 340–351.
 Erdem, E., Shi, J., 2011. ARMA based approaches for forecasting the tuple of wind speed and direction. Appl. Energy 88, 1405–1414.
 Esen, H., Seen, M., 2008. Forecasting of a ground-coupled heat pump performance using neural networks with statistical data weighting pre-processing. Int. J. Therm. Sci. 47 (4), 471.
- (4), 431-441.
- naeili, M.A., Twomey, J., 2012. Self-organizing map (SOM) in wind speed forecasting a new approach in computational intelligence (CI) forecasting methods. Proceeding

Heliyon 5 (2019) e01664

of the ASME/ISCIE 2012 International Symposium on Flexible Automation, ISFA, St. Louis, Missouri, USA, June 18-20, 2012.

- Holm, mussual, Oct. June 192, solution using artificial neural networks based on multiple local measurements in Eskischir, 3rd international conference on energy and environment research, ICEER 2016, 7-11 September 2016, Barcelona, Spnin, Energy cedia 107, 264-269
- GE Renewable Energy, 2019. Wind Energy: How it Works. What is Wind Energy? Link to cess: https://www.ge.com/renewableener.gy/wind-energy/technology/what wind-energy. (Accessed 29 January 2019). G., Brownsword, R., Kariniotakis, G., Denhard, M., Drad, C., 2011. The State-Ofaccess: https://
- Giebel, G., Brown The Art in Short Term Prediction of Wind Power: A Literature Overview, second ed.
- ANEMOG.phus.
 Haupt, S.E., Kosovic, B., 2017. Variable generation power forecasting as a big data problem. IEEE Trans. Sustain. Energy 8 (2). April 2017.
- Haykin, S., 1999. Neural Network: A Comprehensive Foundation. Simon Haykin, second ed. Pearson Education Inc., Hamilton, Ontario, Canada, p. 823p. Huang, C., Li, F., Jin, Z., 2015. Maximum power point tracking strategy for large-scale wind generation systems considering wind turbine dynamics. IEEE Trans. Ind.
- Elect
- Jiang, P., Wang, Y., Wang, J., 2016. Short-term wind speed forecasting using a hybrid. del, Energy.
- Khoaravi, A., Koury, R.N.N., Machado, L., Pabon, J.J.G., 2018. Prediction of wind speed and wind direction using artificial neural network, support vector regression a adaptive neuro-fuzzy inference system. Sustain. Energy Technol. Assess. 25, 146-160. Kusiak, A., Zheng, H., Song, Z., 2009. Short-term prediction of wind farm po
- mining approach. IEEE Trans. Energy Convers. 24 (1), 125-136.
- (ii) G., Ski, J., Zhou, J., 2011. Bayesian adaptive combination of short-term wind speed forecasts from neural network models. Renew. Energy 36, 352–359.
- synchronous optimisation for multi-step short-term wind speed forecasting. Appl. Energy 215, 131-144.
- Intergy 215, 131–144.
 Iui, H.P., Shi, J., Erdem, E., 2010. Prediction of wind speed time series using modified Taylor Kriging method. Energy 35, 4870–4879.
 Iui, H., Mi, X., IJ, Y., 2018. Wind speed forecasting method based on deep learning
- strategy using empirical wavelet transform, long short-term memory neural network and El
- a acegy using empirical waveer is anatom, ang soort een memory ised a network nd Elman neural network. Energy Convers: Manag, 156, 498–514. Maurique, L.M., Macias-Melo, E.V., May Tzuc, O., Basson, A., Aguilar-Castro, K.M., Iemández-Pérez, I., 2018. Assessment of resource and forecast modeling of wind López-n. Herní speed through an evolutionary programming approach for the north of Tehuantepec
- appear littogram and an and a second seco
- Especial IX Brazilian Micrometeorology Workshop, pp. 426-434. as, E.A., Arce, A.M.G., Moraes, M.R., Boezio, G.C., 2017. Vertical wind profile simulations in the planetary boundary layer with the WRFARW model. Scientia Luc Plena 13 13 (04), 049913.
- Martins, F.R., Pereira, E.B., Guamieri, R.A., 2012. Solar radiation forecast using artificial
- Martins, F.R., Pereira, E.R., Guamieri, R.A., 2012. Solar radiation forecast using artificial neural networks. Int. J. Energy Sci. 2, 217-227.
 McGovent, A., Elmore, K.L., Gagne H, D.J., Haupt, S.E., Karstens, C.D., Lagerquist, R., Smith, T., Williams, J.K., 2017. Using Artificial Intelligence to Improve Real-Time Decision-Making for High-Impact Weather. American Meteorological Society. Mendes, D., Marengo, J.A. (2010. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios. Theor. Appl. Climatol. 100 (3-4), 413–421.
 More, A., Deo, M.C., 2003. Forecasting wind with neural networks. Mar. Struct. 16 (1), 35–49.
- Word, H., Umezawa, Y., 2009. Application of NBTree to Selection of Meteorologic Variables in Wind Speed Prediction. Transmission & Distribution Conference / Exposition: Asia and Pacific, Seoul, Korea.
- Nogay, H.S., Akinci, T.C., Eidukeviciue, M., 2012. Application of artificial neural networks for short term wind speed for exacting in Mardin, Turkey. J. Energy South. Ar. 23 (4), 2-7. Available from: http://www.science.orgaa/sciel.ophp?corpit_eci_attreat.gpid=S 1021447X2012000500001&lng=en&nnn=iso. (Accessed 22 February 2019).
- Okumus, I., Dinler, S., 2016. Current status of wind energy forecasting and a hybrid Ontaine, C., Dinel, A., 2018. Charles hand on Mand Sherger Archaeolog and Anyonic method for hourly predictions. Energy Convers. Manag. 123, 362–371.
 Pelletier, F., Masson, C., Tahan, A., 2016. Wind turbine power curve modelling using artificial neural network. Renew. Energy B9, 207–214.

- artificial neural network. Renew. Energy B9, 207-214.
 Peng, H., Lin, F., Yang, X., 2013. A hybrid strategy of short term wind power prediction. Renew. Energy 50, 590-595.
 Qin, S., Liu, F., Wang, J., Song, Y., 2015. Interval forecasts of a novelty hybrid model for wind speeds. Energy 1, 8-16.
 Quan, D.M., Ogliari, E., Grimaccia, F., Leva, S., Mussetta, M., 2013. Hybrid Model for Hourly Fo recast of Photovoltaic and Wind Power. Politecnico di Milan
- From y Forecast of FROM VOIDS of the Arman Wass, Million Holy, p. 20156.
 Ren, C., An, N., Wang, J., Li, L., Hu, B., Shang, D., 2014. Optimal parameters selection for BP neural network based on particle awarm optimization: a case study of wind speed forecasting. Knowl-Based Syst. 56, 226–239.
- forecasting. Knowl-Based Syst. 55, 226–239.
 Bassel, S., Novrig, P., 2010. Artificial Intelligence: A Modern Approach. Stuart J. Russell and Peter Norvig, third ed. Pearson Education, Inc., p. 1153p
 RIN 21, 2017. Renewables 2017 Global Status Report. REN21 Secretarist, Paris.
 Santus, J.V.C., Moreira, D.M., Moret, M.A., Nascimento, E.G.S., 2018. Analysis of long-range correlations of wind speed in different regions of Babia and the Abrolhos headpointer form! December 1627. 665 627 Archipelago, Brazil. Energy 167, 680-687.

P.J. Zucatelli et al.

- Skamarock, W.C., Klemp, J.B., Dudhis, J., Gill, D.O., Barker, D.M., Huang, X.Y., Wang, W., Powers, J.G., 2008. A Description of the Advanced Research WRF Version 3 (NCAR Technical Note), Mesoscale and Microscale Meteorology Division Do NCAR. Boulder, Colorado, USA
 Sun, G., Jiang, C., Cheng, P., Liu, Y., Wang, X., Fu, Y., He, Y., 2018. Short-term wind power forecasts by a synthetical similar time series data mining method. Renew. Energy 115, 575-584.
 Wang, J., Zhang, W., Li, Y., Wang, J., Dang, Z., 2014. Forecasting wind speed using empirical mode decomposition and Elman neural network. Appl. Soft Comput. 23, 452-459. October 2014.

Heliyon 5 (2019) e01664

- Wasilewskia, J., Baczynski, D., 2017. Short-term electric energy production fore-casting at wind power plants in pareto-optimality context. Renew. Sustain. Energy Rev. 69, 177–187.
- 177-187. Watts, J., 2015. Uruguay Makes Dramatic Shift to Nearly 95% Electricity from Clean Energy: Keep it in the Ground Renewable Energy. Link to Access: https://www.the guardian.com/environment/2015/dec/03/uruguay-makes-dramatic-shift-to-nea rly-95-clean energy. (Accessed 11 January 2019). Zhung, J., Wei, Y., Tan, Z., Wang, K., Tian, W., 2017. A hybrid method for short-termwind speed forecasting. Sustainability 9, 596.

6.2 Artigo 2: Scientific and technological development in Bahia: a case study using computational intelligence

O artigo "Scientific and technological development in Bahia: a case study using computational intelligence" a ser submetido à revista Energy, ampliou a área de abrangência no sítio tropical, estado da Bahia, com relação à previsão da velocidade do vento usando inteligência computacional via redes neurais artificiais com algoritmo de aprendizado de máquina supervisionado previamente estudado com os dados anemométricos de Mucuri. Neste estudo, foram coletados dados atmosféricos em torres anemométricas de 150 m de altura na cidade de Esplanada (região Nordeste da Bahia) e na cidade de Mucugê (região central). Tais dados medidos foram unidos aos dados do município de Mucuri e caracterizaram bem a diversidade do estado da Bahia, salienta-se que este estado brasileiro é maior em área (km²) do que alguns países europeus como Alemanha, Suica, Bélgica, Espanha e Portugal. Assim, este estudo de caso fez uma análise estatística descritiva advinda dos resultados preditos pelas redes neurais comparados com os resultados medidos pelas 3 torres anemométricas dos sítios da região tropical na Bahia. Portanto, o objetivo deste trabalho é contribuir para a gestão e o desenvolvimento regional da Bahia de forma ampliada com políticas de energia sustentável para abastecer os setores produtivos industriais e a sociedade em geral, como, por exemplo, a energia elétrica dos ventos do Nordeste. A visão é convergir os resultados aqui registrados para beneficiar a Bahia por meio de projetos futuros que promovam o seu desenvolvimento.

SCIENTIFIC AND TECHNOLOGICAL DEVELOPMENT IN BAHIA: A CASE STUDY USING COMPUTATIONAL INTELLIGENCE

DESENVOLVIMENTO CIENTÍFICO E TECNOLÓGICO NA BAHIA: UM ESTUDO DE CASO USANDO INTELIGÊNCIA COMPUTACIONAL

Pedro Junior Zucatelli, pedrojrzucatelli@gmail.com¹ Erick Giovani Sperandio Nascimento, ericksperandio@gmail.com² Alex Álisson Bandeira Santos, alex.santos@fieb.org.br² Davidson Martins Moreira, davidson.moreira@gmail.com²

¹Federal University of Espírito Santo, Av. Fernando Ferrari, 514, Goiabeiras, 29075-910, Vitória, ES, Brazil.

²Manufacturing and Technology Integrated Campus SENAI CIMATEC, Av. Orlando Gomes, 1845, Piatã, 41650-010, Salvador, BA, Brazil.

Abstract

Technological development regarding renewable energy sources with the ultimate goal of reducing environmental pollution is an issue that deserves attention, mainly due to air pollution from high emissions of greenhouse gases into the atmosphere in several nations, which is an issue that has received a global alert. A renewable energy source means sustainable energy something that cannot run out, or is endless, like the wind. The wind is a plentiful source of energy. Featuring a growing alternative energy source in the global market, wind power has shown rapid development in the past ten years, from 2010 to 2020. Therefore, the objective of this work is to contribute to the management and regional development of Bahia in order to amplify sustainable energy policies to supply the industrial productive sectors and society in general, such as the electric energy from the northeast winds, for example. The vision is to converge the results registered here to benefit Bahia through future projects that promote its development. For the execution of this case study on wind speed prediction, anemometric data were collected in Bahia, in 3 poor regions that need improvement in the management of regional development. The observed data come from anemometers located at 100, 120, and 150 m. These heights are important due to the real positions of the wind turbine hub. The results for shortterm wind speed forecasting showed good accuracy to be used as a powerful tool to help Brazil's national grid operator (ONS) for the energy supply in Bahia.

Keywords: Artificial neural networks. Computational modeling. Computer sciences. Regional management and development. Renewable resources.

Resumo

O desenvolvimento tecnológico em relação às fontes renováveis de energia com o objetivo final de reduzir a poluição ambiental é um tema que merece atenção, principalmente devido à poluição do ar pelas elevadas emissões de gases de efeito estufa na atmosfera em várias nações, tema que tem recebido um alerta global. Uma fonte de energia renovável significa energia sustentável - algo que não pode acabar, ou é infinito, como o vento. O vento é uma fonte abundante de energia. Apresentando uma crescente fonte alternativa de energia no mercado

global, a energia eólica tem apresentado rápido desenvolvimento nos últimos dez anos, de 2010 a 2020. Portanto, o objetivo deste trabalho é contribuir para a gestão e o desenvolvimento regional da Bahia de forma ampliada com políticas de energia sustentável para abastecer os setores produtivos industriais e a sociedade em geral, como, por exemplo, a energia elétrica dos ventos do nordeste. A visão é convergir os resultados aqui registrados para beneficiar a Bahia por meio de projetos futuros que promovam o seu desenvolvimento. Para a execução deste estudo de caso de previsão da velocidade do vento, foram coletados dados anemométricos na Bahia, em 3 regiões carentes que necessitam de aprimoramento na gestão do desenvolvimento regional. Os dados observados vêm de anemômetros localizados a 100, 120 e 150 m de altura. Essas alturas são importantes devido às posições reais do cubo da turbina eólica. Os resultados da previsão de velocidade do vento prazo mostraram boa precisão para serem usados como uma ferramenta poderosa para ajudar o operador nacional da rede (ONS) no fornecimento de energia na Bahia.

Palavras-chave: Redes neurais artificiais. Modelagem computacional. Ciências da Computação. Gestão e desenvolvimento regional. Recursos Renováveis.

1. Introduction

Technological development regarding renewable energy sources with the ultimate goal of reducing environmental pollution is an issue that deserves attention, mainly due to air pollution from high emissions of greenhouse gases into the atmosphere in several nations, which is an issue that has received a global alert. The consequences of global warming are diverse and complex and can cause irreversible damage to humanity. One of the most notable consequences is the melting of the glaciers. The melting of the glaciers generates environmental and social upheavals. This phenomenon alters the temperature of the oceans, causing an environmental imbalance and affecting mainly marine species. Other consequences of global warming are desertification, alteration of the rain regime, intensification of droughts in certain places, water scarcity, an abundance of rain in some locations, storms, hurricanes, floods, changes in ecosystems, reduction of biodiversity, loss of areas fertile for agriculture.

The evolution of the use of alternative energy sources is very important, given the unsustainable impact of conventional sources of non-renewable energy, which pollute the environment by burning fossil fuels. This is an option that allows combating environmental pollution, greenhouse gases, climate change, and global warming, as is the case with renewable energy sources, e.g., wind energy (CHENG et al., 2017; AKDAG and YILDIRIM, 2020). Due to these environmental issues, there is a trend towards the incorporation of renewable sources connected to the energy distribution system (ZUCATELLI et al., 2019a). Brazilian energy policy, driven by environmental interests and the search for diversification of the country's energy matrix, has

been encouraging the generation of electric energy based on these sources, both for the connection in the transmission and distribution systems of large generation parks, wind energy, as well as for the distributed microgeneration and minigeration interconnected to the distribution system. Figure 1 shows the sources of energy in Brazil. Eighty percent (80%) of Brazilian wind farms are in the Northeast, a region that has one of the best winds in the world for producing wind energy (ABEEolica, 2021).



Figure 1: Sources of energy in Brazil in Giga Watts (GW).

Source: adapted from ABEEolica (2021).

In terms of wind potential, there is a wide variety of wind regimes, i.e. the southern region and the northeast of Brazil. In the southern region, the variability of direction and wind transmission is greater because this region suffers an influence of cold fronts. However, in this region, this difficulty is counterbalanced by greater scientific knowledge and a greater number of measurement systems. In contrast, in the northeast, the climate is tropical, where there are huge gaps in scientific knowledge of wind behavior in the region and relatively lacking in measurement systems. In this sense, the fact that trade winds develop on oceans, impose the need to use wind profiles derived from remote sensing of satellites, in addition to the challenges of complex terrain and coastal regions. These are considered the main scientific frontiers in wind predictability.

In Brazil, the electric energy trading chamber (CCEE) acts like an operator in the Brazilian electric energy market, aimed at enabling a competitive, sustainable, and safe trading environment. The CCEE promotes discussions and proposes solutions for the development of the national electric sector, making the dialogue between the agents and the instances of formulation of policies and regulation. The institution's focus is on the evolution of the commercialization segment, based on neutrality, liquidity, and symmetry of information. Accounting involves the calculation of the difference between the energy measured and that contracted by an agent, valued at the difference settlement price (PLD) for financial settlement at CCEE. This step is performed based on the Marketing Rules, taking into account the short-term market exposures, the receipt/payment of system service charges (ESS), the energy reallocation mechanism (MRE) and the consolidation of results to be settled, including any financial adjustments. In this context, is inserted the nowcasting. The World Meteorological Organization specifies nowcast for 0 to 6 h ahead.

Wind power prediction is important for the reliability of the electrical system and can help the planning for wind farms. Brazil is ranked 7th in the World Ranking of wind energy installed capacity, and Bahia is ranked 2nd in the Brazilian Ranking of wind energy installed capacity (Figure 2). It is worth mentioning that 80% of Brazilian wind farms are in the Northeast, a region that has one of the best winds in the world for producing wind energy. The favorable winds for producing wind energy are more constant, have a stable speed, and do not change direction frequently (ABEEolica, 2021).



Figure 2: Capacity installed and the number of wind farms in Brazil.

Source: adapted from ABEEolica (2021).

Computational intelligence (CI) or artificial intelligence (AI) is inserted in this context because it has been applied to predict the behavior of the wind in studies involving wind energy and its regional potential for managing or installing wind farms. Scientifically, CI refers to a set of bioinspired computational methods capable of treating complex real-world problems. CI is based on models inspired by nature, for example, artificial neural networks (ANN), genetic algorithms, or swarm intelligence. CI methods aim to perform tasks that require reasoning, machine learning, deep learning, decision making, and optimization. Machine learning can be classified into 4 types:

a) Supervised learning: classification (e.g. identify fraud detection, image classification, customer retention, diagnostics) and regression (e.g. advertising popularity prediction, weather forecasting, market forecasting, estimating life expectancy, population growth prediction, wind power forecasting).

b) Unsupervised learning: dimensionality reduction (e.g. big data visualization, meaningful compression, structure discovery, feature elicitation) and clustering (customer segmentation, targeted marketing, recommender systems).

c) Semi supervised learning includes both the problems discussed previously and it uses both labeled and non-labeled data.

d) Reinforcement learning: e.g. real-time decisions, game AI, skill acquisition, learning tasks, robot navigation.

Therefore, the main contributions of this work can be summarized as follows: the computational model proposed in this paper elucidates the behavior of the wind speed prediction at three important heights, and at three important sites in Bahia, a humid tropical region. Research on wind power forecasting usually focuses on prediction methods where the design of the input vector is based on anemometer data collected at 10 m. The need to use physical equations (e.g. logarithmic profile or power/log law) to calculate the wind at heights greater than 10 m adds errors in wind predictions. Therefore, this study used weather data measured at 100, 120, and 150 m for ANN input to training, validation, and test sets. This is important due to the real hub height of the wind turbines in wind farms. The closer the anemometer is placed for the eventual height of the wind turbine hub (e.g. 100, 120, and 150 m), the more accurately it measures the meteorological variables for which the wind turbine is exposed. Then, these results constitute a significant contribution to the Brazilian electricity market and for the scientific and technological development in Bahia. In terms of wind potential, there is a wide variety of wind

regimes, i.e. the southern region and the northeast of Brazil. In the southern region, the variability of wind is greater because this region suffers an influence of cold fronts. However, in this region, this difficulty is counterbalanced by greater scientific knowledge and a greater number of measurement systems. In contrast, in the northeast, the climate is tropical, where there are huge gaps in scientific knowledge of wind behavior in the region and relatively lacking measurement systems. In this sense, the fact that trade winds develop on oceans, impose the need to use wind profiles derived from remote sensing of satellites, in addition for the challenges of complex terrain and coastal regions. These are considered the main scientific frontiers in wind predictability. The remaining sections of the article are organized as follows: a section that describes the methodology shows the study region, and the data used in the work and provides details of the computational framework used in the model, a section that presents and discusses obtained results, and a section that presents the conclusions of the research.

2. Literature review

Recent scientific works highlight wind, wind power and short-term wind speed forecasting using AI by supervised machine learning and deep learning. Zucatelli et al. (2019a; 2019b) show that the short-range wind speed prediction (1 to 12 h) in Soriano Department (humid subtropical region in Uruguay), is performed applying computational intelligence by supervised machine learning, using ANN technique (multilayer perceptron – MLP, recurrent neural network – RNN, gated recurrent units – GRU, and long short-term memory – LSTM, a deep learning algorithm-based method) with anemometer data. The ANN was trained and validated to perform the prediction 1 h ahead, and then, using it, the ANN was applied for recursively infer the forecasting for the next hours of the wind speed. The computational complexity is smaller than if it were necessary to train to predict the next 12 hours for each input/sample of anemometric data, for example. The tabulated statistical results and the results showed in graphs of the short-range wind speed prediction showed good accuracy at all the anemometer heights tested (10.0 m, 25.7 m, 81.8 m, and 101.8 m), suggesting that this computational method is a powerful tool for the electrical energy sector in Uruguay.

Zucatelli et al. (2019c) present the nowcasting prediction of wind speed to six hours ahead, applying AI by supervised machine learning, using MLP and comparing with RNN, and anemometers data collected by an anemometric tower at a height of 100 m in Brazil (tropical region) and 101.8 m in Uruguay (subtropical region), both countries located in South America.

The proposed method is benchmarked against other computational methods published in the literature and proved to be precise and accurate.

Santos et al. (2019) study the analysis of long-range correlations of wind speed in different regions of Bahia and the Abrolhos Archipelago, Brazil. The work confirms the universal nature of crossover appearance in onshore situations. The authors show a systematic analysis used in detecting long-term correlations, known as detrended fluctuation analysis, was applied to wind speed data from 3 towers located at the State of Bahia (with anemometers at heights of 80, 100, 120, and 150 m) and in the Abrolhos Archipelago with measurements taken at 10 m. The main contribution was to show the character universal of the crossover phenomenon in onshore cases, considering experimental data from elevated towers at different sites, suggesting that this occurs due to solar radiation/surface interaction during the daily cycle in the planetary boundary layer.

Chen et al. (2019) present a multifactor spatio-temporal correlation model based on a combination of convolutional neural network – CNN and LSTM for wind speed prediction. The performance of the proposed model is verified by three experiments. In each experiment, different datasets are used to forecast the wind speed of different target sites in the spring and summer, and eight performance evaluation metrics are used to evaluate each model.

Demolli et al. (2019) study wind energy prediction performed based on daily wind speed data using deep learning algorithms. Classification algorithms were used to forecast values of the given wind speed values. Daily mean wind speed values were generated using the hourly wind speed dataset, and the daily total wind energy was modeled using daily wind speed and the standard deviation.

Dupré et al. (2020) discuss the performances of downscaling approaches using information from numerical weather prediction models and compare them with the statistical approaches for the wind speed prediction at hub height. The authors determine the added value of model output statistics for classical time series-based methods compared for the sub-hourly forecasts of wind speed. Two downscaling approaches are tested: one that includes local wind speed measurements and another using explanatory variables from numerical weather prediction model outputs.

Wang et al. (2020) recommend a hybrid wind speed prediction approach based on Bayesian model averaging and Ensemble learning. Self-organizing map clustering and K-fold cross-validation are used to generate multiple sets of the training subsets with the same distribution from the training set of meteorological data to increase the difference of the input samples of the base learners. These training subsets are imported into three base learners, i.e. backpropagation neural network, Radial basis function neural network, and Support vector machine, to train the model.

Zhao et al. (2020) develop a novel data-driven method to realize combination forecasts of average wind speed and turbulent standard deviation for both wind components, the study focused on 4 h ahead predictions of 16 steps to be well demand orientated. For the multi-step bivariate forecast task, an adaptive multi-model strategy based on 1D CNN is put forward.

In this way, this work contributes to the scientific community, emphasizing the tropical region of Bahia, given its importance in the development of wind energy (or wind power) in Brazil.

3. Methodology

It should be noted that the advancement of technology in wind energy has allowed the installation of turbines at high levels, requiring knowledge of the wind potential at ever greater heights. To validate the estimates and disseminate the installation of wind farms in the state of Bahia, four anemometric towers of 150 m were installed in locations with promising winds. At this point, it is important to mention that the Bahia state is consolidating the position of the largest Brazilian pole of investments in wind energy, as well as becoming an international reference in this area. Numerous investments have been made by new companies, generating job opportunities and income for the population, including with positive impact in needy regions. A new production chain, focused on wind energy, was successfully implemented in Bahia, and continues to expand, boosting the economy.

In this study, the sites are Esplanada, Mucugê and Mucuri. The Esplanada city is in the microregion of the north coast of Bahia with an altitude of 140 m in relation to the sea level and it has a territorial area of 1,297.9 km², approximately. The Esplanada's anemometric tower is 40 km from the sea, with latitude 11°50'55.22"S and longitude 37°55'44.31"W. The Mucugê city is at an altitude of 984 m in relation to the sea level and is one of the municipalities

belonging to *Chapada Diamantina*, the central region of the state of Bahia, characterized by being a mountainous region and it has a territorial area of 2,482.2 km², approximately. The anemometric tower of Mucugê has located approximately 280 km from the Bahia coast, with a latitude of 13°21'01.92"S and longitude of 41°31'53.76" W. The Mucuri city is located at an altitude of 7 m in relation to the sea level and it has a territorial area of 1,774.7 km², approximately. The Mucuri's anemometer tower is in a coastal plain, at 340 m from the sea, with latitude 18°1'31.52"S and longitude 39°30'51.69"W (see Figure 3).



Figure 3: Location of towers in Bahia, Brazil.

This work defined the most efficient configuration, all of MLP with Levenberg-Marquardt feedforward backpropagation training algorithm, to predict the wind speed for 1-step ahead, and then apply it 2 to 12 h, using as reference observational data (744 h or 31 days) collected from three towers, with anemometers installed at 100, 120 and 150 m height, in all sites studied, in Bahia state, Brazilian Northeast region, for the period between April 28, 2016 until May 29, 2016 (Esplanada), September 07, 2016 until October 07, 2016 (Mucugê), and November 30, 2015 until December 31, 2015 (Mucuri).

All the experiments are developed in Matlab and the core configuration of the personal computer includes Intel Core i7-7500U processors running at 2.90 GHz, and a 64-bit system with 8 GB of RAM. To perform the training and validation of ANN, data (e.g. wind speed,

wind direction, pressure, temperature, and humidity) was applied. It is possible to observe, through Table 1, the information of each ANN configuration analyzed in this paper.

ANN with 3 layers				
Configuration	Input layer	1 hidden layer	Output layer	
i	9 nodes	9 neurons	1 node	
ii	9 nodes	6 neurons	1 node	
iii	9 nodes	3 neurons	1 node	
iv	9 nodes	1 neuron	1 node	
		ANN with 4 layers		
Configuration	Input layer	2 hidden layers	Output layer	
V	9 nodes	9 and 6 neurons	1 node	
vi	9 nodes	6 and 3 neurons	1 node	
vii	9 nodes	1 and 1 neuron	1 node	

Table 1: Configurations of each artificial neural network applied in this work.

The input for each ANN is hour, day, month, year, and average hourly values of wind speed, wind direction, air temperature, air humidity, and air pressure. The output vector is the predicted wind speed for the next hour. Once the best model was obtained to reproduce the real data, it is important to verify its accuracy utilizing the data outside the training sample. The total amount of data is 6,696 (100%), and the amount of data for training and validation is 4,950 (73.92%). This means to use the last 194 hours not considered during the training of the ANN. Therefore, the quantity of data for forecast simulation is 1,746 (26.08%). Each ANN configuration presented above was trained, validated, and tested to determine which would be the most efficient to perform short-term wind speed forecasting. Figure 4 and Figure 5 show the AI flowchart.







Figure 5: Schematic of the procedure used for wind speed prediction using AI.

The activation functions applied in this study were the sigmoidal function in the form of the hyperbolic tangent function for all hidden layers and linear function to the output layer.

4. Numerical results and discussions

The statistical treatment employed in the results are factor of 2 (or Fac2, that is the percentage of values $0.50 \le$ wind speed predicted/wind speed anemometer ≤ 2.0), mean absolute error (MAE), root-mean-square error (RMSE), coefficient of determination (R² or R-square) and Pearson's correlation coefficient (r), or Pearson's r. Each ANN architecture represented by the configurations defined and exposed in Table 1 was trained and validated using the input vector for each hour and presenting the wind speed of the next hour as the desired output. The best ANN configuration to Esplanada, Mucugê and Mucuri are showed in Table 2. The ANN architectures that were defined as the most efficient for the one-step forecast for each height, were applied in the computational simulation to predict the wind speed for 2 to 12 h in all sites and the all heights.

	Anemometer height			
Site	150 m	120 m	100 m	
	Th	e best ANN configura	tion	
Esplanada	vii	vii	vii	
Mucugê	iii	iii	iv	
Mucuri	i	vi	vi	

Table 2: The best ANN configuration to Esplanada, Mucugê and Mucuri.

The statistical results of the MAE, RMSE, R-square and Pearson coefficients with respect to the wind speed forecasting for 1 to 12 h to Esplanada, Mucugê and Mucuri are recorded in Tables 3, 4 and 5. It can be seen that the lowest values of MAE, and RMSE were recorded for the forecast of 1 h, as well as the highest Pearson's correlation coefficient and R-square values, for all the analyzed heights. The mean R-square and Pearson's r for wind speed forecasting for 1 h ahead was 0.614 and 0.783 (Esplanada), 0.847 and 0.920 (Mucugê), 0.890 and 0.943 (Mucuri), respectively. By performing a general statistical analysis of the predicted data, we can see that the forecast results for Esplanada had a smaller error when the forecast horizon exceeded 6 hours (when comparing with Mucugê and Mucuri).

Anemometer height: 150 m				
Prediction horizon (h)	MAE	RMSE	Pearson	R-square
1	0.821	1.081	0.795	0.632
3	1.169	1.519	0.567	0.322
6	1.420	1.871	0.348	0.121
9	1.646	2.105	0.202	0.041
12	1.812	2.291	0.015	0.0002
		Anemometer he	ight: 120 m	
Prediction horizon (h)	MAE	RMSE	Pearson	R-square
1	0.763	1.012	0.780	0.609
3	1.081	1.406	0.503	0.253
6	1.318	1.745	0.198	0.039
9	1.533	1.968	0.035	0.001
12	1.716	2.176	-0.156	0.024
		Anemometer he	ight: 100 m	
Prediction horizon (h)	MAE	RMSE	Pearson	R-square
1	0.718	0.967	0.776	0.602
3	1.021	1.346	0.496	0.246
6	1.292	1.680	0.227	0.051
9	1.515	1.892	0.058	0.003

Table 3: Simulation results of wind speed forecasting to Esplanada.

12	1.683	2.088	-0.155	0.024

Anemometer height: 150 m				
Prediction	MAE	RMSE	Pearson	R-square
norizon (n)	0.0.61	1.000	0.000	0.0.62
1	0.961	1.232	0.928	0.862
3	1.846	2.395	0.636	0.405
6	2.683	3.372	0.214	0.045
9	3.086	3.856	-0.042	0.001
12	3.191	3.931	-0.083	0.006
		Anemometer he	eight: 120 m	
Prediction horizon (h)	MAE	RMSE	Pearson	R-square
1	0.999	1 249	0.907	0.823
3	1.842	2.228	0.657	0.432
6	2.497	3.030	0.373	0.139
9	2.731	3.394	0.242	0.058
12	2.883	3.583	0.189	0.035
		Anemometer he	eight: 100 m	
Prediction horizon (h)	MAE	RMSE	Pearson	R-square
1	0.957	1.186	0.925	0.857
3	1.908	2.320	0.685	0.470
6	2.835	3.521	0.213	0.045
9	3.401	4.250	-0.103	0.010
12	3.695	4.635	-0.255	0.065

Table 4: Simulation results of wind speed forecasting to Mucugê.

Table 5: Simulation results of wind speed forecasting to Mucuri.

Anemometer height: 150 m					
Prediction horizon (h)	MAE	RMSE	Pearson	R-square	
1	0.790	1.008	0.928	0.862	
3	1.384	1.794	0.789	0.622	
6	2.164	2.929	0.467	0.218	
9	2.691	3.643	0.073	0.005	
12	2.908	3.856	-0.217	0.047	
		Anemometer h	eight: 120 m		
Prediction horizon (h)	MAE	RMSE	Pearson	R-square	
1	0.731	0.911	0.948	0.899	
3	1.177	1.514	0.857	0.734	
6	1.669	2.148	0.726	0.528	
9	2.232	2.686	0.595	0.355	
12	2.360	2.841	0.532	0.284	
Anemometer height: 100 m					

Prediction horizon (h)	MAE	RMSE	Pearson	R-square
1	0.718	0.908	0.953	0.909
3	1.373	1.878	0.809	0.655
6	2.434	3.628	0.343	0.118
9	3.422	5.043	-0.063	0.004
12	3.821	5.617	-0.082	0.006

The degradation of the forecast can also be noted by observing that, as the forecast horizon increases, the predicted curve moves away from the real curve. Table 6 presents the percentage of data on the factor of 2 (Fac2).

Site	Anemometer height	Prediction horizon	Factor of 2 (Fac2)
		1 h	99.48%
Mucugê Esplanada	150 m	3 h	98.43%
		6 h	96.68%
		9 h	92.97%
		12 h	91.21%
а	120 m	1 h	98.45%
lad		3 h	97.91%
olar		6 h	94.68%
Esp		9 h	90.81%
		12 h	86.26%
Site Esplanada	100 m	1 h	98.45%
		3 h	98.95%
		6 h	94.15%
		9 h	91.35%
		12 h	88.46%
		1 h	97.93%
		3 h	95.81%
	150 m	6 h	90.96%
		9 h	88.11%
		12 h	87.36%
		1 h	100.0%
Mucugê	120 m	3 h	96.34%
		6 h	90.96%
		9 h	90.27%
		12 h	86.81%
	100 m	1 h	99.48%
		3 h	96.34%
		6 h	88.30%
		9 h	83.24%
		12 h	79.12%
M uc uri	150 m	1 h	100.0%

Table 6: Simulation results of factor of 2 (Fac2).

3 h	100.0%	
6 h	92.55%	
9 h	85.41%	
12 h	84.62%	
1 h	100.0%	
3 h	100.0%	
m 6 h	98.40%	
9 h	93.51%	
12 h	93.41%	
1 h	100.0%	
3 h	98.95%	
m 6 h	86.17%	
9 h	78.38%	
12 h	79.12%	
	3 h 6 h 9 h 12 h 1 h 3 h 6 h 9 h 12 h 1 h 3 h 6 h 9 h 12 h 1 h 3 h 6 h 9 h 12 h 1 h 3 h 1 h 3 h 1 h 3 h 1 h	$ \begin{array}{c c c c c c c c c c c c c c c c c c c $

It is noticeable that the computational intelligence model implemented in this study suits different locations. The study of mechanisms that aid in the short-term wind speed forecasting, as performed in this work for 1 to 12 h, for the generation of energy in wind farms, has been critical to ensuring the correct functioning of traditional energy systems. An accurate prediction of short-term wind speed output will be advantageous for the independent system operators to adjust the scheduling plan in time, make the correct decision, reduce the standby capacity, cut down the operation cost of the power system, and weak the adverse effect of the wind power fluctuation.

5. Conclusions

The present work defined the most efficient ANN architecture to wind speed forecasting 1-step ahead and, after that, applied it for 2 to 12 h ahead, using as reference observational data collected from 3 anemometric towers with anemometers installed at 100, 120 and 150 meters height, located in a humid tropical region in the Esplanada, Mucugê and Mucuri cities, Bahia state, northeastern Brazil, for the period 31 days (or 744 hours). Atmospheric modeling and prediction of the wind field applied to the energy sector have two main approaches: the estimation of average winds considering climatological data and short- and medium-term wind forecasting. The first approach is to select sites that present better wind conditions for wind power generation in order to provide the necessary data to evaluate the economic feasibility and to establish the parameters to be adopted in the development of generating units and wind farms. As for the short-term estimates, these are particularly useful in identifying periods of higher wind occurrence, as well as the occurrence of winds that could damage the system. Meanwhile, the wind forecast in the medium-term is useful in the management of electric energy resources, aiming to supply deficiencies in the supply of wind generation by electricity from other sources.

By using computational intelligence through ANN with the main objective of predicting the wind speed in the interval of 1 to 12 h, using anemometric data collected at elevated heights, over 100 meters (120 and 150 m, for example) in 3 Brazilian cities with different characteristics of relief and climate (Mucugê, for example, does not suffer the influence of the sea-breeze and is at an altitude beyond the other cities mentioned in this study, approximately 1.0 km, not to mention that it is characterized as a semiarid and arid region, with wide vegetation of caatinga), it was demonstrated that this technique is plausible for any place since a similar short-term predictability behavior was observed for the three cities, for the three anemometric heights mentioned above. It contributes to the scientific community regarding the dissemination of this wind speed prediction information to a State with high wind power potential (i.e., Bahia), considering the interest of private companies in the energy sector and the interest in control of Brazil's national electric system operator (ONS). Therefore, it is suggested as future work using other observational data collected in different site and heights to perform short- and medium-range wind speed forecasting (48 h to 1 week ahead) using computational intelligence and Wavelets decompositions.

6. Acknowledgments

We thank Manufacturing and Technology Integrated Campus – SENAI CIMATEC, Salvador, Bahia, Brazil, for their computational support.

7. References

ABEEolica. (2021). Infowind Brazil Update 19 2021 - Feb, 11. Available from: http://abeeolica.org.br/wp-content/uploads/2021/02/2021_02_18_InfoWind19.pdf

AKDAG, S.; Yıldırım, H.; (2020). Toward a sustainable mitigation approach of energy efficiency to greenhouse gas emissions in the European countries. Heliyon Volume 6, Issue 3, March 2020, e03396. DOI: https://doi.org/10.1016/j.heliyon.2020.e03396

CHEN, Y.; Zhang, S.; Zhang, W.; Peng J.; Cai, Y.; (2019). Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting. Energy Conversion and Management Volume 185, 1 April 2019, Pages 783-799. DOI: https://doi.org/10.1016/j.enconman.2019.02.018

CHENG, W.Y.Y.; Liu, Y.; Bourgeois, A.J.; Wu, Y.; and Haupt, S.E.; (2017). Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation. Renewable Energy 107, 340-351.

DEMOLLI, H.; Dokuz, A.S.; Ecemis, A.; Gokcek, M.; (2019). Wind power forecasting based on daily wind speed data using machine learning algorithms. Energy Conversion and Management Volume 198, 15 October 2019, 111823. DOI: https://doi.org/10.1016/j.enconman.2019.111823

DUPRÉ, A.; Drobinski, P.; Alonzo, B.; Badosa, J.; Briard, C.; Plougonven, R.; (2020). Subhourly forecasting of wind speed and wind energy. Renewable Energy Volume 145, January 2020, Pages 2373-2379. DOI: https://doi.org/10.1016/j.renene.2019.07.161

SANTOS, J.V.C.; Moreira; D.M.; Moret; M.A.; Nascimento; E.G.S.; (2019). Analysis of longrange correlations of wind speed in different regions of Bahia and the Abrolhos Archipelago, Brazil. Energy 167 (2019) 680e687. DOI: https://doi.org/10.1016/j.energy.2018.11.015

WANG, G.; Jia, R.; Liu, J.; Zhang, H.; (2020). A hybrid wind power forecasting approach based on Bayesian model averaging and ensemble learning. Renewable Energy Volume 145, January 2020, Pages 2426-2434. DOI: https://doi.org/10.1016/j.renene.2019.07.166

ZHAO, X.; Jiang, N.; Liu, J.; Yu, D.; Chang, J.; (2020). Short-term average wind speed and turbulent standard deviation forecasts based on one-dimensional convolutional neural network and the integrate method for probabilistic framework. Energy Conversion and Management Volume 203, 1 January 2020, 112239. DOI: https://doi.org/10.1016/j.enconman.2019.112239

ZUCATELLI, P. J.; Nascimento, E. G. S.; Aylas, G. Y. R.; Souza, N. B. P.; Kitagawa, Y. K. L.; Santos, A. A. B.; Arce, A. M. G.; Moreira, D. M.; (2019a). Short-term wind speed forecasting in Uruguay using computational intelligence. Heliyon, Volume 5, Issue 5, May 2019, e01664. DOI: https://doi.org/10.1016/j.heliyon.2019.e01664

ZUCATELLI, P. J.; Nascimento, E. G. S.; Arce, A. M. G.; Moreira, D. M.; (2019b). Short-Range Wind Speed Predictions in Subtropical Region Using Artificial Intelligence. Journal of Systemics, Cybernetics and Informatics. Volume 17 - Number 4 - Year 2019. ISSN: 1690-4524. Available from: http://www.iiisci.org/journal/sci/Abstracts.asp?var=&previous=ISS1904>

ZUCATELLI, P. J.; Nascimento, E. G. S.; Santos, A. A. B.; Arce, A. M. G.; Moreira, D. M.; (2019c). Study of the Wind Speed Forecasting Applying Computational Intelligence [Online First], IntechOpen, DOI: 10.5772/intechopen.89758. Available from: https://www.intechopen.com/online-first/study-of-the-wind-speed-forecasting-applying-computational-intelligence

6.3 Artigo 3: An interdisciplinary machine learning approach for wind speed forecasting

Os resultados do artigo "An interdisciplinary machine learning approach for wind speed forecasting" foram apresentados no 23nd World Multiconference on Systemics, Cybernetics and Informatics (WMSCI 2019) na cidade de Orlando - EUA, e, originalmente, o trabalho foi publicado no Journal on Systemics, Cybernetics and Informatics (JSCI), ISSN: 1690-4524 (Online), Volume 17 – Number 4 – Year 2019, com o título: Short-Range Wind Speed Predictions in Subtropical Region Using Artificial Intelligence. A versão aqui apresentada foi publicada no mesmo Journal (JSCI), Volume 19 - Number 1 - Year 2021, pp. 211-236. ISSN: 1690-4524 (Online), porém com uma abordagem interdisciplinar do assunto e tema desta pesquisa <http://www.iiisci.org/journal/sci/FullText.asp?var=&id=IP128LL21>. Esta pesquisa visou realizar um comparativo de 4 diferentes tipos de redes neurais tais como MLP, RNN, GRU e as LSTM para prever a velocidade do vento no sítio subtropical e averiguar a acurácia de cada arquitetura empregada. Os dados atmosféricos empregados foram os coletados no sítio de Colônia Eulacio, Departamento de Soriano, Uruguai. As alturas anemométricas de registro foram 10,0 m, 25,7 m, 81,8 m e 101,8 m, e o horizonte de previsão foi de 1 h a 12 h. Este trabalho foi importante para entender sobre o custo computacional e como os diferentes tipos de rede se comportam na previsão da velocidade do vento tendo um mesmo conjunto de dados anemométricos.
An Interdisciplinary Machine Learning Approach for Wind Speed Forecasting¹

Pedro Junior Zucatelli¹, Erick Giovani Sperandio Nascimento^{*2}, Alejandro Mauricio Gutiérrez Arce³ and Davidson Martins Moreira⁴

¹Technological Center, Federal University of Espírito Santo – UFES Vitória, Espírito Santo, Brazil.
^{2,4}Manufacturing and Technology Integrated Campus – SENAI CIMATEC Salvador, Bahia, Brazil.
³Universidad de la República – UdelaR – FING – IMFIA Montevideo, Uruguay.
¹pedrojrzucatelli@gmail.com, ²ericksperandio@gmail.com, ³aguti@fing.edu.uy, ⁴davidson.moreira@gmail.com

* Corresponding Author

Abstract

Multidisciplinary researchers have collaborated with industry to develop advanced high-fidelity simulation and optimization tools for wind power plants and turbine interactions with the atmosphere. These tools are capable of modeling the processes needed to predict plant interactions and provide state-of-the-art simulation and analysis capabilities that allow industry stakeholders to perform a wide variety of forecasting and optimization to lower the energy costs and mechanical impacts. Insights from machine learning and computational intelligence have the potential to transform nearly every aspect of the world as we know it. Today, these insights are being applied to accelerate the pace of discovery in a wide variety of areas including materials science, wind and solar energy, health care, national security, emergency response, and transportation. In order to provide effective wind speed forecasting, an interdisciplinary approach based on artificial intelligence (AI) by supervised machine learning with human judgment is presented in this work. An approach is proposed for a representative site in the Colonia Eulacio, Soriano Department, Uruguay. The statistical results are evaluated, and a quantitative interpretation given to choose the machine learning configuration that best forecasts the actual data. These machine learning methods have lower computational costs than other techniques such as numerical models for weather or climate prediction. The proposed method is a scientific contribution to reliable large-scale wind energy prediction and integration into existing

¹ The paper "An Interdisciplinary Machine Learning Approach for Wind Speed Forecasting" was edited by Elsevier Language Editing Services.

We would like to express our deeply felt gratefulness to Professor Lilian Guarieiro for her comprehensive and detailed peer-editing of this document, as well as for her gentle alerts with regards to important issues.

grid systems in Soriano, Uruguay, and is a powerful tool that can help the UTE manage the national energy supply.

Keywords: Atmospheric Science; Interdisciplinary Communication; Machine Learning; System Sciences and Engineering; Wind Speed Forecasting.

1. Introduction

The integrity of natural ecosystems is already at risk from climate change caused by the intense emissions of greenhouse gases (or GHG emissions) such as carbon dioxide, methane, nitrous oxide, hydrofluorocarbons, perfluorocarbons, and sulfur hexafluoride into the atmosphere. Air pollution is currently a global issue that has received considerable attention. Alternative renewable resources such as solar and wind power must be developed to reduce global greenhouse gas emissions and, consequently, air pollution (Cheng et al., 2017). Nowadays, the adaptation of renewable energy (the most common examples include solar, wind, biomass, geothermal, hydropower, hydrogen, geothermal, and ocean energy) has become a national energy policy for many countries.

Wind energy has developed rapidly in the past ten years (Jiang et al., 2016; Lia et al., 2018). This burgeoning type of renewable energy has showed exponential growth between 2010 and 2020. It was reported in Huang et al. (2015) that wind energy has the largest market share among renewable energy sources and is expected to maintain its rapid growth in the coming decade. The country of Uruguay, which is in South America, the fourth largest continent in the world, surprisingly obtains 94% of its electricity from renewable sources (Watts, 2015) mainly in the form of solar and wind power. Among the countries of the world, Uruguay ranks 3rd in the generation of wind energy (REN21, 2020). Wind speed prediction is fundamental in the monitoring, planning, and control of intelligent wind power systems. However, owing to the intermittent and stochastic nature of wind, it is difficult to make satisfactory forecasts (Liu et al., 2018).

Wind energy varies over time. The variations occur mainly due to the influence of meteorological fluctuations over various time scales of within a minute, within an hour, from hour to hour, monthly and seasonally, and across years. Understanding these variations and their predictability is of key importance for the integration and optimal utilization of wind in the power system. Accurate

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021

short-term wind speed forecasting (1 h to 12 h ahead) plays a substantial role in addressing this challenge. The correct prediction of wind speed can reduce the risk of wind power breaking in hybrid energy systems.

Computational tools have been used to evaluate the wind behavior and thus obtain valuable information for the electro-energy sector in several parts of the world. Computational models can be useful for the identification of locations with high wind potential and, when used operationally in a daily and integrated manner, provide short, medium, and long-term wind energy generation forecasts (Peng et al., 2013). The use of wind energy generation for powering industries and society in general is very challenging for current power system operations. One reason for this is the fact that wind power is an intermittent energy source with a high degree of randomness and instability (Zhang et al., 2017).

Artificial intelligence (AI), machine learning, and deep learning are among the most important soft computing methods that are widely used in a large range of applications spanning across various scientific fields. Short-term wind speed prediction for Colonia Eulacio, Soriano Department, Uruguay, has been performed by applying an artificial neural network (ANN) technique to representative hourly time series data for the site (Zucatelli et al., 2019a). The authors adopted an AI model using an multilayer perceptron (MLP) ANN with the Levenberg-Marquardt backpropagation learning algorithm. An MLP is a class of feed-forward ANN. The ANN in that work was first trained to provide the forecast for the next 1 hour ahead and using the forecast, the trained network was then applied recursively to infer the wind speed forecast for the next 12 h. The results of the short-term wind speed prediction showed good accuracy at all the anemometer heights tested, suggesting that this method is a powerful tool that can help the Administración Nacional de Usinas y Trasmisiones Eléctricas (UTE) manage the generation, transmission, distribution, and commercialization of electrical energy in Uruguay.

Zucatelli et al. (2019b) reported short-term wind speed forecasting for the next 6 h ahead (nowcasting) through the application of computational intelligence. The forecast was generated by an recurrent neural network (RNN) using anemometer data collected by anemometric towers at heights of 100.0 m in Brazil (tropical region) and 101.80 m in Uruguay (subtropical region). Both Brazil and Uruguay are Latin American countries. The results of the study were compared with wind

speed prediction results from the literature. The prediction results from the method proposed in the study achieved superior evaluation metrics (error, and regression).

As an example of nowcasting, Zucatelli et al. (2019c) presented an application of the ANN technique to representative hourly time series data for short-term wind speed prediction at a site in the tropical region of Mucuri city, Bahia state, Brazil. To generate the training, validation, and test sets for this technique (supervised machine learning), one month of data was collected in a tower with anemometers installed at the heights of 100 m, 120 m, and 150 m. Different ANN configurations were applied with aim of finding the most efficient MLP ANN configuration with the Levenberg-Marquardt backpropagation training algorithm to forecast the wind speed for the next one hour ahead. The configuration was then applied to forecast the wind speed for the next three and six hours ahead. The coefficient of determination and the Pearson coefficient for the wind speed prediction for one hour ahead were 0.890 and 0.943, respectively. The statistical results show that the application of the ANN technique to predict the wind speed at the higher heights at the Bahia site has good accuracy and demonstrate its applicability as a powerful tool to help National Electrical System Operator (ONS) improve the usage and integration of wind energy into the national electrical grid.

Zucatelli et al. (2019d) studied the use of a supervised machine learning algorithm that applied the MLP, RNN, and wavelet decomposition techniques to representative time series data of the site to generate short-term wind speed predictions in the tropical region of Mucuri city, Bahia state, Brazil. To train the ANN and validate the technique (supervised machine learning), data for one month were collected by an anemometric tower at a height of 100 m. Different wavelet families and ANN configurations were applied for this site and height. Based on the results of the study cases, it can be concluded that the proposed method (RNN + discrete Meyer wavelet, or dmey, level 3) provided the best results for the short-term forecasting horizon.

In this context, the objective of this study is to identify the most efficient ANN configuration applying fully-connected RNN, gated recurrent unit (GRU), and long short-term memory (LSTM) with the Adam optimizer training algorithm for wind speed prediction 1 h ahead, and perform a comparison with MLP researched

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021

and developed in Zucatelli et al. (2019a). The Adam optimization algorithm is an extension to stochastic gradient descent (SGD) that has recently seen broader adoption in computer vision and natural language processing deep learning applications (Kingma et al., 2014). The algorithm has also been applied for 1 h to 12 h forecasts using anemometer data collected from a tower located in Colonia Eulacio, Soriano Department, Uruguay, which is used as a reference in this current study. Anemometers were installed at the heights of 10.0 m, 25.70 m, 81.80 m, 101.80 m between August 08, 2014, and August 07, 2015. There are no published reports in the literature for short-term 1 h to 12 h forecasts of the wind speed at four different anemometric heights in subtropical regions (south temperate zone), which include Uruguay, using and comparing the results of MLP (Zucatelli et al., 2019a), RNN, GRU, and LSTM. Thus, this study is a novel investigation relevant to the operation of wind energy plants in Uruguay. The main contributions of the study are as follows:

i) One innovative aspect of this work is that it uses an approach to train the model for next-hour forecasting and then recursively infers the forecast for the following hours by applying artificial intelligence methods targeting short-term wind speed forecasting for the specified heights using RNN, LSTM, and GRU.

ii) The proposed computational models based on AI by supervised machine learning elucidate the wind speed behavior and allow accurate wind speed prediction at different anemometric heights, e.g. 10.0 m, 25.70 m, 81.80 m, and 101.80 m. The model can be used to identify optimal locations for wind turbines and to predict irregular wind energy for different anemometric heights at different sites. Short-term wind energy prediction can be improved using this model to enhance the wind power quality 1 h to 12 h ahead.

iii) No previous research had applied the RNN, LSTM, and GRU ANNs and performed a comparison against a classical neural network (e.g. MLP) for shortterm wind speed prediction at the studied heights in Uruguay, which is a humid subtropical climate region. Thus, the results constitute a significant contribution to the scientific community.

iv) The short-term wind speed prediction model is an important contribution to reliable large-scale wind energy forecasting and integration in Uruguay, given the increased use of this energy source in this country.

The remainder of this paper is organized as follows: the methodology is presented in section 2. Section 3 presents the numerical results and discussions, and the conclusion is given in section 4.

2. Methodology

Artificial intelligence models (ANN models) by supervised machine learning using MLP with Levenberg-Marquardt Backpropagation, and fully-connected RNN, GRU, and LSTM with the Adam optimizer (Kingma et al., 2014) were adopted as the computational methods. A training algorithm was applied for short-term wind speed prediction 1 h to 12 h ahead at Colonia Eulacio, Soriano Department, Uruguay at the anemometer's heights of 10.0 m, 25.70 m, 81.80 m, and 101.80 m. The mean wind diurnal cycle in different seasons for this location was described in Lucas et al. (2016), which employed the same data for analysis as that used in the present study. ANN models are implemented through layers of interconnected nodes called neurons. The number of layers may vary depending on the characteristics of the problem. At least three layers are required: an input layer, a hidden layer, and an output layer (Russel & Norvig, 2010). A concise definition of the AI field, by Chollet (2018), would be as follows: "the effort to automate intellectual tasks normally performed by humans". Chollet (2018) explain that "a machine-learning system is trained rather than explicitly programmed. It's presented with many examples relevant to a task, and it finds statistical structure in these examples that eventually allows the system to come up with rules for automating the task". He defines that "deep learning is a specific subfield of machine learning: a new take on learning representations from data that puts an emphasis on learning successive layers of increasingly meaningful representations". For Chollet (2018), "the deep in deep learning isn't a reference to any kind of deeper understanding achieved by the approach; rather, it stands for this idea of successive layers of representations". Other definitions found in the literature, no less important, are highlighted in Figure 1. It shows an illustration of the relationship between computational or artificial intelligence, machine learning, and deep learning. Machine learning algorithms can be classified into different types as shown in Figure 2.

Computational or Artificial Intelligence: 1: deals with the simulation of intelligent behavior in computers. 2: an area of computer science that deals with giving machines the ability to seem like they have human intelligence.
Machine Learning: 1: learns useful representations from a given input set and defines rules to describe the data better. 2: the branch of computer science dealing with the creation and use of computer software that employs machine learning.
Deep Learning: 1: subset of machine learning that adds consecutive layers of representation to find even more useful information from the input data. 2: a subset of machine learning where artificial neural networks, algorithms inspired by the human brain, learn from large amounts of data.

Figure 1: Relationship between computational or artificial intelligence, machine learning, and deep learning.



Figure 2: Types of Machine Learning.

Validation (the checking or proving of the validity or accuracy of something) employs a set of anemometer data to calculate the error during training and for monitoring the fit level of the ANN to the training data.

Generalization is the ability of the network to respond correctly to conditions never experienced before, i.e., the test dataset. As described in Haykin (1999), there are different possibilities for structuring an ANN based on the choices made for

- i. the number of hidden layers,
- ii. the type of training,
- iii. the architecture configurations,
- iv. the type of neuron and transfer (activation) functions, and
- v. the number of input/output parameters.

To develop an ANN model, a set of input and output parameters are necessary. These sets are subdivided for use in the two different steps of network training and estimate validation. The correct selection of the predictors is crucial for the satisfactory performance of the model (Mori & Umezawa, 2009).

This work uses an approach to train the model for next-hour forecasting and then recursively infers the forecast for the following hours by applying artificial intelligence methods targeting short-term wind speed forecasting for the specified heights using AI. Figure 3 shows the supervised machine learning workflow.

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021



Figure 3: Supervised machine learning workflow.

The improvement of wind power technology has allowed the installation of turbines at high altitudes (100.0 m or higher), which requires knowledge of the wind potential at these heights. To validate the estimates and increase the number of wind farms installed in Uruguay, 100.80 m high anemometric towers were installed at locations with promising winds in Colonia Eulacio (Soriano is a department of Uruguay), which is the region considered in this study (Figure 4). According to Datum WGS84, the tower is located at 33°16' S, 57°31' W (Zucatelli et al., 2019a).

ISSN: 1690-4524



Figure 4: Colonia Eulacio Tower, Soriano department, Uruguay.

The measuring station used for this study is located in the southwestern region of Uruguay and consists of a 100.80 m high and 0.45 m wide triangular tower. The altitude of the installation location is approximately 100.0 m, and the location is surrounded by fields with plains. Thus, the location is characterized as a non-complex terrain. The station is owned by the *Administración Nacional de Usinas y Transmissiones Eléctricas*, or UTE. The UTE is a public energy sector company that works to make electric energy affordable in the country through the development of electricity generation, transmission, distribution, and commercialization well as the provision of advisory services and technical assistance in the areas of its specialty and annexes.

The computational intelligence procedure was coded and executed in Matlab together with Python by Google Colab, Google's free cloud service for artificial intelligence (AI) developers, and Keras, which follows best practices for reducing cognitive loads. Keras offers consistent and simple APIs, minimizes the number of user actions required for common use cases, and provides clear and actionable error messages. The MLP, RNN, GRU, and LSTM neural network configurations analyzed are listed in Table 1. In this study, the *fully connected* network structure was applied for RNN, GRU, and LSTM. The fully connected layers were defined using the Dense class.

ANN	Layers				
config.	Input node	1 st hidden	2 nd hidden	Output node	
		layer	layer	Output node	
Config. 1	7 neurons	9 neurons	-	1 neuron	
Config. 2	7 neurons	6 neurons	-	1 neuron	
Config. 3	7 neurons	3 neurons	-	1 neuron	
Config. 4	7 neurons	1 neuron	-	1 neuron	
Config. 5	7 neurons	9 neurons	6 neurons	1 neuron	
Config. 6	7 neurons	6 neurons	3 neurons	1 neuron	
Config. 7	7 neurons	1 neuron	1 neuron	1 neuron	

Table 1. ANN configurations (config.) analyzed.

Each training and forecast simulation took, on average, 3 seconds for MLP, 8 minutes for RNN, 16 minutes for GRU, and 18 minutes for LSTM on a personal computer with 8 GB RAM.

The inputs for each ANN are:

- i. hour,
- ii. day,
- iii. month,
- iv. year,
- v. average hourly values of the wind speed,
- vi. average hourly values of the wind direction, and
- vii. average hourly values of the temperature.

The insertion of these meteorological parameters as input data contributes to the efficient training and validation of each ANN. Some descriptive statistics for the wind speed at different heights are shown in Table 2.

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021

Height [m]	Hourly average speed [m/s]	Standard deviation [m/s]
101.80	7.21	3.00
81.80	6.81	2.74
25.70	4.98	2.21
10.0	4.01	2.08

Table 2. Wind speed: descriptive statistics.

The ANN output is the predicted wind speed for the next hour. In view of the total hours registered in the anemometer (1 year of recorded data = 8,760 hours), the data were separated into training, validation, and test datasets at a ratio of 35:35:30 for all the ANNs. Each of the aforementioned ANN configurations was trained, validated, and tested to determine which was the most efficient for short-term (1 h to 12 h) wind speed prediction.

The activation functions, which define the outputs of the neurons in terms of their activity levels, that were inserted in this simulation are the:

- Sigmoidal function, in the form of the hyperbolic tangent function (which is differentiable, nonlinear, continuous, and increasing), for the hidden layers in all configurations.
- ii. Linear function for the output layer in MLP.
- iii. Softplus activation function for the dense output layer in RNN, GRU, and LSTM. The Softplus is smooth and differentiable. Experiments show that deep neural networks with Softplus units achieve significant performance improvement.

To perform the forecasting, the ANN architecture that can achieve the best performance in the one-hour forecasting of the wind speed at each height (10.0 m, 25.70 m, 81.80 m, 101.80 m) is *first* identified. This forecasted wind speed value is then assigned as the input for the 2^{nd} hour of prediction, while the other input parameters (e.g. wind direction and air temperature) used at the start of the prediction are kept unchanged. The predicted wind speed for the 2^{nd} hour is calculated. This procedure, which is shown in Figure 5, is repeated until the *nth* hour of forecasting is reached.

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021

223





As the forecasting horizon increases, the quality of the forecasted wind speed is expected to decrease. This is evaluated and discussed in section 3.

3. Numerical Results and Discussions

In this work, the statistical indicators employed to analyze the results are the mean absolute error (*MAE*), mean squared error (*MSE*), root-mean-square error (*RMSE*), mean absolute percentage error (*MAPE*), coefficient of determination (R^2 or *R*-squared), factor of two (*Fac2*), and Pearson's correlation coefficient (r or Pearson's r) as defined in Equations 1 to 8 respectively. An explanation of these statistical indicators is provided in [10, 11].

$$e_t = o_t - f_t \tag{1}$$

$$MAE = \frac{1}{n} \sum_{t=1}^{n} |e_t| \tag{2}$$

$$MSE = \frac{1}{n} \sum_{t=1}^{n} e_t^2 \tag{3}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}e_t^2}$$
(4)

$$MAPE = \frac{1}{n} \sum_{t=1}^{n} \frac{|e_t|}{o_t} \times 100\%$$
(5)

$$R^{2} = \frac{\sum_{t=1}^{n} (f_{t} - \bar{o})^{2}}{\sum_{t=1}^{n} (o_{t} - \bar{o})^{2}}$$
(6)

$$r = \frac{\sum_{t=1}^{n} (o_t - \bar{o})(f_t - \bar{f})}{\sqrt{\sum_{t=1}^{n} (o_t - \bar{o})^2 \sum_{t=1}^{n} (f_t - \bar{f})^2}}$$
(7)

$$Fac2 =$$
fraction of data [%] for $0.50 \le \left(\frac{f_t}{o_t}\right) \le 2.0$ (8)

where t is the time, n the number of samples, e_t the error, o_t the observed value, f_t the forecasted value, \overline{o} the mean of all observed values, and \overline{f} the mean of all forecasted values.

When connected and trained in multiple layers, an ANN model can represent any nonlinear function (McGovern et al., 2017). One advantage of an ANN model is that it can learn the relationship between complex nonlinear inputs and outputs (Quan et at., 2013). The best ANN configurations in this work are presented in Table 3. The aforementioned ANN architectures that were identified as the most efficient for the 1-hour forecast for each height were applied in the computational simulation to predict the wind speed for 2 h to 12 h ahead in Colonia Eulacio at all the heights tested. The best MLP architecture was described in Zucatelli et al. (2019a).

ANN / heights	101.80 m	81.80 m	25.70 m	10.0 m		
AININ / Inerginis	Best ANN configurations					
MLP	7	4	7	4		
RNN	1	3	7	5		
GRU	7	6	6	5		
LSTM	6	5	1	1		

Table 3. The best ANN configurations.

The statistical results for the 1 h to 12 h wind speed prediction at a height of 101.80 m are presented in Table 4. The lowest values of the MAE, MSE, RMSE, and MAPE, as well as the highest Pearson's correlation coefficient and R² values, were recorded for the 1-hour forecast for all the analyzed heights (10.0 m, 25.70 m, 81.80 m, and 101.80 m). The mean R² and Pearson's r for the 1-hour wind speed forecasting are 0.843 and 0.918, respectively. The lowest MAPE value is 15.84% for the height of 101.80 m and prediction horizon of 1 hour.

The results showed in Table 4 indicate that as the wind speed prediction load increases, the quality of the ANN forecasting output data decreases. Thus, a longer prediction time yields a larger error. As explained in the previous section, these results are expected as the adopted procedure uses the input data from the start of the prediction in addition to the wind speed computed for each forecasted hour to predict the wind speed for the *nth* hour, leading to accumulated errors. This result is consistent with the literature, e.g. Zucatelli et al. (2019a); Zucatelli et al. (2019b); Kusiak et al. (2009); Blonbou (2011); Carpinone et al. (2015); Filik and Filik (2017). Figure 6 presents a graphical comparison of the RMSE [m/s] and Pearson coefficients for different ANN models at 101.80 m. The graph shows that as the prediction horizon [h] increases, the RMSE increases, indicating that the error between the actual and predicted values increases.

MLP					
Prediction Horizon [h]	1	3	6	9	12
MAE [m/s]	0.89	1.67	2.24	2.59	2.87
MSE [m ² /s ²]	1.40	4.68	7.95	10.3	12.38
RMSE [m/s]	1.18	2.16	2.82	3.22	3.51
Pearson	0.92	0.73	0.54	0.43	0.34
R ²	0.84	0.53	0.30	0.18	0.11
MAPE [%]	15.84	30.13	39.19	43.65	47.10
]	RNN			
Prediction Horizon [h]	1	3	6	9	12
MAE [m/s]	0.93	2.64	7.29	7.78	7.94
MSE [m ² /s ²]	1.53	9.77	60.99	68.97	71.43
RMSE [m/s]	1.23	3.12	7.81	8.30	8.45
Pearson	0.91	0.70	0.40	0.25	0.17
R ²	0.84	0.49	0.16	0.06	0.03
MAPE [%]	17.58	63.56	173.12	183.97	187.0
	(GRU			
Prediction Horizon [h]	1	3	6	9	12
MAE [m/s]	0.91	1.96	6.41	8.49	8.85
MSE [m ² /s ²]	1.45	5.92	47.56	80.69	87.04
RMSE [m/s]	1.20	2.43	6.89	8.98	9.33
Pearson	0.91	0.71	0.47	0.03	0.03
R ²	0.83	0.50	0.22	0.001	0.001
MAPE [%]	18.35	45.84	149.54	197.63	204.7
LSTM					
Prediction Horizon [h]	1	3	6	9	12
MAE [m/s]	0.89	3.45	5.85	6.08	6.13
MSE [m ² /s ²]	1.43	16.15	42.22	45.03	45.71
RMSE [m/s]	1.19	4.02	6.49	6.71	6.76
Pearson	0.91	0.63	0.13	0.10	0.09
R ²	0.84	0.39	0.01	0.01	0.01
MAPE [%]	17.33	88.09	146.65	151.25	152.4

Table 4. Performance indices of forecasting results obtained by different	
models on the case study for the height of 101.80 m.	

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021



Figure 6: Graphical comparison of a) the RMSE [m/s] and b) Pearson coefficient at different prediction horizons for different ANN models (height: 101.80 m).

Nowcasting refers to short lead-time weather forecasts. The U.S. National Weather Service specifies a lead-time of zero to three hours, although forecasts of up to six hours may also be called nowcasts by some agencies. Nowcasting is usually performed with techniques that differ significantly from the usual numerical weather prediction models (Kuikka, 2009; Zucatelli et al., 2019e). Figure 7 shows a comparison of the statistical results for the

root mean squared error [m/s] at different heights for the wind speed prediction at 6 h (which is important in nowcasting to short lead-time wind speed forecasting) using different ANNs. The best results were recorded for MLP followed by LSTM.



Figure 7: RMSE [m/s] for 6 h ahead using MLP, RNN, GRU, and LSTM at different heights.

Figure 8 shows the dispersion between the anemometer and predicted wind speed 6 h ahead using MLP (i.e. nowcasting). Figures 9 a), b), and c) present a comparison of the results for the 6 h ANN wind speed forecasted (nowcasting) through the MLP designed in Zucatelli et al. (2019a) with the actual data recorded at Colonia Eulacio at the anemometer height of 101.80 m. The ratio between the wind speed predicted by the ANN model and that measured by the anemometer is also plotted with respect to the time and the measured wind speed. The middle lines in the plots indicate one-to-one correspondence, and the outer lines indicate differences by a *factor of two (Fac2)*.

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021



Figure 8: Dispersion results for forecast 6 h ahead at 101.80 m.



229



Figure 9: Short-term wind speed prediction for 6 h ahead (nowcasting): a) The results of six-step predictions of the wind speed series [m/s]; b) Comparison of *Fac2* versus time [h], and c) Comparison of *Fac2* versus anemometer wind speed [m/s].

The degradation of the forecast can also be seen from the movement of the predicted curve away from the actual curve as the forecast horizon increases. Table 5 presents the percentage of the predicted wind speeds that match the actual

wind speed within a factor of two. The MLP and LSTM models are the only models that maintained results within the *factor of two* (i.e *Fac2*) above 58% of the forecasts.

AND model	Deadiction having	Percentage of the forecasts within a		
AININ IIIOdei	Prediction nonzon	factor of two, Fac2		
	1 h	98.44%		
	3 h	93.29%		
MLP	6 h	88.29%		
	9 h	82.43%		
	12 h	77.44%		
	1 h	98.21%		
	3 h	84.64%		
RNN	6 h	50.67%		
	9 h	47.90%		
	12 h	46.69%		
	1 h	97.79%		
	3 h	93.71%		
GPU	6 h	56.92%		
GRU	9 h	43.58%		
	12 h	40.69%		
	1 h	98.29%		
	3 h	76.94%		
LSTM	6 h	60.70%		
	9 h	59.05%		
	12 h	58.39%		

Table 5. Percentage of the forecasts within a factor of two (heigh	t: 101.80
m).	

The results in Figure 10 indicate that on average, the MLP ANN has better results than the persistence model for a prediction horizon of 1 h.



Figure 10: Comparison between the ANN models and the persistence reference model for wind speed forecasting 1 h ahead.

The investigation of mechanisms that aid the short-term wind speed forecasting for 1 h to 12 h ahead as performed in this study for energy generation in wind farms has been critical for ensuring the proper functioning of traditional energy systems. Accurate prediction of the short-term wind speed output helps system operators to

- i. reduce the operational costs of the power system,
- ii. mitigate the adverse effects of wind power fluctuations,
- iii. adjust scheduling plans in a timely manner,
- iv. make correct decisions, and
- v. reduce standby capacity.

Wind energy has become a major source of electricity supply in Uruguay and around the world. The large contribution of wind energy to the reliable operation of the electric power network today makes the application of supervised machine learning AI to wind speed forecasting very important. Wind energy has characteristics that differ from electricity generation powered by coal, petroleum, nuclear, and natural gas. Because wind generation is driven by

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021

meteorological processes, it is intrinsically variable and has real-time fluctuations on the time scale ranging from minute-to-minute fluctuations to yearly variations affecting long-term planning for utility operations. These characteristics can require changes in system operational practices and the potential addition of flexibility reserves to help manage increased variability and uncertainty from wind energy.

4. Conclusions

The application of computational intelligence (supervised machine learning) is a viable alternative for the forecasting of wind speed and thus wind energy generation mainly because of the low computational cost. However, an ANN configuration that is appropriate for the forecasting must be selected, and the data fed to the model must be quantitatively and qualitatively analyzed because these variables directly impact the prediction results. This research is relevant because it is a first step in the application of the MLP, RNN, GRU, and LSTM models to wind speed forecasting. There have been no previous studies on the application of computational intelligence using supervised machine learning and deep learning through such ANNs for this region.

The statistical results for the prediction horizons of 1 h to 12 h for each anemometric height exhibit predictable behavior similar to that for short time ranges. These results are novel because no other studies have used these computational models to predict the wind speed in Uruguay. The MLP and LSTM models are adequate for wind speed forecasting at different heights. From the analysis, it was found that the MLP model is superior to the other neural network models because it can achieve a relatively lower prediction error. The MLP approach introduced here uses a differentiated process of forecasting based on inference.

The surprising result is that the simplest model architecture of a MLP (using the Levenberg–Marquardt algorithm, also known as the damped least-squares method) with only two hidden layers containing one neuron in each layer gives the best performance among the considered architectures. This result suggests that deeper neural network architectures (deep learning), ensemble other models, may achieve higher performance. The 1 h to 6 h forecasts are particularly

accurate (i.e. nowcasting). As the forecast time increased, the accuracy of the results decreased, as expected. However, this degradation does not render the forecasting results for longer prediction horizons useless. The proposed technique can still produce satisfactory short-term wind speed forecasts of up to 12 h with low computational costs to help wind-farm operators with decision making.

This study contributes to the scientific community considering the interest of private companies and UTE in the energy sector by providing wind speed prediction information for Uruguay. Future work can study the application of wavelets decomposition to weather data and deep learning technology (LSTM, GRU, and CNN or convolutional neural networks) for wind speed and wind power forecasting. Wind ramps and longer forecasting horizons are also future subjects for research.

Acknowledgments

The study is fully supported by the SENAI Cimatec of University Center, in Bahia, Brazil. We want to thank the SENAI Cimatec, its Reference Center on Artificial Intelligence and its Supercomputer Center for Industrial Innovation (CS2i). We also want to thank the Administración Nacional de Usinas y Trasmisiones Eléctricas (UTE) of Uruguay.

References

Blonbou, R. (2011). Very short-term wind power forecasting with neural networks and adaptive Bayesian learning. Renewable Energy, 36(3), 1118–1124. https://doi.org/10.1016/j.renene.2010.08.026

Carpinone, A., Giorgio, M., Langella, R., & Testa, A. (2015). Markov chain modeling for very-shortterm wind power forecasting. Electric Power Systems Research, 122, 152–158. https://doi.org/10.1016/j.epsr.2014.12.025

Cheng, W. Y. Y., Liu, Y., Bourgeois, A. J., Wu, Y., & Haupt, S. E. (2017). Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation. Renewable Energy, 107, 340–351. https://doi.org/10.1016/j.renene.2017.02.014

Chollet, F. (2018). Deep Learning with Python. (1st ed.). Manning Publications Co. http://faculty.neu.edu.cn/yury/AAI/Textbook/Deep%20Learning%20with%20Python.pdf

Filik, Ü., & Filik, T. (2017). Wind Speed Prediction Using Artificial Neural Networks Based on Multiple

234

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021

Local Measurements in Eskisehir. 3rd International Conference on Energy and Environment Research, ICEER 2016, 7-11 September 2016, Barcelona, Spain Energy Procedia, 107, 264–269. https://doi.org/10.1016/j.egypro.2016.12.147

Haykin, S. (1999). Neural Networks: A Comprehensive Foundation (2nd ed.). Pearson Education Inc. Hamilton, Ontario, Canada, 823p.

Huang, C., Li, F., & Jin, Z. (2015). Maximum Power Point Tracking Strategy for Large-Scale Wind Generation Systems Considering Wind Turbine Dynamics. IEEE Transactions on Industrial Electronics, 62(4), 2530–2539. https://doi.org/10.1109/TIE.2015.2395384

Jiang, P., Wang, Y., & Wang, J. (2016). Short-term wind speed forecasting using a hybrid model. Energy, 119, 561–577. http://dx.doi.org/10.1016/j.energy.2016.10.040

Kingma, D. P., & Ba, J. L. (2014). Adam: A method for stochastic optimization. [Conference presentation]. Published as a conference paper at the 3rd International Conference for Learning Representations, San Diego. https://arxiv.org/abs/1412.6980

Kuikka, I. (2009). Wind Nowcasting: Optimizing Runway in Use; Technical Report; Helsinki University of Technology Systems Analysis Laboratory: Espoo, Finland.

Kusiak, A., Zheng, H., & Song, Z. (2009). Short-term prediction of wind farm power: a data mining approach. IEEE Transactions on Energy Conversion, 24 (1), 125–136. https://doi.org/10.1109/TEC.2008.2006552

Lia, C., Xiao, Z., Xia, X., Zou, W., & Zhang, C. (2018). A hybrid model based on synchronous optimisation for multi-step short-term wind speed forecasting. Applied Energy, 215, 131–144. https://doi.org/10.1016/j.apenergy.2018.01.094

Liu, H., Mi, X., & Li, Y. (2018). Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short-term memory neural network and Elman neural network. Energy Conversion and Management, 156, 498–514. https://doi.org/10.1016/j.enconman.2017.11.053

Lucas, E. A., Arce, A. M. G., Moraes, M. R., Boezio, G. C., & Ottieri, J. C. (2016). Statistical description of diurnal cycle of wind profile in the first 100 meters of height of the Planetary Boundary Layer, in Colonia Eulacio Uruguay. [Conference presentation]. Ciência e Natura, 38, ed. Especial – IX Brazilian Micrometeorology Workshop, 426–434. http://dx.doi.org/10.5902/2179460X20308

McGovern, A., Elmore, K. L., Gagne II, D. J., Haupt, S. E., Karstens, C. D., Lagerquist, R., Smith, T., & Willians, J. K. (2017). Using Artificial Intelligence to Improve Real-Time Decision-Making for High-Impact Weather. American Meteorological Society, 98(10), 2073–2090. https://doi.org/10.1175/BAMS-D-16-0123.1

Mori, H., & Umezawa, Y. (2009). Application of NBTree to Selection of Meteorological Variables in Wind Speed Prediction. [Conference presentation]. Transmission & Distribution Conference & Exposition: Asia and Pacific, Seoul, Korea. https://doi.org/10.1109/TD-ASIA.2009.5356831

Peng, H., Liu, F., & Yang, X. (2013). A hybrid strategy of short term wind power prediction. Renewable Energy, 50, 590-595. DOI: https://doi.org/10.1016/j.renene.2012.07.022

Quan, D. M., Ogliari, E., Grimaccia, F., Leva, S., & Mussetta, M. (2013). Hybrid Model for Hourly Forecast of Photovoltaic and Wind Power. [Conference presentation]. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE). Hyderabad, India. https://doi.org/10.1109/FUZZ-IEEE.2013.6622453

REN21. (2020). Renewables 2020 Global Status Report (Paris: REN21 Secretariat). ISBN 978-3-

948393-00-7. https://www.ren21.net/reports/global-statusreport/?gclid=CjwKCAjw88v3BRBFEiwApwLevXhcmpLVjwsXuIdI49YJHJ-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE

Russel, S., & Norvig, P. (2010). Artificial Intelligence: A Modern Approach. Stuart J. Russell and Peter Norvig. Third Edition. Pearson Education, Inc., 1153p.

Watts, J. (2015). Uruguay makes dramatic shift to nearly 95% electricity from clean energy: Keep it in the ground Renewable energy. https://www.theguardian.com/environment/2015/dec/03/uruguay-makes-dramatic-shift-to-nearly-95-clean-energy

Zhang, J., Wei, Y., Tan, Z., Wang, K., & Tian, W. (2017). A Hybrid Method for Short-TermWind Speed Forecasting. Sustainability, 9, 596. https://doi.org/10.3390/su9040596

Zucatelli, P. J., Nascimento, E. G. S., Aylas, G. Y. R., Souza, N. B. P., Kitagawa, Y. K. L., Santos, A. A. B., Arce, A. M. G., & Moreira, D. M. (2019a). Short-term wind speed forecasting in Uruguay using computational intelligence. Heliyon, 5(5), e01664. https://doi.org/10.1016/j.heliyon.2019.e01664

Zucatelli, P. J., Nascimento, E. G. S., Santos, A. A. B., Arce, A. M. G., & Moreira, D. M. (2019b). Study of the Wind Speed Forecasting Applying Computational Intelligence [Online First], IntechOpen, 10.5772/intechopen.89758. https://www.intechopen.com/online-first/study-of-the-wind-speedforecasting-applying-computational-intelligence

Zucatelli, P. J., Nascimento, E. G. S., Aylas, G. Y. R., Souza, N. B. P., Kitagawa, Y. K. L., Santos, A. A. B., & Moreira, D. M. (2019c). Short-term wind speed forecasting using computational intelligence in Bahia, Brazil. [Conference presentation]. Proceedings of the Air Pollution Conference Brazil and 4th CMAS South America, Extended Abstract. Belo Horizonte, Brazil.

Zucatelli, P. J., Nascimento, E. G. S., Campos, L. R., Santos, A. A. B., & Moreira, D. M. (2019d). Shortterm wind speed forecasting in tropical region using Wavelets and Artificial Intelligence. [Conference presentation]. Proceedings of the International Symposium on Innovation and Technology (SIINTEC). Complete Articles. Salvador, Brazil. https://www.proceedings.blucher.com.br/article-details/previso-davelocidade-do-vento-a-curto-prazo-em-regio-tropical-utilizando-wavelets-e-inteligncia-artificial-33286. DOI: 10.5151/siintec2019-46

Zucatelli, P. J., Nascimento, E. G. S., Arce, A. M. G., & Moreira, D. M. (2019e). Short-Range Wind Speed Predictions in Subtropical Region Using Artificial Intelligence. Journal of Systemics, Cybernetics and Informatics, 17(4). ISSN: 1690-4524. http://www.iiisci.org/journal/sci/Abstracts.asp?var=&previous=ISS1904

236

SYSTEMICS, CYBERNETICS AND INFORMATICS VOLUME 19 - NUMBER 1 - YEAR 2021

6.4 Artigo 4: Nowcasting prediction of wind speed using computational intelligence and Wavelet in Brazil

O artigo "Nowcasting prediction of wind speed using computational intelligence and Wavelet in Brazil" foi publicado online em 02/11/2020 no International Journal for Computational Methods in Engineering Science & Mechanics, Volume 21, 2020 – Issue 6, (DOI: https://doi.org/10.1080/15502287.2020.1841335). Por meio desta pesquisa foi desenvolvido uma metodologia de análise estatística descritiva das funções Wavelets com o objetivo de averiguar qual função Wavelet mãe é a mais eficiente para a filtragem passa baixa e passa alta da velocidade do vento. Para a decomposição de todas as séries temporais da velocidade do vento registrados na região tropical (sítios da Bahia) a função Wavelet discreta Meyer (dmey) se mostrou mais eficaz seguindo a metodologia proposta, satisfazendo assim o que foi publicado de forma empírica previamente por este autor no Brasil e por pesquisadores na China. O estudo aplicou o método híbrido (inteligência computacional e decomposição Wavelets) para prever a velocidade do vento nos três sítios da Bahia usando dados anemométricos medidos em 100 m, 120 m e 150 m. Os resultados contribuíram com a comunidade científica diante da metodologia adequada de análise antes da aplicação do sistema híbrido de previsão.

Taylor & Francis



International Journal for Computational Methods in Engineering Science and Mechanics

ISSN: (Print) (Online) Journal homepage: https://www.tandfonline.com/loi/ucme20

Nowcasting prediction of wind speed using computational intelligence and wavelet in Brazil

Pedro Junior Zucatelli , Erick Giovani Sperandio Nascimento , Alex Álisson Bandeira Santos & Davidson Martins Moreira

To cite this article: Pedro Junior Zucatelli, Erick Giovani Sperandio Nascimento, Alex Álisson Bandeira Santos & Davidson Martins Moreira (2020): Nowcasting prediction of wind speed using computational intelligence and wavelet in Brazil, International Journal for Computational Methods in Engineering Science and Mechanics, DOI: <u>10.1080/15502287.2020.1841335</u>

To link to this article: https://doi.org/10.1080/15502287.2020.1841335

Published online: 02 Nov 2020.

🖉 Submit your article to this journal 🗹

Article views: 13

Q View related articles

🕕 View Crossmark data 🗹

Full Terms & Conditions of access and use can be found at https://www.tandfonline.com/action/journalInformation?journalCode=ucme20 INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS https://doi.org/10.1080/15502287.2020.1841335 Taylor & Francis Taylor & Francis Group

(Check for updates

Nowcasting prediction of wind speed using computational intelligence and wavelet in Brazil

Pedro Junior Zucatelli^a (0), Erick Giovani Sperandio Nascimento^b (0), Alex Álisson Bandeira Santos^b (0), and Davidson Martins Moreira^{a,b} (0)

^aTechnological Center, Federal University of Espírito Santo – UFES, Vitória, Brazil; ^bManufacturing and Technology Integrated Campus, SENAI CIMATEC, Salvador, Brazil

ABSTRACT

This work presents a novel investigation on the nowcasting prediction of wind speed for three sites in Bahia, Brazil. For this, it was applied the computational intelligence by supervised machine learning using different artificial neural network technique, which was trained, validated, and tested using time series are derived from measurements that are acquired in towers equipped with anemometers at heights of 100.0, 120.0 and 150.0 m. To define the most efficient ANN, different topologies were tested using MLP and RNN, applying Wavelet packet decomposition (bior, coif, db, dmey, rbior, sym). The best statistical analysis was RNN + discrete Meyer wavelet.

HIGHLIGHTS

- A new methodology for improving forecast accuracy of wind speed using artificial neural network (ANN) and Wavelet packet decomposition.
- . Using machine learning and Wavelet packet decomposition to nowcast wind speed (m/s).
- To predict the wind speed at 100.0 m, 120.0 m and 150.0 m height in tropical region.
- Performance evaluation of Wavelet packet decomposition applying 48 different mother Wavelet functions.
- ANN approach for the estimation of nine types of wind speed time series.
- The proposed hybrid model (ANN+Wavelet packet decomposition) is capable of wind speed forecasting efficiently.

1. Introduction

Technological development regarding renewable energy sources with the ultimate goal of reducing environmental pollution is an issue that deserves attention, mainly due to air pollution from high emissions of greenhouse gases into the atmosphere in several nations, which is an issue that has received a global alert. The consequences of global warming are diverse and complex and can cause irreversible damage to humanity. One of the most notable consequences is the melting of the glaciers. The melting of the glaciers generates environmental and social upheavals. This phenomenon alters the temperature of the oceans, causing an environmental imbalance and affecting mainly marine species. Other consequences of global warming are desertification, alteration of the rain regime, intensification of droughts in certain places, water scarcity, an abundance of rain in some

locations, storms, hurricanes, floods, changes in ecosystems, reduction of biodiversity, loss of areas fertile for agriculture.

A renewable energy source means sustainable energy – something that can't run out, or is endless, like the wind [1]. The wind is a plentiful source of energy. Featuring a growing alternative energy source in the global market, wind power has shown rapid development in the past ten years, from 2010 to 2020 [2, 3]. Wind energy shows significant participation in the energy commercialization market and is expected to show exponential growth in the coming years, from 2020 to 2030 [4]. The energy transition can be noticed in the social consciousness globally and in the policies, most countries are adopting, when outlining their energy strategies, e.g. in Brazil and Uruguay. The hybrid models combined with different single models will be an effective way to improve the wind speed

CONTACT Pedro Junior Zucatelli 😡 pedrojrzucatelli@gmail.com 🕤 Technological Center, Federal University of Espírito Santo – UFES, Vitória, Brazil. © 2020 Taylor & Francis Group, LLC

KEYWORDS

Computational methods; computer science; engineering science and mechanics; machine learning; sustainable energy; wind power

2 🐵 P. J. ZUCATELLI ET AL.

prediction accuracy, agreement of a particular measurement with an accepted standard [5–9].

In meteorology, it is known that the wind results from the movement of the air due to pressure gradients in the atmosphere. The wind flows from the high-pressure regions to the low-pressure regions. The greater the pressure gradient in the atmosphere, the greater the wind speed and, therefore, the greater the wind energy that can be captured by the wind using wind energy conversion machines: wind turbines. Records say that wind speed is the most critical feature of wind power generation. Wind generation and movement are complex due to several physical factors. Among them, the most important factors are the uneven solar heating on the Earth's surface, the Coriolis effect due to the Earth's autorotation, and local geographic conditions. Since wind speed is a random parameter, measured wind speed data is usually treated using statistical methods [10].

A single model is hard to satisfy the accuracy requirement due to the complex characteristics of wind speed. Modern-day grid reliability and security are highly dependent on accurate wind speed and power forecasts. Whereas the nonlinear nature of wind poses challenges in forecasting via traditional methods, supervised machine learning-based hybrid models adequately address this issue. Nowcasting refers to short lead-time weather forecasts. The World Meteorological Organization (WMO) specifies 0h to 6 h ahead. Nowcasting is usually applied with techniques that differ significantly from normal numerical weather prediction models. In this time range, it is possible to forecast small features such as individual storms with reasonable accuracy [11]. In Brazil, the electric energy trading chamber (CCEE) acts like an operator in the Brazilian electric energy market, aimed at enabling a competitive, sustainable, and safe trading environment. The CCEE promotes discussions and proposes solutions for the development of the national electric sector, making the dialogue between the agents and the instances of formulation of policies and regulation. The institution's focus is on the evolution of the commercialization segment, based on neutrality, liquidity, and symmetry of information. Accounting involves the calculation of the difference between the energy measured and that contracted by an agent, valued at the difference settlement price (PLD) for financial settlement at CCEE. This step is performed based on the marketing rules, taking into account the short-term market exposures, the receipt/ payment of system service charges (ESS), the energy reallocation mechanism (MRE) and the consolidation

of results to be settled, including any financial adjustments.

Signal processing techniques have been used in tandem with machine learning methods to improve the forecast accuracy and eliminate the stochastic variations in the time-series. Signal transforms like the Fourier transform, Wavelet transform, and Wavelet packet decomposition are the common algorithms used. A major drawback of using the Fourier transform in wind speed decomposition is the loss of information concerning the time scale, which is overcome by the Wavelet transform. The Wavelet transform captures information of a signal in both time and frequency scales. Since temporal variations hold greater importance in wind speed time-series analysis, the Fourier transform is not preferred [12].

Works such as [13-18] showed results of numerical simulation, and mathematical modeling for short-term wind speed forecasting with artificial intelligence (AI) techniques, especially using multilayer perceptron (MLP) with feedforward and Levenberg-Marquardt backpropagation training algorithm, all with good results achieved, and low associated errors. Wind power prediction is important for the reliability of the electrical system and can help the planning for wind farms. Brazil is ranked 7th in the world ranking of wind energy installed capacity, and Bahia is ranked 2nd in the Brazilian ranking of wind energy installed capacity (Figure 1). It is worth mentioning that 80% of Brazilian wind farms are in the Northeast, a region that has one of the best winds in the world for producing wind energy. The favorable winds for producing wind energy are more constant, have a stable speed, and do not change direction frequently [19].

The research presented by Zucatelli et al. [16, 17] showed a computation simulation about the shortterm wind speed prediction in the tropical region of Mucuri city, Bahia state, Brazil (humid tropical region), using AI by supervised machine learning technique (with neural network architectures) to the hourly time series representative of the site. The authors used MLP, recurrent neural network (RNN) and Wavelets decomposition with Levenberg-Marquardt Backpropagation training algorithm to predict the wind speed for 1 h ahead, and then apply it for 2 h to 12 h ahead.

The study referenced by Zucatelli et al. [14, 18] shows that the short-term wind speed prediction (1 h to 12 h) for Soriano Department (Mercedes is the capital and largest city of the department of Soriano), humid subtropical region in Uruguay, is performed by applying computational intelligence by supervised



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS 😡 3

Figure 1. Capacity installed and the number of wind farms in 2020 in Brazilians sites (adapted from [19]).

machine learning by artificial neural network (ANN) technique using anemometer data. The ANN was trained to perform the forecasting of 1 h ahead, and then, using it, the trained network was applied to recursively infer the forecasting for the next hours of the wind speed, the computational complexity is smaller than if it were necessary to train to predict the next 6 h for each input/sample of anemometric data, for example. Different ANN architectures to MLP, RNN, gated recurrent units (GRU), and long short-term memory (LSTM), a deep learning algorithm-based method, are applied for each height (10.0 m, 25.70 m, 81.80 m, and 101.80 m). The statistical results show that the neural networks based on the MLP and LSTM model had the best accuracy when comparing the measured results and the predicted results, in addition to showing more accurate predicted results.

Zucatelli et al. [15] present the nowcasting prediction of wind speed to 6 h ahead, applying AI by supervised machine learning, using MLP and comparing with RNN, and anemometers data collected by an anemometric tower at a height of 100.0 m in Brazil (tropical region) and 101.80 m in Uruguay (subtropical region), both countries located in South America. The proposed method is benchmarked against other computational methods published in the literature and proved to be precise and accurate.

Therefore, this research is a novel investigation that contributes directly to the operation of wind energy plants for Mucuri, Mucugê, and Esplanada, Bahia, Brazil, with time series of wind derived from measurements that are acquired in three towers equipped with anemometers at heights of 100.0 m, 120.0 m, and 150.0 m. The main contributions of this work can be summarized as follows:

- Nowadays, the application of Wavelet decomposa. ition in weather signals to predict wind speed has been studying in empirical research. Accurate analysis of data is critical to determining the validity of empirical research. The empirical results achieved are promising for the renewable energy market, in this case, wind power, and this is because wind forecasting is important to ensure efficient risk management in wind farms. Nevertheless, there is no scientific methodology for choosing the best Wavelet functions to be applied to temporal wind signals. Therefore, a novel methodology for knowledge discovery is showed using different Wavelet families (48 different mother Wavelet functions), a comparison of Wavelet transform is presented, and different artificial neural network configurations were applied using wind data.
- b. The proposed model in this paper elucidates the behavior of the wind speed and allows accurate wind speed prediction at three important heights e.g. 100.0 m, 120.0 m, and 150.0 m, and at three important sites i.e. Esplanada, Mucugê, and

4 🕢 P. J. ZUCATELIJ ET AL.

Mucuri (Bahia, Brazil). Short-term wind power prediction can be improved using this computational model to enhance the wind energy quality 6 h ahead (nowcasting). Then a new evaluation of Wavelet families by wind time series decomposition is presented. In this study, the matching relationship between the original wind signal and 48 different mother Wavelet functions was discussed to determine the most suitable mother Wavelet function for the hybrid model.

- c. Research on wind energy forecasting usually focuses on forecast methods, where the design of the input vector is based on anemometer data collected at 10.0 m. The need to use physical equations (i.e. logarithmic profile or power/log law) to calculate the wind at heights greater than 10.0 m adds errors in wind speed and wind direction predictions. Therefore, this study used meteorological measurements measured at 100.0 m, 120.0 m, and 150.0 m to ANN input (training, validation, and test sets). This is important due to the real hub height of the wind turbines in wind farms. The closer the anemometer is placed to the eventual height of the wind turbine hub (e.g. 100.0 m, 120.0 m, and 150.0 m), the more accurately it measures the meteorological variables to which the wind turbine is exposed.
- d. No previous papers applied artificial intelligence by supervised machine learning and Wavelet decomposition for short-term wind speed prediction for these heights in such a humid tropical climate region (Bahia: 2nd in the Brazilian ranking of wind energy installed capacity). It uses an approach to train the model for the next hour forecasting, then recursively inferring the forecasting for the following hours, in addition to applying this AI method targeting short-range wind speed forecasting for these heights in a tropical region. Therefore, the results constitute a significant contribution to the Brazilian electricity market and to neighboring countries, such as Uruguay, which has great wind potential.
- e. In terms of wind potential, there is a wide variety of wind regimes, i.e. the southern region and the northeast of Brazil. In the southern region, the variability of wind is greater because this region suffers an influence of cold fronts. However, in this region, this difficulty is counterbalanced by greater scientific knowledge and a greater number of measurement systems. In contrast, in the northeast, the climate is tropical, where there are huge gaps in scientific knowledge of wind

behavior in the region and relatively lacking measurement systems. In this sense, the fact that trade winds develop on oceans, impose the need to use wind profiles derived from remote sensing of satellites, in addition to the challenges of complex terrain and coastal regions. These are considered the main scientific frontiers in wind predictability.

The remaining sections of the article are organized as follows: Section 2 describes the methodology, shows the study region, and the data used in this work and provides details of the computational framework used in the computational model, Section 3 presents and discusses obtained results, and Section 4 presents the conclusions of the research, and some suggestions for the future works and studies.

2. Methodology

This methodological section presents the anemometers data of the study regions, as well as on the computational model used to wind speed forecasting. The accuracy measures are presented to identify the quality of the adjustments produced by the models. To reach the objective of the present work was adopted the computational intelligence model by supervised machine learning and Wavelet packet decomposition. This computational method is called supervised machine learning (Figure 2) because the process of an algorithm learning from the training dataset can be thought of as an expert supervising the learning process. It knows the correct answers, the algorithm iteratively makes forecasts on the training data and is corrected by the expert. When the computational algorithm achieves an acceptable level of performance, the machine learning stops.

At this point, it is important to mention that the Bahia state is consolidating the position of the largest Brazilian pole of investments in wind energy, as well as becoming an international reference in this area. Numerous investments have been made by new companies, generating job opportunities and income for the population, including a positive impact in needy regions. A new production chain, focused on wind energy, was successfully implemented in the state and continues to expand, boosting the economy as a whole. Wind energy has become a good alternative to diversification and expansion of the Brazilian electric matrix [20]. It should be noted that the advancement of technology in wind energy has allowed the installation of turbines at high levels, requiring knowledge of





Figure 2. Schematic diagram of the supervised learning.

the wind potential at ever greater heights. To validate the estimates and disseminate the installation of wind farms in the state of Bahia, four anemometric towers of 150.0 m height were installed in locations with promising winds, in the cities of Esplanada, Mucugê, Mucuri, and Casa Nova. The anemometric towers installed in Esplanada, Mucugê, and Mucuri are the most important, their anemometric data recorded well represent the climatic diversity of the state of Bahia, and, therefore, contemplate this case study.

The Esplanada city is located in the microregion of the north coast of Bahia with an altitude of 140.0 m concerning the sea level and it has a territorial area of 1,299.35 km², approximately. Its characteristic biome is the Atlantic Forest. The Esplanada's anemometric tower is 40.0 km from the sea, with latitude 11°47'45" S, and longitude 37°56'42" W. The Mucugê city is at an altitude of 984.0 m concerning the sea level and is one of the municipalities belonging to Chapada Diamantina, the central region of the state of Bahia, characterized by being a mountainous region and it has a territorial area of 2,462.15 km², approximately. Its characteristic biome is the caatinga. The anemometric tower of Mucugê has located approximately 280.0 km from the Bahia coast, with a latitude of 13°00'18" S, and longitude of 41°22'15" W. The Mucuri city is located at an altitude of 7.0 m concerning the sea level and it has a territorial area of 1,787.62 km², approximately. Its characteristic biome

is the Atlantic Forest. The Mucuri's anemometer tower is located in a coastal plain, at a distance of 340.0 m from the sea, with latitude 18°05'09" S, and longitude 39°33'03" W (see Figure 3), south region of Bahia. The data observed at intervals of 20 in 20 seconds were converted to hourly values, being realized the means of the original measures measured in 1 hour (60 min).

The time series used in the models consists of 744 records in total (100%), corresponding to hourly mean data for each of the period between April 28, 2016, until May 29, 2016 (site: Esplanada), September 07, 2016, until October 07, 2016 (site: Mucugê), and November 30, 2015, until December 31, 2015 (site: Mucuri), see Figures 4–6. The wind database that will be used in this study is characterized by data on speed, direction, temperature, relative humidity, and barometric pressure.

The frequencies distributions of wind speed data are shown in Figures 7–9, and a descriptive statistic regarding wind speed at different sites is shown in Table 1.

The Weibull distribution is important, especially for reliability and maintainability analysis. The probability density function f(v) is given by the following Equation (1):

$$f(v) = \frac{k}{c} \left(\frac{v}{c}\right)^{k-1} \cdot e^{\left[-\binom{n}{c}\right]^{k}}$$
(1)

where $\nu =$ is the wind speed [m/s]; k = is the Weibull shape factor [unitless]; c = is the Weibull scale parameter [m/s]. In this work, to determine the shape (k) and scale (c) parameters of the Weibull probability density function did apply Justus Empirical Method following Lysen equations, i.e. $k = (\sigma/\overline{\nu})^{-1.086}$ and $c = [\overline{\nu}(0.568 + 0.433/k) - 1/k]$ where σ is the standard deviation [m/s] and $\overline{\nu}$ is the mean wind speed [m/s].

The training set with 550 recorded hours (average hourly values of the wind speed [m/s], wind direction [°], air temperature [°C], air humidity [%], and air pressure [Bar]) was used for the models' training (44.35%), and validation (29.57%). The prediction set

- Esplanada: 05/21/2016 at 7:00 a.m. until 05/29/ 2016 at 8:00 a.m.,
- Mucugê: 09/29/2016 at 10:00 p.m. until 10/07/2016 at 11:00 p.m., and
- Mucuri: 12/23/2015 at 12:00 p.m. until 12/31/2015 at 1:00 p.m.

consisting of 194 data (26.08%) was used to verify their accuracy during the prediction stage. The software used to program and perform this computational 6 🕢 P. J. ZUCATELLI ET AL.



Figure 3. Location of Esplanada, Mucuge and Mucuri Towers in Bahia, Brazil.

procedure was Matlab, the core configuration of the personal computer includes Intel Core i7-7500U processors running at 2.90 GHz, and a 64-bit system with 8 GB of RAM, and the proposed ANN architectures to be analyzed are the following ones (see Table 2).

The ANN architecture depends on the number of input features being analyzed. In architecture 1, the input features are day, month, year, hour, and important meteorological parameters: wind speed [m/s], wind direction [°], air temperature [°C], air humidity [%], and air pressure [Bar]; in architecture 2, the value depends on the Wavelet level applied to wind speed decomposition.

Haykin [21] explain that a neuron is an information-processing unit that is fundamental to the operation of a neural network. In mathematical terms, in this paper we may describe a neuron k by writing the following pair of equations:

$$u_k = \sum_{j=1}^m w_{kj} x_j \tag{2}$$

$$y_k = \varphi(u_k + b_k) \tag{3}$$

where $x_{1}, x_{2}, ..., x_{m}$ are the input signals; $w_{k1}, w_{k2}, ..., w_{kn}$ are the synaptic weights of neuron k; u_{k} is the linear combiner output due to the input signals; b_{k} is the bias; $\varphi(\bullet)$ is the activation function, and y_{k} is the output signal of neuron.

A MLP (Figure 10) is an ANN composed of more than one perceptron. They are composed of an input layer to receive the signal, an output layer that makes a decision or prediction about the input, and between these two, an arbitrary number of hidden layers that are the true computational mechanism of MLP. Multilayer perceptron with a hidden layer can approximate any continuous function. Recurrent networks (Figure 11), on the other hand, take as input not only the example of the current entry it sees but also what it perceived earlier in time. The decision of a recurring network reached in time step t-1 affects the decision that will reach a moment later in time step t. Thus, RNN has two sources of input, the present, and the recent past, which combine to

and



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS 🛞 7

Figure 4. Wind speed anemometer data, site: Esplanada 100.0 m (a), 120.0 m (b), and 150.0 m (c).

determine how they respond to new data, according to Haykin [21].

After collecting the anemometric data at each site, the data is preprocessed to ascertain, for example, the presence of not a number (or nan) and to transform the records into hourly averages. The discrete Wavelet transform using different families is then applied to the selected data set. The high-pass filter results in the detailed coefficients and the low-pass filter results in the approximate coefficients. For these anemometers' signals, the low-frequency content is the most important part, because it is what gives the signal its identity. Thus, the objective is to compare the performance of the approximate coefficients with the original signal to ascertain the maintenance of the energy of the decomposed signal. With the results of this comparison, the most efficient family of Wavelets in this process is evaluated and chosen. After this step, the technology for predicting the approximate and detailed coefficients is applied using supervised machine learning using artificial neural networks. After predicting these

coefficients, the wind speed signal needs to be reconstructed, so that it can be compared with the original signal. The aim is to evaluate the Wavelet before applying computational intelligence. Since the published works perform empirical tests without a scientific methodology for assessing discrete Wavelet families before applying the forecast method. Figure 12 shows a flowchart of the Wavelet decomposition strategy and computational intelligence.

The Wavelet decomposition strategy was applied using mothers' functions Biorthogonal (bior), Reverse biorthogonal (rbio), Coiflet (coif), Daubechies (db), discrete Meyer (dmey), and Symlet (sym). Hybrid models arising from the filtering of anemometric signals through Wavelet decompositions and computational intelligence have been developed with efficiency in the forecast results.

Daubechies [22] teach that a Wavelet transform is a tool that cuts up data or functions or operators into different frequency components, and then studies each component with a resolution matched to its scale. The



Figure 5. Wind speed anemometer data, site: Mucugê 100.0 m (a), 120.0 m (b), and 150.0 m (c).

Wavelet transform of a signal evolving in time depends on two variables: frequency (or scale) and time. Wavelets provide a tool for time-frequency localization. In many applications, given a signal f(t) (for the moment, we assume that t is a continuous variable), one is interested in its frequency content locally in time. The standard Fourier transform is given by the following Equation (4):

$$(\mathcal{F}f)(\omega) = \frac{1}{\sqrt{2\pi}} \int dt e^{-i\omega t} f(t) \tag{4}$$

also gives a representation of the frequency content of f, but information concerning time-localization of, e.g., high-frequency bursts cannot be read off easily from $\mathcal{F}f$. Time-localization can be achieved by first windowing the signal f, so as to cut off only a well-localized slice of f, and then taking its Fourier transform:

$$(T^{win}f)(\omega, t) = \int dsf(s)g(s-t)e^{-iws}$$
 (5)

where f = function; t = time; $\omega = frequency$; g = window function.

This is the windowed Fourier transform, which is a standard technique for time-frequency localization. It is even more familiar to signal analysts in its discrete version, where t and ω are assigned regularly spaced values: $t = nt_0$, $\omega = m\omega_0$, where m, n range over \mathbb{Z} , and ω_0 , $t_0 > 0$ are fixed. Then Equation (5) becomes

$$T_{m,n}^{\min}(f) = \int ds f(s)g(s-nt_0)e^{-im\omega_0 s}$$
(6)

for fixed *n*, the $T_{m,n}^{win}(f)$ correspond to the Fourier coefficients of $f(\bullet)g(\bullet - nt_0)$. If, for instance, *g* is compactly supported, then it is clear that with appropriately chosen ω_0 , the Fourier coefficients $T_{.,n}^{win}(f)$ are sufficient to characterize and, if need be, to reconstruct $f(\bullet)g(\bullet - nt_0)$. Changing *n* amounts to shifting the "slices" by steps of t_0 and its multiples, allowing the recovery of all of *f* from the $T_{m,n}^{win}(f)$. The windowed Fourier transform provides thus a description of *f* in the time-frequency plane.

The idea of the Wavelet transform, first put forward by a geophysicist Jean Moret in 1982 for seismic wave


INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS 🛞 9

Figure 6. Wind speed anemometer data, site: Mucuri 100.0 m (a), 120.0 m (b), and 150.0 m (c).

analysis [22], can be categorized as the continuous wavelet transform (CWT) and discrete wavdet transform (DWT). The continuous Wavelet involves the continuous scaling and time-shifting of the mother Wavelet. The high scaling (low-pass filter) gives approximate information about the signal (A₁, A₂, ..., A_n), whereas low scaling (high-pass filter) gives a detailed information of the signal (d₁, d₂, ..., d_n). The Wavelet transform provides a similar time-frequency description, with a few important differences. The Wavelet transform formulas analogous to (5) and (6) are,

$$(T^{\mathrm{wav}}f)(a,\mathbf{b}) = |a|^{-1/2} \int dt f(t) \psi\left(\frac{t-b}{a}\right)$$
(7)

and

$$T_{m,n}^{wav}(f) = a_0^{-m/2} \int dt f(t) \psi \left(a_0^{-m} t - n b_0 \right)$$
(8)

in both cases, we assume that ψ satisfies, $\int dt \ \psi(t) = 0$. Equation (8) is again obtained from (7) by restricting *a*, *b* to only discrete values: $a = a_0^m$, $b = nb_0a_0^m$ in this case, with m, n ranging over \mathbb{Z} , and $a_0 > 1$, $b_0 > 0$ fixed. One similarity between the Wavelet and windowed Fourier transforms is clear: both (5) and (7) take the inner products of f with a family of functions indexed by two labels, $\psi^{a,b}(s) =$ $g^{w,t}(s) = e^{iws}g(s - t)$ in (5), and $\psi\left(\frac{s-b}{a}\right)$ in (7). The functions $\psi^{a,b}$ are called a-Wavelets; the function ψ is sometimes called mother Wavelet. Daubechies [22] notes that ψ and g are implicitly assumed to be real, even though this is by no means essential; if they are not, then complex conjugates have to be introduced in (5), (7). There exist many different types of the Wavelet transform, all starting from the basic formulas (7), (8). In these notes we will distinguish between: i) The continuous Wavelet transform (7); and ii) The discrete Wavelet transform (8).

The Meyer Wavelet $(\hat{\psi})$ and scaling function $(\hat{\phi})$ are defined in the frequency domain. Daubechies [22] explain that both $\hat{\psi}$ and $\hat{\phi}$ are defined in the frequency domain, starting with an auxiliary function (ν) . Then,

10 🛞 P. J. ZUCATELLI ET AL.









c)

Figure 7. Frequency distribution of wind speed data, Esplanada 100.0 m (a), 120.0 m (b), and 150.0 m (c).

the Meyer Wavelet function is represented by Equations (9)-(11), i.e.

$$\tilde{\psi}(\omega) = (2\pi)^{-1/2} e^{i\omega/2} \sin \left[\frac{\pi}{2} \nu \left(\frac{3}{2\pi} |\omega| - 1 \right) \right] \quad \text{if} \quad \frac{2\pi}{3} \le |\omega| \le \frac{4\pi}{3}$$
(9)

$$\hat{\psi}(\omega) = (2\pi)^{-1/2} \gamma^{i\omega/2} \cos\left[\frac{\pi}{2}\nu\left(\frac{3}{4\pi}|\omega|-1\right)\right] \text{ if } \frac{4\pi}{3} \le |\omega| \le \frac{8\pi}{3}$$

(10)

$$\hat{\psi}(\omega) = 0 \quad \text{if} \quad |\omega| \notin \left[\frac{2\pi}{3}, \frac{8\pi}{3}\right] \tag{11}$$

and scaling function by Equations (12)-(14),

$$\hat{\phi}(\omega) = (2\pi)^{-1/2} \ if \ |\omega| \le \frac{2\pi}{3}$$
 (12)

$$\hat{\phi}(\omega) = (2\pi)^{-1/2} \cos\left[\frac{\pi}{2}\nu\left(\frac{3}{2\pi}|\omega| - 1\right)\right] \quad \text{if} \quad \frac{2\pi}{3} \le |\omega| \le \frac{4\pi}{3} \tag{13}$$

$$\hat{\phi}(\omega) = 0 \quad if \quad |\omega| > \frac{4\pi}{3} \tag{14}$$

All ANN (MLP or RNN) were trained with Levenberg-Marquardt backpropagation training algorithm, to predict the wind speed for 1h ahead, and then apply it for 2h to 6h ahead. The Levenberg-Marquardt optimization algorithm exhibits fast convergence speed and applies the Hesse and Jacobian matrices to solve multidimensional optimization problems. The approach to training and validating the model for the next hour wind speed prediction, then recursively inferring the wind speed forecasting for the following hours is showed in Figures 13 and 14.

Therefore, the ANN was trained to perform the wind speed forecasting 1 h ahead, using it, the trained ANN was applied to recursively infer the forecasting



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS 🛞 11

Figure 8. Frequency distribution of wind speed data, Mucugê 100.0 m (a), 120.0 m (b), and 150.0 m (c).

for the next hours of the wind speed. The computational cost of this methodology, as applied in [14-18], is smaller than if it were necessary to train to predict the next nth hour for each input or sample of anemometric data. Then, to perform the prediction, the first phase is to identify what ANN topology can better perform the wind speed forecasting 1h ahead for each height and each site. Afterward, this predicted wind speed value is assigned as input for the second-hour forecasting. So, it is calculated the forecast of the wind speed for the second hour. This computational procedure is repeated until the nth hour of the forecasting is reached. In this hybrid model (ANN+Wavelet decomposition), the result of the wind speed forecasting is the sum of the predicted detail and approximation components. In this study, the activation functions were hyperbolic tangent function (sigmoidal function: this function accepts both real and

complex inputs) for all hidden layers, and the linear function to the output layer. Results and discussions are presented in the next section.

3. Results and discussions

For being able to measure the accuracy of the forecasted values provided by the tool, the error (e_t) calculated through Equation (15) was used in this work. This is the method that is commonly used to analyze the efficiency of an ANN. The statistical treatment employed in the results is mean squared error (MSE), root mean squared error (RMSE), Pearson's correlation coefficient (Equations 16–18), and percentage of data of factor of two (Fac2). For these statistical indicators, values close to 0.0 (zero) are adequate for the MSE, RMSE, and values close to 1.0 (one) are adequate for the Pearson. Values close to 100% are adequate for the Fac2. In other words, is a fraction of

12 🕢 P. J. ZUCATELLI ET AL.





c)

Figure 9. Frequency distribution of wind speed data, Mucuri 100.0 m (a), 120.0 m (b), and 150.0 m (c).

Table 1. Descriptive statis	cs regarding wind speed.
-----------------------------	--------------------------

Sites	Anemometer height [m]	Arithmetic mean of wind speed [m/s]	Variance [m ² /s ²]	Standard deviation (m/s)
Esplanada	100.0	4.956	2.333	1.527
	120.0	5.285	2.382	1.543
	150.0	5.673	2.518	1.587
Mucuge	100.0	8.159	6.158	2.481
	120.0	8.090	6.021	2.453
	150.0	8.192	6.254	2.500
Mucuri	100.0	7.905	8.534	2.921
	120.0	8.127	8.066	2.840
	150.0	8.440	7.586	2.754

Table 2. MLP and RNN architectures.

MLP and RNN configuration (config.) and layer	Architecture 1 MLP: input layer	Architecture 2 RNN + Wavelets: input layer	1 st hidden layer	2 nd hidden layer	Output layer
Config. 1	9 neurons	8 neurons	9 neurons		1 neuron
Config. 2	9 neurons	8 neurons	6 neurons	-	1 neuron
Config. 3	9 neurons	8 neurons	3 neurons	-	1 neuron
Config. 4	9 neurons	8 neurons	1 neuron	-	1 neuron
Config. 5	9 neurons	8 neurons	9 neurons	6 neurons	1 neuron
Config. 6	9 neurons	8 neurons	6 neurons	3 neurons	1 neuron
Config. 7	9 neurons	8 neurons	1 neuron	1 neuron	1 neuron



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS 🛞 13

Figure 10. Fully connected feedforward or acyclic network with two hidden layers and one output layer.



Figure 11. Recurrent network with hidden neurons.



Figure 12. Flowchart of the wavelet decomposition strategy.

```
14 🛞 P. J. ZUCATELLI ET AL.
```



Figure 13. Flowchart of the procedure using MLP.

data [%] for $0.50 \leq$ (simulated wind speed/observed wind speed) ≤ 2.0 .

$$e_t = o_t - f_t \tag{15}$$

$$MSE = \frac{1}{n} \sum_{t=1}^{n} e_t^2$$
 (16)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^{n} e_t^2}$$
(17)

Pearson =
$$\sum_{t=1}^{n} (o_t - \overline{o})(f_t - \overline{f})$$

$$\frac{\sum_{t=1}^{n} (o_t - \overline{o})^2 \sum_{t=1}^{n} (f_t - \overline{f})^2}{\sqrt{\sum_{t=1}^{n} (o_t - \overline{o})^2 \sum_{t=1}^{n} (f_t - \overline{f})^2}}$$
(18)

where: t = time; n = number of samples; $e_t = \text{error}$; $o_t = \text{observed value}$; $f_t = \text{forecasted value}$; $\overline{o} = \text{is the}$ mean of all observed values; $\overline{f} = \text{is the mean of all forecasted values}$.

Table 3 presents the Weibull shape factor and the Weibull scale parameter. Figures 15–17 show Weibull distribution density versus wind speed to all sites and all anemometer height. Sites characterized by very steady winds (like tropical trade wind environments) may have a Weibull shape factor value as high as 3.0 or 4.0.

To find out which family of Wavelets (Daubechies, Biorthogonal, Reverse biorthogonal, Coiflets, Symlets, or discrete Meyer) would present more precision in the decomposition of anemometric signals, in this study, a comparison and a statistical evaluation were analyzed between the approximate level 1 decomposed signal (or A1 signal by Wavelet decomposition) and the original wind speed time series. Figures 18–24 show the results achieved from this comparison. The Wavelet discrete Meyer family (dmey) demonstrates greater precision in the decomposition of the signals collected in Esplanada, Mucugê, and Mucuri.



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS

Figure 14. Flowchart of the procedure using RNN + Wavelet decomposition.

Sites	Anemometer height [m]	k = the Weibull shape factor [unitless]	c = the Weibull scale parameter [m/s]
Esplanada	100.0	3.590	3.134
	120.0	3.806	3.340
	150.0	3.988	3.587
Mucuge	100.0	3.642	5.329
and the second	120.0	3.653	5,280
	150.0	3.627	5.355
Mucuri	100.0	2.947	5.312
	120.0	3.132	5.420
	150.0	3.374	5.581

Table 3. Weibull shape factor and Weibull scale parameter.

The best ANN configurations for Mucuri, Esplanada, and Mucugê are shown in Tables 4 and 5. This distribution of neurons was obtained empirically by testing different values and varying the amount of processing neurons and learning rate until obtaining the best results.

The neural network configurations shown in the previous tables detected as the most efficient in

```
16 🕒 P. J. ZUCATELLI ET AL.
```



Figure 15. Weibull distribution density versus wind speed. Site: Esplanada.



Figure 16. Weibull distribution density versus wind speed. Site: Mucugê.



Figure 17. Weibull distribution density versus wind speed. Site: Mucuri.



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS (G) 17



Figure 20. Wavelet Reverse biorthogonal (rbio) decomposition. RMSE (a), R² (b).

precision and accuracy were used to predict the wind speed from 1h to 6h (nowcasting) in Mucuri, Esplanada, and Mucugê at all the heights tested. Tables 6 and 7 show the evaluation metrics of the prediction results (1h, 3h, and 6h ahead) obtained by the MLP model, and RNN+Wavelet decomposition (hybrid model), respectively.

In Tables 6 and 7 it can be observed that, as the wind speed forecasting load increases, there is a reduction in the quality of the predicted data during ANN forecasting so that the higher the forecasting time, the greater the associated error measured by RMSE, and this is following what the literature describes [23-26]. It is observed that the statistical



Figure 23. Wavelet discrete Meyer (dmey) decomposition. RMSE (a), R² (b).

results reported in this study show that the computational model is applicable in any site and any anemometer height, given the low variability of such results. In short, it is very important to analyze the neural network architectures that will be applied in the prediction tests, because they adapt to the anemometric data set (or time series). When a critical analysis is made on the statistical meters calculated and recorded in this work, we understand that the application of artificial intelligence through supervised machine learning along with the Wavelet decomposition (e.g. hybrid computational method) is a viable technique to predict the wind speed and, therefore, the wind energy generation,



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS (a) 19

Figure 24. Wavelet families' statistical results. RMSE (a), R² (b).

Table 4. The best ANN (MLP) configuration.

	Anemometer height The best ANN configuration			
Site	150.0 m	120.0 m	100.0 m	
Esplanada	7	7	7	
Mucuge	6	7	3	
Mucuri [16]	1	6	6	
		The best learning rate	The best learning rate	
Esplanada	0.001	0.300	0.001	
Mucugé	0.300	0.900	0.300	
Mucuri	0.900	0.300	0.010	

Table 5. The best ANN (RNN+ Wavelet decomposition) configuration.

	Anemometer height The best ANN configuration			
Site	150.0 m	120.0 m	100.0 m	
Esplanada	5	6	5	
Mucugê	3	3	5	
Mucuri	6	6	1	
	The best learning rate			
Esplanada	0.010	0.010	0.010	
Mucugê	0.900	0.900	0.010	
Mucuri	0.900	0.010	0.010	

Table 6. The contrast between RMSE, Pearson, and Fac2 values depending on site, and anemometer height. ANN: MLP.

Site / Anemometer height	Time horizon	mean RMSE [m/s]	mean Pearson correlation coefficient	mean Percentage of the data of a factor of two (Fac2)
Esplanada (100.0 m, 120.0 m, and 150.0 m)	1 h	1.020	0.784	98.79%
Mucuge (100.0 m, 120.0 m, and 150.0 m)		1.384	0.879	98.79%
Mucuri (100.0 m, 120.0 m, and 150.0 m) [16]		0.942	0.943	100%
Esplanada (100.0 m, 120.0 m, and 150.0 m)	3 h	1.424	0.522	98.43%
Mucuge (100.0 m, 120.0 m, and 150.0 m)		2.154	0.673	95.81%
Mucuri (100.0 m, 120.0 m, and 150.0 m) [16]		1.729	0.818	99.65%
Esplanada (100.0 m, 120.0 m, and 150.0 m)	6 h	1.765	0.258	95.17%
Mucuge (100.0 m, 120.0 m, and 150.0 m)		2.787	0.463	90.07%
Mucuri (100.0 m, 120.0 m, and 150.0 m) [16]		2.902	0.512	92.37%

mainly due to the low cost and low computational time. However, it's essential to carefully choose the architecture of the neural network (or topology) and its hyperparameters that best matches the wind power forecasting project, in addition to the need to make a quantitative and qualitative analysis of the anemometric data that will feed the neural network, since these predictors directly impact the predicted results (in this case, the wind speed). Figures 25–27 describe the mean squared error (MSE). Given all the cases projected in the figures, 100% were more accurate when using computational intelligence + Wavelet decomposition (i.e.

20 🛞 P. J. ZUCATELLI ET AL.

Table 7. The contrast between RMSE, Pearson, and Fac2 values depending on site, and anemometer height. ANN: RNN + discrete Meyer Wavelet decomposition (dmey).

Site / Anemometer height	Time horizon	mean RMSE [m/s]	mean Pearson correlation coefficient	mean Percentage of the data of a factor of two
Esplanada (100.0 m, 120.0 m, and 150.0 m)	1h	0.814	0.832	100%
Mucuge (100.0 m, 120.0 m, and 150.0 m)		0.821	0.962	99.48%
Mucuri (100.0 m, 120.0 m, and 150.0 m)		0.870	0.951	100%
Esplanada (100.0 m, 120.0 m, and 150.0 m)	3 h	1.272	0.662	97.73%
Mucuge (100.0 m, 120.0 m, and 150.0 m)		1.581	0.856	98.43%
Mucuri (100.0 m, 120.0 m, and 150.0 m)		1.501	0.853	99.13%
Esplanada (100.0 m, 120.0 m, and 150.0 m)	6h	1.597	0.487	97.16%
Mucugé (100.0 m, 120.0 m, and 150.0 m)		2.259	0.717	97.16%
Mucuri (100.0 m, 120.0 m, and 150.0 m)		1.713	0.815	97.87%



a)



b)



c)

Figure 25. MSE results for Esplanada, 100.0 m (a), 120.0 m (b), and 150.0 m (c).

RNN + dmey). Which justifies the use of energy in this scientific investigation. The Wavelet decomposition eliminates noisy components from the wind time series, and the supervised machine learning by ANN provides a multistep forecast on the sub-signals obtained from the decomposition technique.

Figure 28 shows the comparison of the MSE statistical descriptive measure comparing the three sites and the three anemometers heights applied in this work. Figures 29–31 show the best prediction results (nowcasting) using hybrid computational model for the sites Esplanada, Mucugé, and Mucuri (computational model: RNN+dmey). In the figures: a) is the results of the 6-step forecasting of the wind speed series, and b) and c) comparison data of Fac2.

Papers such as those developed by [27-30] highlight the relevance of studies on ANN applied to wind time series with the ultimate goal of improving wind field forecasting technologies and then the short-term



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS 🛞 21

Figure 26. MSE results for Mucuge, 100.0 m (a), 120.0 m (b), and 150.0 m (c).

forecasting for energy. This directly helps the operators of the electrical matrix of the region in question and helps other regions to develop sustainably, especially using wind energy. This paper shows the shortterm wind speed forecasting in the humid tropical region of Bahia, Brazil, applying the Wavelet decomposition and the ANN technique to the hourly time series representative of the site. It uses an approach to train the model for the next hour forecasting, then recursively inferring the forecasting for the following hours. This kind of method has low computational costs when compared with numerical modeling. The results achieved and recorded in this research are important for improving knowledge about the application of the Wavelet decomposition in the time series of the wind through the different families. Different families provide different relationships between how compact the basis function is localized in space and how smooth they're.

The dmey Wavelet provides the best results among all the included 48 mother Wavelet functions. These results agree with the results published by empirical evidence in the literature. Zucatelli et al. [17] showed a comparison of the mean squared error and Rsquared to MLP, RNN, and RNN+Wavelet decomposition. The Wavelet families applied to wind speed data decomposition were bior3.9 level 3, coif5 level 3, db7 level 3, db8 level 5, db9 level 7, dmey level 3 and sym7 level 3. The work presents that the RNN + dmey Wavelet decomposition has the best result. Multi-step prediction intervals are 1h to 12h ahead and the site is in Brazil. Already in Liu et al. [31] is showed that discrete Meyer Wavelet provides the best results among all the included 17 mother Wavelet functions. These mother Wavelet functions include the haar; the db4, db6 and db10; the coif1, coif2, coif3, coif4 and coif5; the sym2, sym3, sym4, sym5, sym6, sym7 and sym8 and the dmey. Multi-step prediction intervals are 1 h to 7 h ahead and the sites are in China. Then, the results published empirically in the literature showed that the discrete Meyer is the most efficient when compared to the other Wavelet families.



Figure 27. MSE results for Mucuri, 100.0 m (a), 120.0 m (b), and 150.0 m (c).

The wind speed forecasting accurately in a time horizon of 1 h to 6 h ahead (nowcasting) contributes to the hourly commercialization of wind power, either in Brazil or in another country. It should be emphasized that the computational cost due to the application of computational intelligence by machine learning in studies such as those carried out in this work increases as the expected workload increases, but it is even lower when compared to the cost of mathematical modeling and numerical simulation for wind prediction using atmospheric models, such as weather research and forecasting (WRF). The WRF is a great example of a numerical model of weather forecasts used both for the operation of meteorological centers and for atmospheric research. The most outstanding features of the WRF are the multiple dynamic cores, a variable 3D data assimilation system, and a software structure that allows computational parallelism, as well as the extensibility of the system. In this way, the computational time resulting from the use of numerical forecasting models (Prediktor, Previento, LocalPred, eWind, and WRF, for example)

with refined simulation grids for a short to the medium-term horizon in microscale spatial resolution, it ends up, many times, not justifying the cost-benefit. These models are well used for forecasting with mesoscale spatial resolution and long-term horizon. In contrast, the persistence method and statistical methods (Autoregressive Model, Autoregressive Moving Average, and Autoregressive Integrated Moving Average - ARIMA, for example) in most studies are applied to forecast up to 1 h ahead, as variability and fluctuations observations of the observed data end up reducing the accuracy of the forecast. Thus, the forecast for wind energy in the short-term can be improved using this hybrid model to improve the quality of wind energy 1h to 6h ahead supplied to the power grid.

4. Conclusion and future works

The objective of this work was to present the shortterm wind speed prediction 6 h ahead (or nowcasting) for three sites in the state of Bahia (Esplanada,



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS (a) 23

Figure 28. MSE results (RNN + dmey) for Esplanada, Mucuri, and Mucuge at 100.0 m (a), 120.0 m (b), and 150.0 m (c).

Mucugê, and Mucuri), which is one of the most important Brazilian states in terms of renewable energy production. For this, it was applied the computational intelligence by ANN technique, which was trained, validated, and tested using data collected in anemometric towers installed at 100.0 m, 120.0 m, and 150.0 m height (average hourly values of the wind speed, wind direction, air temperature, air humidity, and air pressure). The wind energy is the fastest-growing type of renewable energy in Brazil and these results are presented as a novelty, since other works that used this computational model to predict wind speed for 1 h to 6 h (nowcasting) in Bahia state, Brazil, especially in the Esplanada, Mucugê, and Mucuri cities, were not found in other scientific research published, particularly in positions where the hub of the wind turbine are usually positioned, such as the anemometric heights of this study, which were 100.0 m, 120.0 m, and 150.0 m. The application of the technique of ANN and Wavelet decomposition to predict the wind speed at different heights and sites was

adequate when interpreting the statistical results. Especially, it can be pointed out that the 6h forecast presented good results (by RNN+Wavelet discrete Meyer) with low computational costs, helping wind farm operators in decision-making processes, as ONS in Brazil. Then, the results showed that the application of the hybrid machine learning algorithm (super-RNN + Wavelet machine learning by vised decomposition, using discrete Meyer) to predict the wind speed at different Bahia's sites and higher heights presented good accuracy, attesting its ability to be used as a powerful tool to ONS to improve the usage and integration of the wind energy into the national electrical grid. Globally, wind power has lessened the burden on conventional fossil fuel-based power generation. Wind resource assessment for wind farms aids accurate forecasting and analyzing the nature of ramp events, for example. An important outcome of this study is that machine learning algorithms could be successfully used to wind forecasting before the establishment of wind plants in a potential





Figure 29. Wind speed prediction 6 h ahead (nowcasting), in Esplanada. Dataset: 05/21/2016 at 7:00 a.m. until 05/29/2016 at 8:00 a.m.



Figure 30. Wind speed prediction 6 h ahead (nowcasting), in Mucugé. Dataset: 09/29/2016 at 10:00 p.m. until 10/07/2016 at 11:00 p.m.



INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS (a) 25

Figure 31. Wind speed prediction 6 h ahead (nowcasting), in Mucuri. Dataset: 12/23/2015 at 12:00 p.m. until 12/31/2015 at 1:00 p.m.

location. We leave it as a suggestion for future work on this research: to use the Mucugê, Esplanada, Mucuri, and other observational data collected in different heights in Brazil and Uruguay to perform the forecast of the wind power. The next papers can apply computational intelligence by supervised machine learning aiming the medium and long-term wind speed forecasting applying long short-term memory (LSTM), gated recurrent units (GRU), convolutional neural networks (CNN), Wavelet neural network (WNN) and to compare these results with the output produced by numerical weather prediction (NWP) using mathematical models. Wind power and wind ramp forecasting using computational intelligence, and self-organizing map (SOM) in wind speed forecasting are also a great subject of research to the electric power sector.

Acknowledgements

We thank Manufacturing and Technology Integrated Campus – SENAI CIMATEC, Salvador, Bahia, Brazil, for their computational support.

Disclosure statement

We wish to confirm that there are no known conflicts of interest associated with this publication and there has been no significant financial support for this work that could have influenced its outcome.

ORCID

Pedro Junior Zucatelli in http://orcid.org/0000-0002-6744-5376 Erick Giovani Sperandio Nascimento in http://orcid.org/ 0000-0003-2219-0290 Alex Álisson Bandeira Santos in http://orcid.org/0000-0001-9935-4084 Davidson Martins Moreira in http://orcid.org/0000-0002-0902-5218

References

[1] W. Y. Y. Cheng, Y. Liu, A. J. Bourgeois, Y. Wu and S. E. Haupt, "Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation," *Renewable Energy*, vol. 107, pp. 340–351, July 2017. DOI: 10.1016/j.renene.2017.02.014. 26 🕞 P. J. ZUCATELLI ET AL.

- [2] P. Jiang, Y. Wang and J. Wang, "Short-term wind speed forecasting using a hybrid model," *Energy*, vol. 119, pp. 561–577, Jan. 2017. DOI: 10.1016/j.energy. 2016.10.040.
- [3] C. Li, Z. Xiao, X. Xia, W. Zou and C. Zhang, "A hybrid model based on synchronous optimisation for multi-step short-term wind speed forecasting," *Appl. Energy*, vol. 215, pp. 131–144, Apr. 2018. DOI: 10. 1016/j.apenergy.2018.01.094.
- [4] C. Huang, F. Li and Z. Jin, "Maximum power point tracking strategy for large-scale wind generation systems considering wind turbine dynamics," *IEEE Trans. Ind. Electron.*, vol. 62, no. 4, pp. 2530–2539, Apr. 2015. DOI: 10.1109/TIE.2015.2395384.
- [5] C. S. Tian, Y. Hao and J. M. Hu, "A novel wind speed forecasting system based on hybrid data preprocessing and multi-objective optimization," *Appl. Energy*, vol. 231, pp. 301–319, Dec. 2018. DOI: 10. 1016/j.apenergy.2018.09.012.
- [6] C. Li, Z. J. Zhu, H. F. Yang and R. R. Li, "An innovative hybrid system for wind speed forecasting based on fuzzy preprocessing scheme and multiobjective optimization," *Energy*, vol. 174, pp. 1219–1237, May 2019. DOI: 10.1016/j.energy.2019. 02.194.
- [7] Y. F. Li, H. P. Shi, F. Z. Han, Z. Duan and H. Liu, "Smart wind speed forecasting approach using various boosting algorithm, big multi-step forecasting strategy," *Renewable Energy*, vol. 135, pp. 540–553, May 2019. DOI: 10.1016/j.renene.2018.12.035.
- [8] Y. Wang, H. B. Wang, D. Srinivasan and Q. Hu, "Robust functional regression for wind speed forecasting based on Spare Bayesian learning," *Renewable Energy*, vol. 132, pp. 43–60, Mar. 2019. DOI: 10.1016/j.renene.2018.07.083.
- [9] R. Kaja Bantha Navas, S. Prakash and T. Sasipraba, "Artificial neural network based computing model for wind speed prediction: A case study of Coimbatore, Tamil Nadu, India," *Physica A: Statistical Mechanics Its Appl.*, vol. 542, pp. 123383, Mar. 2020. DOI: 10.1016/j.physa.2019.123383.
- [10] W. Tong, "Chapter 1: Fundamentals of wind energy," in Wind Power Generation and Wind Turbine Design, vol. 44, USA: WTT Press, 2010, pp. 3–46. Available: https:// www.witpress.com/Secure/elibrary/papers/9781845642051/ 9781845642051001FU1.pdf. DOI: 10.2495/978-1-84564-205-1/01.
- [11] I. Kuikka, "Wind nowcasting: Optimizing runway in use," Technical report, Systems Analysis Laboratory, Helsinki University of Technology, 2009. Available: https://www.mdpi.com/1996-1073/12/16/3050/pdf
- [12] H. S. Dhiman, D. Deb and V. E. Balas, "Chapter 6 -Hybrid machine intelligent wind speed forecasting models", in Supervised Machine Learning in Wind Forecasting and Ramp Event Prediction, USA: Academic Press, 2020, pp. 75–99. DOI: 10.1016/ B978-0-12-821353-7.00017-X
- [13] D. B. Alencar, C. M. Affonso, R. C. L. Oliveira, J. L. M. Rodríguez, J. C. Leite and J. C. R. Filho, "Different models for forecasting wind power generation: Case study," *Energies*, vol. 10, no. 12, pp. 1976, 2017. DOI: 10.3390/en10121976.

- [14] P. J. Zucatelli, et al., "Short-term wind speed forecasting in Uruguay using computational intelligence," *Heliyon*, vol. 5, no. 5, pp. e01664, May 2019, DOI: 10.1016/j.heliyon.2019.e01664.
- [15] P. J. Zucatelli, E. G. S. Nascimento, A. A. B. Santos, A. M. G. Arce and D. M. Moreira, Study of the Wind Speed Forecasting Applying Computational Intelligence. Rijeka: IntechOpen, 2019. DOI: 10.5772/ intechopen.89758.Available: https://www.intechopen. com/online-first/study-of-the-wind-speed-forecasting-applying-computational-intelligence.
- [16] P. J. Žucatelli, et al., "Short-term wind speed forecasting using computational intelligence in Bahia, Brazil," In Proceedings of the Air Pollution Conference Brazil and 4th CMAS South America, 2019. Extended Abstract, Belo Horizonte, 2019. Available: https://com.us14listmanage.com/subscribe?u=2498509b374e6e196b427a2c4& id=162bf02c3d.
- [17] P. J. Zucatelli, E. G. S. Nascimento, L. R. Campos, A. A. B. Santos and D. M. Moreira, "Short-term wind speed forecasting in tropical region using wavelets and artificial intelligence," In Proceedings of the International Symposium on Innovation and Technology (SIINTEC), 2019, pp. 365–372. DOI: 10.5151/siintec2019-46.Available: https://www.proceedings.blucher.com.br/article-details/ previso-da-velocidade-do-vento-a-curto-prazo-em-regiotropical-utilizando-Wavelets-e-inteligncia-artificial-33286.
- [18] P. J. Zucatelli, E. G. S. Nascimento, A. M. G. Arce and D. M. Moreira, "Short-range wind speed predictions in subtropical region using artificial intelligence," J. Systemics, Cybern. Informatics, vol. 17, no. 4, pp. 1–8, 2019. Available: http://www.iiisci.org/journal/sci/ Abstracts.asp?var=&previous=ISS1904.
- [19] ABEEolica. 2020. Infowind Brazil Update 16 2020 -Jun, 15. Available: http://abeeolica.org.br/wp-content/ uploads/2020/06/InfoventoPT_16.pdf
- [20] J. L. Paixão, et al., "Wind generation forecasting of short and very short duration using Neuro-Fuzzy Networks: A case study," 7th International Conference on Modern Power Systems (MPS 2017), IEEE, 2017. Available: https://ieeexplore.ieee.org/document/7974446. DOI: 10. 1109/MPS.2017.7974446.
- [21] S. Haykin, Neural Networks: A Comprehensive Foundation, 2nd ed. Hamilton, Ontario, Canada: Pearson Education Inc., 1999, pp. 823.
- [22] I. Daubechies, "Ten lectures on wavelets," CBMS-NSF Regional Conference Series in Applied Mathematics, SIAM, 1992. DOI: 10.1137/1.9781611970104.
- [23] A. Kusiak, H. Zheng and Z. Song, "Short-term prediction of wind farm power: A data mining approach," *IEEE Trans. Energy Conversion*, vol. 24, no. 1, pp. 125–136, Mar. 2009. DOI: 10.1109/TEC. 2008.2006552.
- [24] R. Blonbou, "Very short-term wind power forecasting with neural networks and adaptive Bayesian learning," *Renewable Energy*, vol. 36, no. 3, pp. 1118–1124, Mar. 2011, DOI: 10.1016/j.renene.2010.08.026.
- [25] A. Carpinone, M. Giorgio, R. Langella and A. Testa, "Markov chain modeling for very-short-term wind power forecasting," *Electric Power Syst. Res.*, vol. 122, pp. 152–158, May 2015. DOI: 10.1016/j.epsr.2014.12. 025.

INTERNATIONAL JOURNAL FOR COMPUTATIONAL METHODS IN ENGINEERING SCIENCE AND MECHANICS 🛞 27

- [26] Ü. B. Filik and T. Filik, "Wind speed prediction using artificial neural networks based on multiple local measurements in Eskisehir," *Energy Procedia*, vol. 107, pp. 264–269, Feb. 2017. DOI: 10.1016/j.egypro.2016.12.147.
 [27] A. Brka, Y. M. Al-Abdeli and G. Kothapalli,
- [27] A. Brka, Y. M. Al-Abdeli and G. Kothapalli, "Influence of neural network training parameters on short-term wind forecasting," *Int. J. Sustainable Energy*, vol. 35, no. 2, pp. 115–131, 2016. DOI: 10. 1080/14786451.2013.873437.
- [28] D. Fang and J. Wang, "A novel application of artificial neural network for wind speed estimation," Int. J. Sustainable Energy, vol. 36, no. 5, pp. 415–429, 2017. DOI: 10.1080/14786451.2015.1026906.
- [29] S. K. Jha and J. Bilalovikj, "Short-term wind speed prediction at Bogdanci power plant in FYROM using

an artificial neural network," Int. J. Sustainable Energy, vol. 38, no. 6, pp. 526-541, 2019. DOI: 10. 1080/14786451.2018.1516668.

- [30] H. H. Çevik, M. Çunkaş and K. Polat, "A new multistage short-term wind power forecast model using decomposition and artificial intelligence methods," *Physica A: Statistical Mechanics Its Appl.*, vol. 534, pp. 122177, Nov. 2019. DOI: 10.1016/j.physa.2019. 122177.
- [31] H. Liu, H. Wu and Y. Li, "Multi-step wind speed forecasting model based on wavelet matching analysis and hybrid optimization framework," *Sustainable Energy Technologies Assessments*, vol. 40, pp. 100745, Aug. 2020. DOI: 10.1016/j.seta.2020. 100745.

6.5 Artigo 5: An investigation on deep learning and Wavelet transform to nowcast wind power and wind power ramp: a case study in Brazil and Uruguay

Este artigo "An investigation on deep learning and Wavelet transform to nowcast wind power and wind power ramp: a case study in Brazil and Uruguay" foi submetido à revista Energy em 23/02/2021 e publicado online em 06/05/2021. DOI: https://doi.org/10.1016/j.energy.2021.120842>. Este é um estudo pioneiro para a região tropical e subtropical da América do Sul sobre a utilização do sistema híbrido de previsão da velocidade do vento, potência de saída e rampa de energia eólica. O trabalho utilizou dados anemométricos da região subtropical (Uruguai) medidos a 81,8 e 101,8 m e todos os datasets da região tropical (Brasil) medidos a 100 m, 120 m, e 150 m. O comparativo estatístico demonstra que o modelo é passivo de utilização em ambas as regiões, o que contribui cientificamente para as empresas investidoras no ramo de energia eólica e para o operador nacional do sistema elétrico no Brasil e no Uruguai, ONS e UTE respectivamente. Além da previsão da velocidade do vento, há previsão da potência de saída e da rampa de energia eólica empregando dados técnicos de turbinas eólicas comerciais de alturas compatíveis com as alturas em que os dados anemométricos foram coletados nos sítios aqui estudados.

AN INVESTIGATION ON DEEP LEARNING AND WAVELET TRANSFORM TO NOWCAST WIND POWER AND WIND POWER RAMP: A CASE STUDY IN BRAZIL AND URUGUAY

P. J. Zucatelli^{a*}, E. G. S. Nascimento^b, A. Á. B.Santos^b, A. M. G. Arce^c and D. M. Moreira^{a,b} *E-mails: pedrojrzucatelli@gmail.com ; ericksperandio@gmail.com ; alex.santos@fieb.org.br ; aguti@fing.edu.uy ; davidson.moreira@gmail.com*

^aTechnological Center, Federal University of Espírito Santo – UFES, Vitória, Brazil. ^bManufacturing and Technology Integrated Campus, SENAI CIMATEC, Salvador, Brazil. ^cUniversidad de la República – UDELAR. Montevideo, Uruguay

Abstract: Large variations in wind energy production over a period of minutes to hours is a challenge for electricity balancing authorities. The use of reliable tools for the prediction of wind power and wind power ramp events is essential for the operator of the electrical system. The main objective of this work is to analyze the wind power and wind power ramp forecasting at Brazil and Uruguay. To achieve this goal the wavelet decomposition applying 48 different mother wavelet functions and deep learning techniques are used. The recurrent neural network was trained to perform the forecasting of 1 h ahead, and then, using it, the trained network was applied to recursively infer the forecasting for the next hours of the wind speed. After this computational procedure, the wind power and the wind power ramp were predicted. The results showed good accuracy and can be used as a tool to help national grid operators for the energy supply. The wavelet discrete Meyer family (dmey) demonstrates greater precision in the decomposition of the wind signals, whether using signals from tropical or subtropical regions.

Keywords: Computational Methods, Computer Science, Deep Learning, Engineering Science and Mechanics, Sustainable Energy, Wind Engineering.

Highlights:

- Nowcasting wind prediction in tropical and subtropical sites using AI and Wavelet.
- An ANN approach for the estimation of wind power ramp using deep learning.
- Modeling of wind using atmospheric factors in tropical and subtropical sites.

• Wind power and wind power ramp forecasting applying 48 mother Wavelet functions.

1. Introduction

Energy is one of the main constituents of factories, industries, transportation systems, and all modern society. It is necessary to develop technologies applied in alternative energy sources to meet the daily energy demands of factories, industries, businesses, transportation facilities (whether public or private), and all society stakeholders (e.g. company, consumer, state, non-governmental organizations, homes) [1]. Economic development and high standards of living are complex processes that share a common denominator: a reliable supply of energy and the availability of adequate system power. However, quality of life is measured by factors other than material goods; human health and well-being and the nature of our social systems play important if not fundamental, roles. Then, the idea is that we are part of a bigger picture and that our well-being cannot be dissociated from the well-being of the planet. Global warming caused by the intense emission of greenhouse gases into the atmosphere from human activities is occurring now and is a growing threat to society [2]. Data collected around the globe reveal a wide range of effects: melting glaciers, destabilizing ice sheets, rising temperature extremes, rising ocean levels, and mutations in species.

It is known that the use of energy can be related to the development of humanity, from an anthropocentric perspective. When looking back at human evolution, some of the main energy development cycles can be highlighted: the wood, coal, and oil cycles together with natural gas; each one with its particularity, but, systematically, each of these aimed to generate energy to provide, basically, comfort and mobility for human beings. Energy management faces new challenges, not only for generation and distribution, but also for sustainability, since the environmental issue recently brought up the discussion of how the use of energy can affect the climate and, consequently, fauna and flora [3]. It is known that this environmental bias, combined with the need for greater diversification in the energy matrix, makes science, in its various forms, seek to subsidize knowledge for the generation and management of energy using the concepts of energy efficiency and sustainability.

The concern with the reduction of the emission of greenhouse gases (GHG) in the atmosphere has led the world to search more and more for the development of alternative sources of energy generation, among them, wind power [4]. What is observed in research and scientific studies on energy scenarios is an increasing growth in energy demand, which ends up intensifying GHG emissions for the atmosphere due mainly to the burning of fossil fuels [3, 5].

It is a fact that the emission of gases such as carbon dioxide (CO₂), nitrous oxide (N₂O), and methane (CH₄) contribute to the expansion of the greenhouse effect and, consequently, to the increase in the average temperature of the Earth, causing the called global warming, the precursor of the global climate change [3]. Due to these environmental issues, there is a trend towards the incorporation of renewable sources connected to the energy distribution system.

Brazilian and Uruguayan energy policy, driven by environmental interests and the search for diversification of the country's energy matrix, has been encouraging the generation of electric energy based on these sources, both for the connection in the transmission and distribution systems of large generation parks, wind energy, as well as for the distributed microgeneration and minigeration interconnected for the distribution system [6, 7, 8]. Inserted in the context of wind energy, it appears that the variation in wind speed tends to hinder the management decision of the wind farms as to whether or not to activate the set of wind turbines, this is because it is known that the wind field presents variations in different orders of magnitude [6, 7], e.g. annual variations (due to climatic changes), seasonal variations (depending on the different seasons), daily variations (due to the local microclimate), hourly variations (land and sea breezes) and short duration (bursts) variations. Furthermore, the spatial variation of wind energy is also very large. Topography and soil roughness also has a great influence on the distribution of the frequency of occurrence of the winds and their velocity in one place. It is understood that economic losses occur if turbines are subjected to unfavorable conditions. Thus, it is important to develop reliable tools for wind power and wind power ramp forecasting using supervised deep learning [7, 8].

Computational intelligence (CI) or artificial intelligence (AI) is inserted in this context because it has been applied to predict the behavior of the wind in studies involving wind energy and its regional potential for managing or installing wind farms. CI methods aim to perform tasks that require reasoning, machine learning, deep learning, decision making, and optimization. Although sometimes confusing, the definitions of artificial intelligence, machine learning, and deep learning are different. AI is defined by the Merriam-Webster dictionary as "a branch of computer science dealing with the simulation of intelligent behavior in computers" [9]. Machine learning is seen as a subset of AI where the idea is to train computer techniques that can learn useful representations from the input data [10]. Finally, deep learning is a subset of machine learning that emphasizes the learning capability by adding many layers in succession to extract even more meaningful representations from the data. In this context, machine learning can be classified into four types [8, 10], i.e.:

- i. Supervised learning: classification (e.g., identify fraud detection, image classification, customer retention, diagnostics) and regression (e.g., advertising popularity prediction, weather forecasting, market forecasting, estimating life expectancy, population growth prediction, wind power forecasting).
- Unsupervised learning: dimensionality reduction (e.g., big data visualization, meaningful compression, structure discovery, feature elicitation) and clustering (customer segmentation, targeted marketing, recommender systems).
- Semi-supervised learning includes both the problems discussed previously and it uses both labeled and non-labeled data.
- iv. Reinforcement learning: e.g., real-time decisions, game AI, skill acquisition, learning tasks, robot navigation.

The main objective of this study is to explore deep learning and Wavelet transform to nowcast wind power and wind power ramp in the tropical and subtropical regions of South America. Therefore, this research is an investigation that contributes directly to the operation of wind energy plants for tropical and subtropical regions. Sites presented in this work are Colônia Eulacio in the Soriano department (Uruguay), and Mucuri, Mucugê, and Esplanada in Bahia state (Brazil). The time series of wind used in this study were obtained from towers equipped with anemometers at heights of 100.0, 120.0, and 150.0 m in Brazil, and in Uruguay with measurements taken at 81.8 m and 101.8 m, which are representative of the vertical wind energy profile. The main contributions of this work can be summarized as follows:

The proposed model in this paper elucidates the behavior of the wind speed and allows accurate wind power and wind power ramp prediction at four important heights, and at four important sites in South America. Short-term wind power and wind power ramp forecasting can be improved using this computational model to enhance the wind energy quality 1 h to 6 h ahead (nowcasting). Then, an investigation on deep learning and Wavelet Packet Decomposition to forecast wind power and wind power ramp is presented.

Research on wind energy forecasting usually focuses on forecast methods where the design of the input vector is based on anemometer data collected at 10.0 m, e.g. [11]. The need to use physical equations (logarithmic profile or power/log law) to calculate the wind at heights greater than 10.0 m adds errors in wind speed and wind direction predictions. Therefore, this study used weather data measured at 81.8 m, 100.0 m, 101.8 m, 120.0 m, and 150.0 m for artificial neural network (ANN) input (training, validation, and test sets). This is important due to the real hub height of the wind turbines in wind farms. The closer the anemometer is placed

for the eventual height of the wind turbine hub (e.g., 80.0 m, 100.0, 120.0, and 150.0 m), the more accurately it measures the meteorological variables for which the wind turbine is exposed. No previous papers applied AI by supervised deep learning and Wavelet decomposition for wind power and wind power ramp prediction for these heights in such a humid tropical and humid subtropical climate region (Brazil and Uruguay, respectively). The works [6, 7, 8, 12, 13] applied tropical and subtropical anemometers data for wind speed forecasting but did not study wind power and wind power ramp prediction using supervised machine learning and wavelets decomposition by a hybrid model. Therefore, the results constitute a significant contribution to the Brazilian electricity market and for neighboring countries, such as Uruguay, which has great wind energy potential.

In terms of wind potential, there is a wide variety of wind regimes, i.e. the southern region and the northeast of Brazil. In the southern region, the variability of wind is greater because this region suffers from the influence of cold fronts. However, in this region, this difficulty is counterbalanced by greater scientific knowledge and a greater number of measurement systems. In contrast, in the northeast, the climate is tropical, where there are huge gaps in scientific knowledge of wind behavior in the region and relatively lacking measurement systems. In this sense, the fact that trade winds develop on oceans, impose the need to use wind profiles derived from remote sensing of satellites, also for the challenges of complex terrain and coastal regions. These are considered the main scientific frontiers in wind predictability.

In Uruguay, scientific research on wind forecasting is recent and the first work using AI dates from 2019. Uruguay has a worldwide prominence in the use of renewable energy sources, with an emphasis on wind energy. In this study, the matching relationship between the predictor and different AI configurations applying Wavelet decomposition will be discussed to determine the most suitable architectures for the hybrid model (AI + Wavelet). This justifies the effort of this work.

The remaining sections of the article are organized as follows: Section 2 shows the literature review, section 3 describes the methodology, shows the study region, and the data used in the work and provides details of the computational framework used in the model, section 4 presents and discusses obtained results, and section 5 presents the conclusions of the research.

2. Literature review

Many works are found in the literature on wind speed and wind energy prediction applying several analysis methods and on several time horizons. Preliminary studies about short-term wind speed prediction consider using persistence and statistical methods, however, recent studies prefer to use supervised machine learning algorithms, especially the deep learning architectures of long short-term memory (LSTM), gated recurrent unit (GRU), and convolutional neural network (CNN) [14, 15, 16]. The main reason for using supervised machine learning algorithms is that these algorithms can adapt themselves to changing trends inside datasets and produce models based on input data rather than using a generalized model. Many literature studies focus on short-term wind speed prediction due to its simplicity and high accuracy. However, there is a limited number of studies on wind power ramp prediction. The last decade (2010 to 2020) is marked by sustainable development in which alternative sources of energy, such as wind and solar energy, have gained commercial prominence and, consequently, in the scientific community [17]. The graphs projected by Figures 1 to 3 show this fact when searching with predefined terms in the search platform Science Direct. The specificity of the search term, such as "wind power ramp prediction using machine learning", results in a smaller amount of published works when compared to the term "wind speed prediction using machine learning" and the term "wind speed forecasting", for example. This demonstrates the need for advances in research regarding wind power ramps.



Figure 1. Distribution of Publications over time. Terms: wind speed forecasting. Source list: Science Direct.



Figure 2. Distribution of Publications over time. Terms: wind speed prediction using machine learning. Source list: Science Direct.



Figure 3. Distribution of Publications over time. Terms: wind power ramp prediction using machine learning. Source list: Science Direct.

Recent scientific works highlight the nowcasting prediction of wind speed. The World Meteorological Organization (WMO) specifies 0 h to 6 h ahead. Nowcasting is usually applied with techniques that differ significantly from normal numerical weather prediction models. In this time range, it is possible to forecast small features such as individual storms with reasonable accuracy. In this context, Zucatelli et al. [6] show that the short-term wind speed prediction (1

h to 12 h) for the Soriano department (humid subtropical region), in Uruguay, is performed by applying computational intelligence by supervised machine learning by ANN technique using anemometer data. The network was trained and validated to perform the prediction 1 h ahead, and then, using it, the ANN was applied for recursively infer the forecasting for the next hours of the wind speed, the computational complexity is smaller than if it were necessary to train to predict the next 6 h for each input/sample of anemometric data, for example. The tabulated statistical results and the results showed in graphs of the short-term wind speed prediction showed good accuracy at all the anemometer heights tested (10.0 m, 25.7 m, 81.8 m, and 101.8 m), suggesting that this computational method is a powerful tool for the electrical energy sector in Uruguay. Chen et al. [18] present a multifactor spatio-temporal correlation model based on a combination of CNN and LSTM for wind speed prediction. The performance of the proposed model is verified by three experiments. In each experiment, different datasets are used to forecast the wind speed of different target sites in the spring and summer, and eight performance evaluation metrics are used to evaluate each model. Demolli et al. [19] study wind energy prediction performed based on daily wind speed data using deep learning algorithms. Classification algorithms were used to forecast the values of the given wind speed values. Daily mean wind speed values were generated using the hourly wind speed dataset, and the daily total wind energy was modeled using daily wind speed and the standard deviation. Dupré et al. [20] determine the added value of model output statistics for classical time series-based methods compared to the sub-hourly forecasts of wind speed. Two downscaling approaches are tested: one that includes local wind speed measurements and another using explanatory variables from numerical weather prediction model outputs. Zucatelli et al. [21] research short-term wind speed predictions for the subtropical region (Uruguay) and it is performed by applying AI by supervised machine learning using ANN technique for the time series representative of the site. Different ANN architectures for multilayer perceptron (MLP), recurrent neural network (RNN), GRU, and LSTM, a deep learning algorithm-based method, are applied for each site and height (10.0 m, 25.7 m, 81.8 m, and 101.8 m). The statistical results show that the neural networks based on the MLP and LSTM model had the best accuracy when comparing the measured results and the predicted results, in addition to showing more accurate predicted results. Wang et al. [22] recommend a hybrid wind speed prediction approach based on bayesian model averaging and ensemble learning. Self-organizing map clustering and k-fold cross-validation are used to generate multiple sets of the training subsets with the same distribution from the training set of meteorological data to increase the difference of the input samples of the base learners. These training subsets are imported into three base learners, i.e., backpropagation neural network, radial basis function neural network, and support vector machine, to train the model. Zhao et al. [23] develop a novel data-driven method to realize combination forecasts of average wind speed and turbulent standard deviation for both wind components, the study focused on 4 h ahead predictions of 16 steps to be well demand orientated. For the multi-step bivariate forecast task, an adaptive multi-model strategy based on 1D CNN is put forward. Tables 1 and Table 2 present authors who study the prediction of wind power and wind power ramp forecasting, respectively.

Categories	Methods	Authors
Short-term wind power	Cadenas et al. [24] Dowell and Pinson [2 Lima et al. [26] Wang et al. [27] Robles-Rodriguez Dochain [28] Pearre and Swan [29]	
forecasting: e.g. 1 h to some days ahead	Supervised machine learning	Li et al. [30] Sun et al. [31] Wang et al. [32] Zheng et al. [33] Yu et al. [34] Qin et al. [35] Shi et al. [36] Hong and Rioflorido [37] Wang et al. [38]
Medium and long-term wind power forecasting:	Statistical methods	Eldali et al. [39] Alencar et al. [40] Ekström et al. [41] Dokuz et al. [42]
ahead	Supervised machine learning	Demolli et al. [19] Dumitru and Gligor [43] Yan and Ouyang [44]

Table 1. Literature review on wind power forecasting.

	Maroufpoor et al. [45]
	Han et al. [46]

Table 2. Literature review on wind power ramp forecasting.

Document Title	Authors	Reference year
Probabilistic forecasting of wind power ramp events using autoregressive logit models	Taylor [47]	2016
Impacts of synoptic circulation patterns on wind power ramp events in East Japan	Ohba et al. [48]	2016
An optimized swinging door algorithm for identifying wind ramping events	Cui et al. [49]	2016
Ramp forecasting performance from improved short-term wind power forecasting over multiple spatial and temporal scales	Zhang et al. [50]	2017
Forecast of infrequent wind power ramps based on data sampling strategy	Takahashi et al. [51]	2017
Prediction of wind power ramp events based on residual correction	Ouyang et al. [52]	2019
Ramp rate abatement for wind energy integration in microgrids	Frate et al. [53]	2019
Hybrid machine intelligent SVR variants for wind forecasting and ramp events	Dhiman et al. [54]	2019
A new strategy for short-term ramp rate control in wind farms	Probst [55]	2020

It can be noticed the need to expand studies regarding the predictions of wind power ramp to facilitate the management of new wind projects and contribute to the risk management of wind farms already installed and operating in Brazil and Uruguay. These are countries with an emphasis on developing a sustainable energy matrix in South America. Zucatelli et al. [12] present a comparison of the mean squared error (MSE) and R-squared (R^2) to MLP, RNN, and

RNN + Wavelet decomposition for wind speed forecasting. The Wavelet families applied to wind speed data decomposition were bior3.9 level 3, coif5 level 3, db7 level 3, db8 level 5, db9 level 7, dmey level 3, and sym7 level 3. The work presents that the RNN + dmey Wavelet decomposition has the best result. Multi-step prediction intervals are 1 h to 12 h ahead and the site is in Brazil. Already in Liu et al. [56] is showed that discrete Meyer Wavelet provides the best results among all the included 17 mother Wavelet functions. These mother Wavelet functions include the haar; the db4, db6, and db10; the coif1, coif2, coif3, coif4, and coif5; the sym2, sym3, sym4, sym5, sym6, sym7 and sym8, and the dmey. Multi-step prediction intervals are 1 h to 7 h ahead and the sites are in China. Then, the results published empirically in the literature showed that the discrete Meyer is the most efficient when compared to the other Wavelet families. Zucatelli et al. [13] study a new methodology for improving forecast accuracy of wind speed using artificial neural network (ANN) and Wavelet packet decomposition. The authors performed research and statistical analysis in a non-empirical way to previously assess the accuracy of the Wavelet function. Performance evaluation of Wavelet packet decomposition applying 48 different mother Wavelet functions was presented. Multi-step prediction intervals are 1 h to 6 h ahead and the sites are in Brazil. The best statistical analysis was RNN + discrete Meyer Wavelet. In this context, Table 3 shows a literature review on hybrid wind forecasting models using AI and Wavelet packet decomposition (WPD).

Document Title	Authors	Reference year
Data mining-assisted short-term wind		
speed forecasting by Wavelet packet	Vu et el [57]	2019
decomposition and Elman neural	i u et al. [57]	2018
network		
A novel wind speed prediction method:		
Hybrid of correlation-aided DWT,	Jiang et al. [58]	2018
LSSVM and GARCH		
Smart wind speed forecasting approach		
using various boosting algorithms, big	Li et al. [59]	2019
multi-step forecasting strategy		
A novel two-stage deep learning wind	Lin et al [60]	2010
speed forecasting method with adaptive		2019

Table 3. Literature review on hybrid wind forecasting model using AI + WPD.

multiple error corrections and bivariate Dirichlet process mixture model		
A review and discussion of decomposition-based hybrid models for wind energy forecasting applications	Qian et al. [61]	2019
Short-term wind speed forecasting in tropical region using Wavelets and artificial intelligence	Zucatelli et al. [12]	2019
Multi-step wind speed forecasting model based on Wavelet matching analysis and hybrid optimization framework	Liu et al. [56]	2020
Nowcasting prediction of wind speed using computational intelligence and Wavelet in Brazil	Zucatelli et al. [13]	2020

No studies were found in the literature that investigates the prediction 1 h to 6 h (nowcasting) of wind power and wind power ramp more than 100.0 m high applying computational intelligence and Wavelet decomposition through weather data recorded in anemometer in the tropical and subtropical regions in South America (Brazil and Uruguay are countries have the highest wind energy capacity). Therefore, this work comes to contribute with a new investigation on the forecast of wind power and forecast of wind power ramps.

3. Methodology

In this work, the statistical indicators employed to analyze the results are the root-meansquare error (RMSE), R-Squared (or R²), and Pearson's correlation coefficient (*r* or Pearson's *r*). Pearson is the measurement of the strength of the relationship between two variables and their association with each other. The *Factor of 2* applied in this work, in other words, is a fraction of data [%] for $0.5 \le$ (simulated wind speed / observed wind speed) ≤ 2.0 . An explanation of these statistical indicators is provided in [6]. The best results are expected to have values near to zero for the RMSE and near to 1 in the indices *Factor of 2*, *r* and R².

The AI model and WPD were developed in Matlab. The core configuration of the personal computer includes Intel Core i7-7500U processors running at 2.90 GHz, and a 64-bit system with 8 GB of RAM. The time series of wind speed used in this study were obtained

from towers equipped with anemometers at heights of 100.0 m, 120.0 m, and 150.0 m in Brazil, and in Uruguay with measurements taken at 81.8 m and 101.8 m which are representative of the vertical wind energy profile. To perform the training and validation of ANN, weather data (e.g., wind speed, wind direction, pressure, temperature, and humidity) was applied. The computational simulation for wind speed forecasting followed the methodology using AI and WPD adopted by Zucatelli et al. [13]. The ANN was trained to perform the forecasting of 1 h ahead, and then, using it, the trained network was applied to recursively infer the forecasting for the next hours of the wind speed. After this procedure, the wind power and the wind power ramp were predicted as presented in Figure 4.



Figure 4. Flowchart of the Wavelet decomposition strategy (adapted from [46]).

The best ANN (RNN + WPD) configurations for sites in Brazil (tropical region) were analyzed in [13], and the best ANN (RNN + WPD) configurations for Uruguay were applied 3 layers for 81.8 m (1 input layer with 8 nodes, 1 hidden layer with 1 neuron, and 1 output layer with 1 node), and 4 layers for 101.8 m (1 input layer with 8 nodes, 2 hidden layers with 3 neurons in first and 1 neuron in second layer, and 1 output layer with 1 node) using Levenberg– Marquardt algorithm, and hyperbolic tangent function was used as the activation function (these topologies were the best configurations for Colônia Eulacio, subtropical region). In this case, 70% of the subtropical dataset was used to train and validate the ANN, while 30% were applied in the test. Table 4 shows the geographic information of the sites. Table 5 presents the location of the anemometric towers analyzed. Figure 5 shows the location of the Esplanada, Mucugê, and Mucuri towers in Brazil, a humid tropical region. Figure 6 presents the location of the Colônia Eulacio tower in Uruguay, a humid subtropical region. Table 6 presents the time interval of data recorded by anemometers. The state of Bahia (564,760.427 km² of territorial extension) has a larger territorial unit area than European countries, such as Spain (505,990 km²), Sweden (450,295 km²), and Germany (357,386 km²). Thus, these municipalities represent well the climate and relief variability of the state of Bahia.

Location (site) Termiterial area		Characteristic	Characteristic	
Location (site)	Terniorial area	biome	climate	
		Atlantic Forest,		
Bahia – Brazil	564.760,427 km²	caatinga, and	Humid tropical	
		cerrado		
Soriano Umuquay	9.008 km²	Temperate	Humid subtropical	
Soriano – Oruguay		grassland	Tunna subtropical	

Table 4. Geographic information of the regions in Brazil and Uruguay.

Table 5. Location of the analyzed anemometric towers.

Site	Latitude	Longitude	Terrain elevation [m]	Anemometer height [m]			
				Ι	II	III	IV
Esplanada	11°47'45" S	37°56'42'' W	140.0	-	100.0	120.0	150.0
Mucugê	13°00'18" S	41°22'15" W	984.0	-	100.0	120.0	150.0
Mucuri	18°05'09" S	39°33'03" W	7.0	-	100.0	120.0	150.0
Colônia Eulacio	33°16'00" S	57°30'60" W	100.0	81.8	101.8	-	-



Figure 5. Location of the Esplanada, Mucugê, and Mucuri tower in Brazil, humid tropical regions.



Figure 6. Location of the Colônia Eulacio tower in Uruguay, humid subtropical region.

Table 6. Time interval of data recorded by anemometers.

Site / anemometer height	Recorded hours	Reference period
--------------------------	----------------	------------------

Esplanada: 100.0 m, 120.0	744 h	04/28/2016	at	9:00	a.m.	to	
m, and 150.0 m	/44 11	05/29/2016 at 8:00 a.m.					
Mucugê: 100.0 m, 120.0 m,	744 h	09/07/2016	at	12:00	a.m.	to	
and 150.0 m	/44 11	10/07/2016 a	t 11:0	00 p.m.			
Mucuri: 100.0 m, 120.0 m,	744 h	11/30/2015	at	2:00	p.m.	to	
and 150.0 m	/44 11	12/31/2016 a	t 1:00	0 p.m.			
Colônia Eulacio: 81.8 m,	9760 h	08/08/2014	at	12:00	a.m.	to	
and 101.8 m	8700 II	08/07/2015 a	t 11:0	00 p.m.			

The time series, frequency distributions, and a descriptive statistic regarding wind speed data at different sites in Brazil are shown in Zucatelli et al. [13], and in Colônia Eulacio, Soriano department, Uruguay is shown in Zucatelli et al. [6]. Table 7 presents the technical specifications of the considered wind turbines in this study. These technical specifications were collected by the portal for wind energy (*wind-turbine-models.com*).

Characteristics	Wind turbines					
Anemometric height [m]	81.8	100.0	101.8	120.0	150.0	
Rated power [kW]	1,500.0	2,000.0	2,000.0	4,500.0	5,000.0	
Hub height [m]	80.0	100.0	100.0	120.0	140.0	
Rotor diameter [m]	77.0	80.0	80.0	128.0	128.0	
Swept area [m ²]	3,848.0	5,027.0	5,027.0	12,868.0	12,868.0	
Number of blades	3	3	3	3	3	
Cut-in wind speed (<i>v</i> _{ci}) [m/s]	3.0	3.5	3.5	1.0	2.0	
Rated wind speed (v_R) [m/s]	11.8	12.0	12.0	12.0	14.0	
Cut-out wind speed (v_{co}) [m/s]	20.0	25.0	25.0	27.0	27.0	

Table 7. Technical specifications of the wind turbines.

Wind power is the flux of wind energy through an area of interest. Consider an area element A $[m^2]$ and flow of magnitude v [m/s] through this area (Figure 7):


Figure 7. Schematics of airflow at velocity v through area A.

If density and velocity are constant, the mass flow rate is derived by multiplying the volume flow rate by the density of the flow ρ [kg/m³] and is equal to the mass m [kg] of that cylinder divided by unit time t [s], resulting the Equation 1:

$$\frac{dm}{dt} = \rho A v \tag{1}$$

Wind energy is the energy content of airflow due to its motion. This type of energy is called kinetic energy E [kg.m²/s² or Joule] and is given by Equation 2:

$$E = \frac{1}{2}mv^2 \tag{2}$$

Wind power *P* [Joule/s or Watt], given by Equation 3, is the rate of kinetic energy flow:

$$P = \frac{dE}{dt} = \frac{1}{2}v^2 \frac{dm}{dt}$$
(3)

Then, the resultant equation for wind power is the Equation 4. This is a fundamental equation in wind power analysis:

$$P = \frac{1}{2}\rho A v^3 \tag{4}$$

In the context of wind power (or turbine power capture), an algebraic equation of degree n according to the power curve of the wind turbine between the cut-in and rated speed or the rated speed and cut-out speed, can be formed as shown in Equation (5) to predict the wind energy output from the wind turbine:

$$P_{i}(v) = \begin{cases} 0, & \text{if } v < v_{ci} \\ 1/2 (\rho \pi r^{2} v^{3} C_{p} \eta), & \text{if } v_{ci} \leq v < v_{R} \\ P_{R}, & \text{if } v_{R} \leq v < v_{co} \\ 0, & \text{if } v \geq v_{co} \end{cases}$$
(5)

where v is the wind speed [m/s]; v_{ci} is the cut-in speed [m/s]; v_R is the rated speed [m/s]; v_{co} is the cut-out speed [m/s]; P_R is the rated power [W]; $P_i(v)$ is the power generated in the related wind speed [W]; ρ is the density of the fluid [kg/m³]; r is the radius [m]; C_p is the coefficient of power; η is the efficiency of the generator set – mechanical and electrical power transmission. In this work $\rho = 1.225$ kg/m³; $C_p = 0.50$; $\eta = 0.95$.

The ascending ramps are characterized by an increase in wind energy, which can result from phenomena such as systems of intense low pressure (or cyclones), low-level jets, storms, gusts of wind, or similar climatic phenomena. Downhill ramps occur when there is a reduction in wind energy (events that usually occur with the rapid easing of a pressure gradient; or the passage of a local pressure couplet, that is, an area of high pressure located adjacent to an area of low pressure) or when high-speed winds cause the turbines to reach cut limits and be shut down to protect the wind turbine from structural damage [62]. To be considered a ramp event, it is assumed that the minimum duration is 1 h in Potter et al. [63]; however, Kamath [64] studies events at intervals of 5 min to 60 min. The magnitude of a ramp event is typically represented by the percentage of the wind farm's nominal energy.

To deal with an "up ramp" event, the wind power producer can shut down the turbines to avoid excessive energy production that cannot be compensated for by a sudden drop in the thermal generation or can increase its generation. In agreement with the system operator. In the latter case, utilities can negotiate the costs of non-renewable energy by purchasing cheaper and renewable wind energy. In a "down ramp" event, the system operator can turn on hydroelectric units or, if this procedure does not generate enough energy to meet demand or is not available, the operator can use non-energy turbines renewable to meet demand. If these measures are not enough, the load cut must be adopted – a scenario that the system operators try to avoid [65]. In this context, four types of significant ramps are defined based on Zhang et al. [66]:

- a) the magnitude of the ramp only;
- b) magnitude and duration of the ramp;
- c) rate of change of the ramp; and
- d) direction, magnitude, and duration of the ramp.

The first definition of a significant ramp is based on the magnitude of the change in wind energy. A significant ramp is defined as the change in the production of wind energy above 30% of the installed wind capacity [66], expressed as Equation (6):

$$|P(t + \Delta t) - P(t)| > P_{val} \tag{6}$$

where P(t) is the wind power produced at time t; Δt is the ramp duration, which is not specified in the significant ramp definition i; and P_{val} is the predefined limit value, which is 30% of the wind capacity.

The second definition defines a significant ramp based on the magnitude and duration of the change in wind energy. The significant ramp is defined as the variation in wind energy production greater than 25% of the installed wind capacity and occurs in a time interval of 4 h or less [66], which is also expressed in Equation (6). In the equation, the ramp duration, Δt , is less than or equal to 4 h; and the limit value, P_{val} , is 25% of the installed wind capacity.

The third definition of significant ramps is based on the rate of change in wind energy. A significant ramp rate is defined as the rate of change in wind energy production greater than 10% of installed wind capacity [66], expressed as Equation (7):

$$\frac{|P(t+\Delta t)-P(t)|}{\Delta t} > R_{val} \tag{7}$$

where R_{val} is the predefined limit value of the rate of change of the output wind power.

The fourth definition of significant ramps is based on the change in direction, magnitude, and duration of wind energy production. An increasing ramp is defined as the change in wind energy greater than 20% of the wind capacity in a period of 4 h or less, and a significant reduction is defined as the change in wind energy greater than 15% of the wind capacity in a period of 4 h or less [66]. Equation (8) and (9) represents this definition:

$$[P(t + \Delta t) - P(t)] > P_{val}^u \tag{8}$$

$$[P(t + \Delta t) - P(t)] < -P_{val}^d \tag{9}$$

where P_{val}^{u} and P_{val}^{d} represent the up ramp and down ramp limit values, respectively.

In this work, the fourth definition was used in a period of 6 h or less (what is not found in the literature). The Equations (10) and (11) are formulas analogous to (8) and (9) and show that significant up ramp is defined in this study as the change in wind power that is greater than $0.20(P_R)$ and a significant down ramp is defined as the change in wind power that is greater than $0.15(P_R)$,

$$up \ ramp \ if \qquad [P(t + \Delta t) - P(t)] > 0.20(P_R)$$
 (10)

down ramp if
$$[P(t + \Delta t) - P(t)] < -0.15(P_R)$$
(11)

where P(t) is the wind power output at time t [W]; Δt is the duration of the ramp [h]; P_R is the installed wind capacity or rated power [W].

Results and discussions are presented in the next section applying the scientific methodology explained here.

4. Results and discussion

The results presented in this section report the application of all computational methodology applied in Zucatelli et al. [13] to forecast wind speed and then to predict wind power and wind power ramp using weather data collected in Brazil and Uruguay. Liu et al. [67] explain that short-term forecasts (or nowcasting, 1 h to 6 h ahead) are more practical and versatile in real applications. The wind speed predicted for Esplanada, Mucugê, and Mucuri applying AI + WPD are presented in Zucatelli et al. [13], and the wind speed predicted for Colônia Eulacio using this methodology are showed in Table 8. Table 8 refers to wind speed predicted 1 to 6 h ahead, i.e., the contrast between RMSE, Pearson, and Factor of 2 for Colônia Eulacio, Uruguay, using a hybrid model by recurrent neural network and discrete approximation of Meyer Wavelet.

			Time hori	zon	
Site	Height [m]	Statistics	1 h	3 h	6 h
		RMSE [m/s]	0.76	1.27	2.03
	81.8	Pearson	0.96	0.88	0.69
Colônia		Factor of 2 [%]	99.09	97.52	92.18
Eulacio		RMSE [m/s]	0.79	1.38	2.16
	101.8	Pearson	0.96	0.89	0.70
		Factor of 2 [%]	99.31	97.71	92.10
Central tendency of the data / Time horizon			1 h	3 h	6 h
mean RMSE [m/s]			0.78	1.33	2.10
mean Pearson			0.96	0.89	0.70
mean Factor of 2 [%]			99.20	97.62	92.14

Table 8. Wind speed predicted: the contrast between RMSE, Pearson, and Factor of 2 for Colônia Eulacio, Uruguay, using AI + discrete approximation of Meyer Wavelet.

When interpreting the values recorded in Table 8, the statistical results for the subtropical region are consistent with the wind speed predicted in Zucatelli et al. [13] for the tropical region 6 h ahead (e.g. in Esplanada the mean RMSE was 1.60 m/s; in Mucugê was 2.26 m/s, and in Mucuri was 1.71 m/s). This indicates that the model can efficiently learn the different wind patterns and thus accurately predict the wind speed in tropical and subtropical regions. The average value of RMSE recorded in this work is better than the average value recorded by Zucatelli et al. [6] which was 2.58 m/s (6 h ahead; anemometer at 101.8 m and 81.8 m) applying feedforward artificial neural network multilayer perceptron (MLP).

Figure 8 a) to h) shows the results achieved from Wavelet decomposition comparison. It is a non-empirical way to previously assess the accuracy of the Wavelet function. Performance evaluation of Wavelet packet decomposition applying 48 different mother Wavelet functions was presented. The Wavelet discrete Meyer family (or dmey) demonstrates greater precision in the decomposition of the wind speed signals collected in Colônia Eulacio (Uruguay), i.e., RMSE = 0.50 m/s and R-squared = 0.97. The second-best function for decomposing the wind speed signal was Symlet (improved version of the Daubechies function), followed by the Daubechies family. Therefore, as found in the analysis of tropical sites published by Zucatelli et al. [13] this Wavelet family is the best to wind signal filter.











c) Reverse biorthogonal

sym6

sym8

sym10 . sym13 sym20 sym25 sym30 sym35

sym16

Wavelet Type & Order

d) Coiflet

RMSE [m/s], Uruguay, 101.80 m R-squared, Uruguay, 101.80 m

0.974

0.972 🛔

0.970

0.968

0.966

0.964

0.962

0.960

b) Biorthogonal





sym2 sym4

0.750 0.700 0.650 0.550 0.550 0.450 0.400 0.350 0.250 0.250 0.250 0.150 0.150 0.100 0.050

Original time series versus signal approximation A1: RMSE [m/s]





Figure 8. Wavelet decomposition using subtropical data.

Thus, it is proven that the Wavelet dmey is the most accurate in the decomposition of temporal wind signals, whether using signals from tropical or subtropical regions. Table 9 shows the results of statistical analyses of wind power forecasting and Table 10 presents the results of statistical analyses of wind power ramp forecasting in the tropical and subtropical sites. The arithmetic mean of the results shows the same math behavior in all anemometers heights in the tropical and subtropical sites for the prediction of wind power and the prediction of the wind power ramp events.

	Site A	Anemometer	Time horizon					
Region		height [m]	1 h		3 h		6 h	
		noight [m]	R ²	r	\mathbb{R}^2	r	\mathbb{R}^2	r
	Esplanada	100.0	0.71	0.84	0.40	0.63	0.20	0.45
	Esplanada	120.0	0.69	0.83	0.32	0.56	0.22	0.47
	Esplanada	150.0	0.68	0.82	0.35	0.59	0.20	0.45
	Mucugê	100.0	0.92	0.96	0.72	0.85	0.56	0.76
	Mucugê	120.0	0.89	0.94	0.68	0.82	0.41	0.64
	Mucugê	150.0	0.88	0.94	0.67	0.82	0.40	0.64
	Mucuri	100.0	0.90	0.95	0.76	0.87	0.73	0.85
ical	Mucuri	120.0	0.84	0.92	0.68	0.82	0.71	0.84
Irop	Mucuri	150.0	0.84	0.91	0.71	0.84	0.57	0.75
	Colônia	81.8	0.87	0.93	0.71	0.84	0.42	0.65
Subtropical	Eulacio	01.0	0.07	0.75	0.71	0.04	0.72	0.05
	Colônia	101.8	0.89	0.94	0.72	0.85	0.44	0.66
	Eulacio	101.0	0.07	0.74	0.72	0.05	0.77	0.00
Central tendency of the data		0.83	0.91	0.61	0.77	0.44	0.65	

Table 9. Wind power forecasting: results of statistical analyses (R-squared and Pearson's r correlation).

Table 10. Wind power ramp forecasting ($\Delta t = 6 h$): results of statistical analyses (R-squared and Pearson's *r* correlation).

Region	Site	Anemometer height [m]	Time horizon					
			1 h		3 h		6 h	
			\mathbb{R}^2	r	\mathbb{R}^2	r	\mathbb{R}^2	r

	Esplanada	100.0	0.64	0.80	0.29	0.54	0.11	0.33
	Esplanada	120.0	0.61	0.78	0.20	0.44	0.12	0.34
	Esplanada	150.0	0.54	0.74	0.18	0.42	0.08	0.28
	Mucugê	100.0	0.85	0.92	0.45	0.67	0.15	0.39
	Mucugê	120.0	0.78	0.88	0.40	0.63	0.002	0.05
Tropical	Mucugê	150.0	0.76	0.87	0.40	0.63	0.03	0.17
	Mucuri	100.0	0.91	0.96	0.73	0.85	0.66	0.81
	Mucuri	120.0	0.85	0.92	0.62	0.79	0.69	0.83
	Mucuri	150.0	0.86	0.92	0.74	0.86	0.60	0.78
	Colônia	81.8	0.78	0.88	0.42	0.65	0.02	0.14
Subtropical	Eulacio	01.0	0.70	0.00	0.72	0.05	0.02	0.14
	Colônia	101.8	0.82	0.90	0.47	0.68	0.06	0.24
	Eulacio	101.0	0.02	0.20	5.17	0.00	0.00	0.21
Central tendency of the data		0.76	0.87	0.45	0.65	0.23	0.40	

It is noticed that as the forecast time horizon is increased from 1 h to 6 h, the precision of the predicted values when compared with the original series is reduced. This fact occurs both in tropical and subtropical sites, and this was expected when using statistical inference and this is reported in Zucatelli et al. [6, 13]. However, the quality of the forecast of the wind power output up to 6 h ahead together with the forecast of wind power ramp lasting 6 h (and in the same time horizon) proved to be effective and of low computational cost. Low-cost forecasting techniques for both wind power and wind power ramps are important for operators of the national electrical system. The graphical results show the original and predicted time series, either for wind power or for wind power ramp.

This short-term forecasting research (nowcasting) applying hybrid models (AI + WPD) is very important, mainly because, in Brazil, the electricity trading chamber manages the energy price panels (R\$/MWh) per hour (settlement price of the differences – PLD, or "preço de liquidação de diferenças" in Portuguese) in each region of the country [68]. This contributes to the anticipation of possible impacts of the adoption of the hourly price, calculated ex-ante (the previous day) by the short-term hydrothermal dispatch model – DESSEM, or "modelo de despacho hidrotérmico de curto prazo" in Portuguese, based on predicted information [68]. The DESSEM model was developed by the electric energy research center – CEPEL and seeks to minimize the total cost of operation. By solving optimization problems, DESSEM can

rationalize the use of thermal generation and operate the system more efficiently over the hours of the day, contributing to the reduction of operating costs [68].

With the increase of the forecast horizon, the accuracy of the forecast is reduced, but this was to be expected. The hybrid model proposed involving computational intelligence and signal processing applies statistical inference and, therefore, over time the error between the real value and the predicted value is increased. For forecasting wind energy and wind ramp from 1 h to 6 h ahead, the model proved to be applicable and of low computational cost in view of the average training time of the ANN. The presentation of statistical analysis for ramp prediction is new in the literature, as is the range of the phenomenon considered, which was 6 h. Simulation results show that the proposed method is more accurate than traditional methods for wind power and wind power ramp forecasting 6 h-ahead. Figures 9 to 12 show a) the wind power predicted and b) the wind power ramp predicted 1 h to 6 h, in Brazil at 100.0 m and in Uruguay at 101.8 m. The duration of the wind power ramp in this work is 6 h. For the subtropical region of Uruguay with data measured at 81.8 m of anemometric height, concerning the wind ramp limits (up and down), the lower limit is -225 kW and the upper limit is 300 kW; for 101.8 m the limits are -300 kW and 400 kW. For the tropical region of Brazil, the limits for 100 m are -300 kW and 400 kW; for 120 m it is -675 kW and 900 kW; finally, for 150 m there are the limits -750 kW and 1000 kW. Variations in wind power within this limit are in the control and management range for the effective maintenance of wind farms. Predicting the phenomenon and the possibility of an energy ramp over some time is important for maintaining the equipment in full operation and maintaining the quality of the wind power generation service to supply the electricity grid.





Figure 9. a) Wind power predicted and the b) wind power ramp predicted, both in Mucuri.





Figure 10. a) Wind power predicted and the b) wind power ramp predicted, both in Mucugê.





Figure 11. a) Wind power predicted and the b) wind power ramp predicted, both in Esplanada.





Figure 12. a) Wind power predicted and the b) wind power ramp predicted, both in Colônia Eulacio.

In all the cases studied, with an increase in anemometric height, there was an increase in the values of wind power and wind power ramp. The highest value of wind power recorded in Mucuri (tropical site) with anemometric data of 100 m was approximately 2,518 kW; for data collected at 120 m it was 6,347 kW, and for data recorded at 150 m height it was 10,151 kW. As values of the wind power ramp event for 100 m, the maximum value was 2,346 kW and the minimum recorded value was -1,632 kW, approximately. For 120 m height, the maximum and minimum values were 5,550 kW and -4,175 kW, respectively. For 150 m, 9,513 kW and -6,962 kW were recorded.

In Mucugê (tropical site) with anemometric data of 100 m the highest value of wind power recorded was approximately 2,505 kW; for data collected at 120 m it was 6,398 kW, and for data recorded at 150 m height it was 9,329 kW. As values of the wind power ramp event for 100 m, the maximum value was 1,943 kW and the minimum value was -1,991 kW, approximately. For 120 m height, the maximum and minimum values were 4,811 kW and -5,284 kW, respectively. For 150 m, 7,227 kW and -7,369 kW were recorded.

With anemometric data of 100 m the highest value of wind power recorded in Esplanada (tropical site) was approximately 1,026 kW; for data collected at 120 m it was 3,220 kW, and for data recorded at 150 m height it was 4,555 kW. As values of the wind power ramp event for 100 m, the maximum value was 906 kW and the minimum recorded value was -831 kW, approximately. For 120 m in height, the maximum and minimum values were 2,740 kW and -2,549 kW, respectively. For 150 m, there were 3,402 kW and -3,502 kW.

The highest value of wind power recorded in Colônia Eulacio (subtropical site) with anemometric data of 81.8 m was approximately 2,197 kW; for data collected at 101.8 m it was 2,523 kW. As values of the wind energy ramp event for 81.8 m, the maximum value was 2,054

kW and the minimum recorded value was -1,983 kW, approximately. For 101.8 m in height, the maximum and minimum values were 2,331 kW and -2,466 kW, respectively.

Graphical analyzes show the feasibility of using this hybrid computational methodology (computational intelligence and Wavelet decomposition) for forecasting up to 6 h ahead (nowcasting) of wind speed, wind power, and wind power ramps analyzed in a time interval equal to 6 h. The wind power ramp graphs are plotted with the upper and lower limit, and these indicate the outliers, that is, the records of the wind power ramp up and the ramp down. This forecast analysis of wind ramps over a 6 h interval is important and fundamental for the good management of nowcasting projects in Brazil and Uruguay. The project reported here contributes to other countries also investing scientific efforts in expanding the analysis of wind ramps using computational intelligence because it presents low computational cost when compared to weather models.

It is noticed the low variability of the results recorded in the tables above and this shows that computational models applying AI by supervised deep learning are applicable in tropical and subtropical regions, as well as at different anemometric heights. The statistical results of this work demonstrate that the application of computational intelligence (AI, supervised deep learning) is a viable alternative for the forecasting of wind speed, wind power, and thus wind power ramp mainly because of the low computational cost. However, an ANN configuration that is appropriate for the forecasting must be selected, and the data fed to the model must be quantitatively and qualitatively analyzed because these variables directly impact the prediction results.

5. Conclusions and future works

The main objective of this study was to explore supervised deep learning by recurrent neural network and Wavelet decomposition following a scientific methodology for error analysis before applying the input data to neural networks to nowcast wind power and wind power ramp in the tropical and subtropical regions of South America. The innovative aspect of this paper is that there is no previous work applying this hybrid model proposed by computational intelligence and Wavelet targeting wind power and wind power ramp nowcasting for such heights in a tropical and subtropical region, specifically for South America. The wind power ramp forecasting is important for wind power operators because an increase of wind power is characterized by the upward ramps, which might result from cyclones, wind gusts, low-level jets, thunderstorms, or similar weather phenomena. The downward ramps are events that generally occur with the rapid slackening of wind speed, passage of a local pressure couplet, or rapid slackening of a pressure gradient. Therefore, wind farms and system operators need to develop procedures that satisfy the electricity demand.

The method proposed for the wind prediction in the present research makes an analysis of the Wavelet decomposition error before the application of the filtered signals how to input in the artificial neural network. It has been proven in the face of 48 different functions that the discrete Meyer wavelet function (dmey) is the most efficient to decompose temporal wind signals in tropical and subtropical regions, followed by Symlet (improved version of the Daubechies function), and the Daubechies family, respectively. The mean value of R^2 for wind power forecasting 1 h ahead was equal to 0.83 and Pearson equal to 0.91 approximately. The statistical results of the wind power ramp event prediction were mean R² equal to 0.76 and Pearson was 0.87. With the exception of Esplanada, all other sites have above-average values. The results for wind power and wind power ramp forecasting 1 h to 6 h ahead using this hybrid model showed a good accuracy to be used as a powerful tool to help Brazil's and Uruguay's national grid operator for the energy supply. Then, this hybrid computational model proved to be efficient in tropical and subtropical regions when applying real technical specifications of commercial wind turbines (rated power, cut-in wind speed, rated wind speed, cut-out wind speed, for example) for each anemometric height. The results from the simulation did not diverge and followed the same behavior. This is because it could approximate this computational simulation using artificial intelligence and processing temporal signals to reality. In other words, the fact that this model predicts the output wind power and wind ramp using these technical specifications refers to the reality of operation and generation of energy in real wind farms.

Recently, there has been a great interest in the development and implementation of new technological solutions applied to the industrial process using AI. Driven by the fourth industrial revolution (or Industry 4.0), industries have seen this as an opportunity to leverage their processes and products and make them more competitive, profitable, and attractive to both their investors and their customers. Therefore, the use of AI techniques applied to industry problems for pattern recognition, classification, time series prediction, natural language processing, search, and optimization, among others, has proved to be an excellent tool for the modernization industry, aiming at improvements in the production and management processes, leading to cost reduction, increase in added value and quality of products and services. As a suggestion for future work, the authors suggest simulating medium-term (seven days ahead) wind speed forecasting and medium-term wind power forecasting using this hybrid method that

is computational intelligence (gru, lstm, cnn, for example) and optimal subband tree structuring (or SB-TS) also called wavelet packet decomposition applying different functions.

Acknowledgments

The study is fully supported by the SENAI CIMATEC, in Bahia, Brazil. We also want to thank the FAPESB and *Administración Nacional de Usinas y Trasmisiones Eléctricas* (UTE) of Uruguay.

Conflict of interest

Disclosure statement – We wish to confirm that there are no known conflicts of interest associated with this publication and there has been no significant financial support for this work that could have influenced its outcome.

ORCID

Pedro Junior Zucatelli. https://orcid.org/0000-0002-6744-5376 Erick Giovani Sperandio Nascimento. https://orcid.org/0000-0003-2219-0290 Alex Álisson Bandeira Santos. https://orcid.org/0000-0001-9935-4084 Alejandro Mauricio Gutiérrez Arce. Davidson Martins Moreira. https://orcid.org/0000-0002-0902-5218

References

[1] E. Hache and A. Palle, "Renewable energy source integration into power networks, research trends and policy implications: A bibliometric and research actors survey analysis," Energy Policy, volume 124, january 2019, pages 23-35. DOI: https://doi.org/10.1016/j.enpol.2018.09.036

[2] S. G. Azevedo, M. Santos and J. R. Antón, "Supply chain of renewable energy: A bibliometric review approach," Biomass and Bioenergy, volume 126, july 2019, pages 70-83.
 DOI: https://doi.org/10.1016/j.biombioe.2019.04.022

[3] P. J. Zucatelli, A. P. Meneguelo, G. L. D. Chaves and M C. R. Tosta, "The application, required investments and operational costs of geological CO2 sequestration: a case study,"

Research, Society and Development, volume 8, issue 6, engineerings, 2019. DOI: https://doi.org/10.33448/rsd-v8i6.1023

[4] R. J. Matthew and D. A. Kumar, "Greenhouse gas emission abatement potential and associated costs of integrating renewable and low carbon energy technologies into the Canadian oil sands," Journal of Cleaner Production, volume 272, november 2020, 122820. DOI: https://doi.org/10.1016/j.jclepro.2020.122820

[5] F. Cucchiella and I. D'Adamo, "Issue on supply chain of renewable energy," Energy Conversion and Management, volume 76, december 2013, pages 774-780. DOI: https://doi.org/10.1016/j.enconman.2013.07.081

[6] P. J. Zucatelli, E. G. S. Nascimento, G. Y. R. Aylas, N. B. P. Souza, Y. K. L. Kitagawa, A. A. B. Santos, A. M. G. Arce and D. M. Moreira, "Short-term wind speed forecasting in Uruguay using computational intelligence," Heliyon, volume 5, issue 5, may 2019, e01664. DOI: https://doi.org/10.1016/j.heliyon.2019.e01664

[7] P. J. Zucatelli, E. G. S. Nascimento, A. A. B. Santos, A. M. G. Arce and D. M. Moreira,
"Study of the Wind Speed Forecasting Applying Computational Intelligence". Rijeka:
IntechOpen, 2019. DOI: 10.5772/intechopen.89758. Available:
https://www.intechopen.com/online-first/study-of-the-wind-speed-forecasting-applying-computational-intelligence

[8] P. J. Zucatelli, E. G. S. Nascimento, A. M. G. Arce and D. M. Moreira, "An Interdisciplinary Machine Learning Approach for Wind Speed Forecasting," J. Systemics, Cybern. Informatics, vol. 19, no. 1, pp. 211–236, 2021. Available: http://www.iiisci.org/journal/sci/Abstracts.asp?var=&next=

[9] Merriam Webster Dictionary. "Dictionary: Artificial Intelligence," 2020. Available from: https://www.merriam-webster.com/dictionary/artificial%20intelligence

[10] F. Chollet, "Deep Learning with Python," Manning Publications Co. ISBN 9781617294433. 1st ed. 493 p. (2018). Printed in the United States of America.

[11] J. W. Taylor; P. E. McSharry; R. Buizza, "Wind Power Density Forecasting Using Ensemble Predictions and Time Series Models," IEEE Transactions on Energy Conversion (Volume: 24, Issue: 3, Sept. 2009). DOI: https://doi.org/10.1109/TEC.2009.2025431

[12] P. J. Zucatelli, E. G. S. Nascimento, A. M. G. Arce and D. M. Moreira, "Short-term wind speed forecasting in tropical region using Wavelets and artificial intelligence," p. 365-372. In: V International Symposium on Innovation and Technology (SIINTEC). São Paulo: Blucher, 2019. ISSN 2357-7592. DOI: 10.5151/siintec2019-46. Available from: https://www.proceedings.blucher.com.br/article-list/siintec2019-324/list

[13] P. J. Zucatelli, E. G. S. Nascimento, A. A. M. Santos and D. M. Moreira, "Nowcasting prediction of wind speed using computational intelligence and Wavelet in Brazil," International Journal for Computational Methods in Engineering Science and Mechanics, volume 21, issue 5, 2020. DOI: https://doi.org/10.1080/15502287.2020.1841335

[14] Z. Niu, Z. Yu, W. Tang, Q. Wu, M. Reformat, "Wind power forecasting using attentionbased gated recurrent unit network," Energy, Volume 196, 1 April 2020, 117081. DOI: https://doi.org/10.1016/j.energy.2020.117081

[15] J. Duan, P. Wang, W. Ma, X. Tian, S. Fang, Y. Cheng, Y. Chang, H. Liu, "Short-term wind power forecasting using the hybrid model of improved variational mode decomposition and Correntropy Long Short -term memory neural network," Energy, Volume 214, 1 January 2021, 118980. DOI: https://doi.org/10.1016/j.energy.2020.118980

[16] X. Zhao, N. Jiang, J. Liu, D. Yu, J. Chang, "Short-term average wind speed and turbulent standard deviation forecasts based on one-dimensional convolutional neural network and the integrate method for probabilistic framework," Energy Conversion and Management, Volume 203, 1 January 2020, 112239. DOI: https://doi.org/10.1016/j.enconman.2019.112239

[17] I. Gunnarsdottir, B. Davidsdottir, E. Worrell, S. Sigurgeirsdottir, "Review of indicators for sustainable energy development," Renewable and Sustainable Energy Reviews, Volume 133, November 2020, 110294. DOI: https://doi.org/10.1016/j.rser.2020.110294

[18] Y. Chen, S. Zhang, W. Zhang, J. Peng and Y. Cai., "Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting," Energy Conversion and Management, volume 185, april 2019, pages 783-799. DOI: https://doi.org/10.1016/j.enconman.2019.02.018

[19] H. Demolli, A. S. Dokuz, A. Ecemisa and M. Gokcek, "Wind power forecasting based on daily wind speed data using machine learning algorithms," Energy Conversion and Management, volume 198, october 2019, 111823. DOI: https://doi.org/10.1016/j.enconman.2019.111823

[20] A. Dupré, P. Drobinski, B. Alonzo, J. Badosa, C. Briard and R. Plougonven, "Sub-hourly forecasting of wind speed and wind energy," Renewable Energy, volume 145, january 2020, pages 2373-2379. DOI: https://doi.org/10.1016/j.renene.2019.07.161

[21] P. J. Zucatelli, E. G. S. Nascimento, A. M. G. Arce and D. M. Moreira, "Short-Range Wind Speed Predictions in Subtropical Region Using Artificial Intelligence," Journal of Systemics, Cybernetics and Informatics, volume 17 - number 4 - year 2019. ISSN: 1690-4524. Available from: http://www.iiisci.org/journal/sci/Abstracts.asp?var=&previous=ISS1904 [22] G. Wang, R. Jia, J. Liu and H. Zhang, "A hybrid wind power forecasting approach based on Bayesian model averaging and ensemble learning," Renewable Energy, volume 145, january 2020, pages 2426-2434. DOI: https://doi.org/10.1016/j.renene.2019.07.166

[23] X Zhao, N Jiang, J Liu, D Yu, J Chang. (2020). Short-term average wind speed and turbulent standard deviation forecasts based on one-dimensional convolutional neural network and the integrate method for probabilistic framework. Energy Conversion and Management Volume 203, 1 January 2020, 112239. DOI: https://doi.org/10.1016/j.enconman.2019.112239 [24] E. Cadenas, W. Rivera, R. Campos-Amezcua and C. Heard, "Wind speed prediction using a univariate ARIMA model and a multivariate NARX model," Energies, 2016, 9(2). DOI: https://doi.org/10.3390/en9020109

[25] J. Dowell and P. Pinson, "Very-short-term probabilistic wind power forecasts by sparse vector autoregression," IEEE Transactions on Smart Grid, volume: 7, issue: 2, march 2016, pages 763–770. DOI: https://doi.org/10.1109/TSG.2015.2424078

[26] J. M. Lima, A. K. Guetter, S. R. Freitas, J. Panetta and J. G. Z. de Mattos, "A meteorological-statistic model for short-term wind power forecasting," Journal of Control, Automation and Electrical Systems, 2017, volume 28, issue 5, pages 679–691. DOI: https://doi.org/10.1007/s40313-017-0329-8

[27] J. Wang, Q. Zhou and X. Zhang, "Wind power forecasting based on time series ARMA model," IOP Conference Series: Earth and Environmental Science. 2018; 199:022015. DOI: https://doi.org/10.1088/1755-1315/199/2/022015

[28] C. Robles-Rodriguez and D. Dochain, "Decomposed threshold armax models for short- to medium-term wind power forecasting," IFAC-PapersOnLine, volume 51, issue 13, 2018, pages 49-54. DOI: https://doi.org/10.1016/j.ifacol.2018.07.253

[29] N. S. Pearre and L. G. Swan, "Statistical approach for improved wind speed forecasting for wind power production," Sustainable Energy Technologies and Assessments, volume 27, june 2018, pages 180-191. DOI: https://doi.org/10.1016/j.seta.2018.04.010

[30] C. Li, S. Lin, F. Xu, D. Liu and J. Liu, "Short-term wind power prediction based on data mining technology and improved support vector machine method: a case study in northwest China," Journal of Cleaner Production, volume 205, 20 december 2018, pages 909-922. DOI: https://doi.org/10.1016/j.jclepro.2018.09.143

[31] G. Sun, C. Jiang, P. Cheng, Y. Liu, X. Wang, Y. Fu and Y. He, "Short-term wind power forecasts by a synthetical similar time series data mining method," Renewable Energy, volume 115, january 2018, pages 575-584. DOI: https://doi.org/10.1016/j.renene.2017.08.071

[32] K. Wang, X. Qi, H. Liu and J. Song, "Deep belief network based k-means cluster approach for short-term wind power forecasting," Energy, volume 165, part a, 15 december 2018, pages 840-852. DOI: https://doi.org/10.1016/j.energy.2018.09.118

[33] D. Zheng, Y. K. Semero, J. Zhang and D. Wei, "Short-term wind power prediction in microgridsusing a hybrid approach integrating genetic algorithm, particle swarm optimization, and adaptive neuro-fuzzy inference systems," IEEJ Transactions on Electrical and Electronic Engineering, volume13, issue 11, november 2018, pages 1561-1567. DOI: https://doi.org/10.1002/tee.22720

[34] R. Yu, J. Gao, M. Yu, W. Lu, T. Xu, M. Zhao, J. Zhang, R. Zhang and Z. Zhang, "LSTM-EFG for wind power forecasting based on sequential correlation features," Future Generation Computer Systems, volume 93, april 2019, pages 33-42. DOI: https://doi.org/10.1016/j.future.2018.09.054

[35] Y. Qin, K. Li, Z. Liang, B. Lee, F. Zhang, Y. Gu, L. Zhang, F. Wu and D. Rodriguez, "Hybrid forecasting model based on long short term memory network and deep learning neural network for wind signal," Applied Energy, volume 236, 15 february 2019, pages 262-272. DOI: https://doi.org/10.1016/j.apenergy.2018.11.063

[36] X. Shi, X. Lei, Q. Huang, S. Huang, K. Ren and Y. Hu, "Hourly day-ahead wind power prediction using the hybrid model of variational model decomposition and long short-term memory," Energies 2018, 11, 3227. DOI: https://doi.org/10.3390/en11113227

[37] Y. Hong and C. L. P. P. Rioflorido, "A hybrid deep learning-based neural network for 24h ahead wind power forecasting," Applied Energy, volume 250, 15 september 2019, pages 530-539. DOI: https://doi.org/10.1016/j.apenergy.2019.05.044

[38] C. Wang, H. Zhang and P. Ma, "Wind power forecasting based on singular spectrum analysis and a new hybrid Laguerre neural network," Applied Energy, volume 259, 1 february 2020, 114139. DOI: https://doi.org/10.1016/j.apenergy.2019.114139

[39] F. A Eldali, T. M Hansen, S. Suryanarayanan and E. K. P. Chong, "Employing ARIMA models to improve wind power forecasts: a case study in ERCOT," 2016 North American Power Symposium (NAPS), Denver, CO, 2016, pp. 1-6. DOI: https://doi.org/10.1109/NAPS.2016.7747861

[40] D. B. de Alencar, C. de M. Affonso, R. C. L. de Oliveira, J. L. M. Rodriguez, J. C. Leite and J. C. R. Filho, "Different models for forecasting wind power generation: case study," Energies, 1976, 10(2017), pp. 1–1976:27. DOI: https://doi.org/10.3390/en10121976

[41] J. Ekström, M. Koivisto, I. Mellin, R. J. Millar and M. Lehtonen, "A statistical modeling methodology for long-term wind generation and power ramp simulations in new generation locations," Energies 2018, 11(9), 2442. DOI: https://doi.org/10.3390/en11092442

[42] A. S. Dokuz, H. Demolli, M. Gokcek and A. Ecemis, "Year-ahead wind speed forecasting using a clustering-statistical hybrid method," International Conference on Innovative Engineering Applications. 2018. p. 971–5. CIEA'2018. Available from: https://www.researchgate.net/publication/331963129

[43] C-D. Dumitru and A. Gligor, "Daily average wind energy forecasting using artificial neural networks," 10th International Conference Interdisciplinarity in Engineering, INTER-ENG 2016, 6–7 October 2016, Tirgu Mures, Romania. Procedia Engineering, volume 181, 2017, pages 829-836. DOI: https://doi.org/10.1016/j.proeng.2017.02.474

[44] J. Yan and T. Ouyang, "Advanced wind power prediction based on data-driven error correction," Energy Conversion and Management, volume 180, 15 january 2019, pages 302-311. DOI: https://doi.org/10.1016/j.enconman.2018.10.108

[45] S. Maroufpoor, H. Sanikhani, O. Kisi, R. C. Deo and Z. M. Yaseen. "Long-term modelling of wind speeds using six different heuristic artificial intelligence approaches," International Journal of Climatology. 2019; 2019:1–15. DOI: https://doi.org/10.1002/joc.6037

[46] S. Han, Y. Qiao, J. Yan, Y. Liu, L. Li and Z. Wang, "Mid-to-long term wind and photovoltaic power generation prediction based on copula function and long short term memory network," Applied Energy, volume 239, 1 april 2019, pages 181-191. DOI: https://doi.org/10.1016/j.apenergy.2019.01.193

[47] J. W. Taylor, "Probabilistic forecasting of wind power ramp events using autoregressive logit models," European Journal of Operational Research, volume 259, issue 2, 1 june 2017, pages 703-712. DOI: https://doi.org/10.1016/j.ejor.2016.10.041

[48] M. Ohba, S. Kadokura and D. Nohara, "Impacts of synoptic circulation patterns on wind power ramp events in East Japan," Renewable Energy, volume 96, part a, october 2016, pages 591-602. DOI: https://doi.org/10.1016/j.renene.2016.05.032

[49] M. Cui, J. Zhang, A. R. Florita, B-M. Hodge, D. Ke and Y. Sun, "An Optimized Swinging Door Algorithm for Identifying Wind Ramping Events," IEEE Transactions on Sustainable Energy, volume: 7, issue: 1, jan. 2016. DOI: https://doi.org/10.1109/TSTE.2015.2477244

[50] J. Zhang, M. Cui, B. M. Hodge, A. Florita and J. Freedman, "Ramp forecasting performance from improved short-term wind power forecasting over multiple spatial and temporal scales," Energy, volume 122, 1 march 2017, pages 528-541. DOI: https://doi.org/10.1016/j.energy.2017.01.104

[51] Y. Takahashi, Y. Fujimoto and Y. Hayashi, "Forecast of Infrequent Wind Power Ramps Based on Data Sampling Strategy," Energy Procedia, volume 135, october 2017, pages 496-503. DOI: https://doi.org/10.1016/j.egypro.2017.09.494

[52] T. Ouyang, X. Zha, L. Qin, Y. He and Z. Tang, "Prediction of wind power ramp events based on residual correction," Renewable Energy, volume 136, june 2019, pages 781-792. DOI: https://doi.org/10.1016/j.renene.2019.01.049

[53] G. F. Frate, P. Cherubini, C. Tacconelli, A. Micangeli, L. Ferraria, U. Desideri, "Ramp rate abatement for wind energy integration in microgrids," Energy Procedia, volume 159, february 2019, pages 292-297. DOI: https://doi.org/10.1016/j.egypro.2019.01.013

[54] H. S Dhiman, D. Deb and J. M. Guerrero, "Hybrid machine intelligent SVR variants for wind forecasting and ramp events," Renewable and Sustainable Energy Reviews, volume 108, july 2019, pages 369-379. DOI: https://doi.org/10.1016/j.rser.2019.04.002

[55] O. Probst, "A new strategy for short-term ramp rate control in wind farms," International Journal of Electrical Power & Energy Systems, volume 120, september 2020, 105969. DOI: https://doi.org/10.1016/j.ijepes.2020.105969

[56] H. Liu, H. Wu and Y. Li, "Multi-step wind speed forecasting model based on Wavelet matching analysis and hybrid optimization framework," Sustainable Energy Technologies and Assessments 40, 2020, 100745. DOI: https://doi.org/10.1016/j.seta.2020.100745

[57] C. Yu, Y. Li, H. Xiang and M. Zhang, "Data mining-assisted short-term wind speed forecasting by Wavelet packet decomposition and Elman neural network," Journal of Wind Engineering and Industrial Aerodynamics, volume 175, april 2018, pages 136-143. DOI: https://doi.org/10.1016/j.jweia.2018.01.020

[58] Y. Jiang, G. Huang, X. Peng, Y. Li and Q. Yang, "A novel wind speed prediction method: Hybrid of correlation-aided DWT, LSSVM and GARCH," Journal of Wind Engineering and Industrial Aerodynamics, volume 174, march 2018, pages 28-38. DOI: https://doi.org/10.1016/j.jweia.2017.12.019

[59] Y. Li, H. Shi, F. Han, Z. Duan and H. Liu, "Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy," Renewable Energy, volume 135, may 2019, pages 540-553. DOI: https://doi.org/10.1016/j.renene.2018.12.035

[60] H. Liu, Z. Duan, C. Chen and H. Wu, "A novel two-stage deep learning wind speed forecasting method with adaptive multiple error corrections and bivariate Dirichlet process mixture model," Energy Conversion and Management, volume 199, 1 november 2019, 111975. DOI: https://doi.org/10.1016/j.enconman.2019.111975

[61] Z. Qian, Y. Pei, H. Zareipour and N. Chen, "A review and discussion of decompositionbased hybrid models for wind energy forecasting applications," Applied Energy, volume 235, 1 february 2019, pages 939-953. DOI: https://doi.org/10.1016/j.apenergy.2018.10.080

[62] J. Freedman, M. Markus and R. Penc, "Analysis of West Texas Wind Plant Ramp-up and Ramp-down Events," AWS Truewind LLC, Albany, N.Y. 2008. Available from: https://www.researchgate.net/publication/317095990_Analysis_of_West_Texas_Wind_Plant_ Ramp-up_and_Ramp-down_Events

[63] C. W. Potter, E. Grimit and B. Nijssen, "Potential Benefits of a Dedicated Probabilistic Rapid Ramp Event Forecast Tool," in Proceedings of the IEEE Power Systems Conference and Exposition–PSCE '09, Seattle, Wash., March. 2009. pp. 1–5, DOI: https://doi.org/10.1109/PSCE.2009.4840109

[64] C. Kamath, "Understanding Wind Ramp Events through Analysis of Historical Data," pp.1–6 in Proceedings of the IEEE PES Transmission and Distribution Conference and Expo, New Orleans, La., april. 2010. DOI: https://doi.org/10.1109/TDC.2010.5484508

[65] C. Ferreira, J. Gama, L. Matias, A. Botterud, J. Wang and I. Porto, "A survey on wind power ramp forecasting," United States: n.p., 2011. Web. DOI: 10.2172/1008309.

[66] J. Zhang, B-M. Hodge, A. Florita, J. Freedman, "Ramp forecasting performance from improved short-term wind power forecasting," Proceedings of the ASME 2014 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference. IDETC/CIE 2014. August 17-20, 2014, Buffalo, New York, USA. Available from: https://www.nrel.gov/docs/fy14osti/61730.pdf

[67] M. Liu, Z. Cao, J. Zhang, L. Wang, C. Huang and X. Luo, "Short-term wind speed forecasting based on the Jaya-SVM model," International Journal of Electrical Power & Energy Systems, volume 121, october 2020, 106056. DOI: https://doi.org/10.1016/j.ijepes.2020.106056

[68] CCEE, "Preço Horário "Sombra," Brazil. Available from: https://www.ccee.org.br/portal/faces/pages_publico/o-que-

fazemos/como_ccee_atua/precos/preco_sombra?_afrLoop=1063069300076925&_adf.ctrlstate=oswzja6vt_14#!%40%40%3F_afrLoop%3D1063069300076925%26_adf.ctrlstate%3Doswzja6vt_18

CAPÍTULO 7

7 DISCUSSÕES FINAIS SOBRE PREVISÃO A MÉDIO PRAZO

Diante das discussões dos resultados expostos nos trabalhos científicos apresentadas no capítulo anterior, seguindo a metodologia híbrida de simulação computacional aplicando a inteligência artificial via redes neurais artificiais por meio dos algoritmos de aprendizado de máquina supervisionado junto com o processamento de sinais temporais, ou seja, filtragem passa alta e passa baixa dos sinais por intermédio da decomposição Wavelet discreta Meyer, tem-se os resultados estatísticos gráficos a seguir.

Ressalta-se que as Wavelets são funções capazes de decompor e descrever e/ou representar outra função — ou uma série de dados — originalmente descrita no domínio do tempo, de forma a poder analisar esta outra função em diferentes escalas de frequência e tempo. Conforme já mencionado, foi demostrado nesta tese que a função Wavelet discreta Meyer é a mais precisa para a filtragem dos sinais de velocidade do vento, tanto para região tropical como para a região subtropical, e que a metodologia híbrida se torna a mais eficiente para previsão de vento a curto e médio prazo, 1 h a 168 h (ou 1 semana) a frente.

Para verificar o comportamento da previsão de 1 h a 168 h a frente, ponto a ponto, gerou-se as imagens a seguir as quais destacam a estatística representada pela raiz do erro quadrático médio e do fator de 2 para a análise da previsão da velocidade do vento na região tropical e subtropical e o coeficiente de correlação de Pearson para a análise estatística da previsão da potência eólica de saída seguindo os parâmetros de engenharia e informações de turbinas comerciais para cada altura anemométrica.

Para a região tropical, percebe-se que os melhores resultados são representados pelos dados coletados na altura de 100 m, seguido por 120 m e 150 m, para a região subtropical tem-se que os melhores resultados são registrados para a altura de 80 m, seguido com o de 100 m, o que indica que quanto maior a altura anemométrica, maior é a variabilidade dos dados coletados, sendo maior a influência dos fenômenos turbulentos de circulação, visto que quanto mais distante da superfície terrestre, menor é a influência física do cisalhamento e maior é o

movimento das partícula que compõem a atmosfera. Assim maior é a dificuldade do modelo de compreender as características de vento medido a 150 m para prever com a mesma qualidade de alturas menores, 80 m, 100 m, ou 120 m.

Para todas as regiões e alturas simuladas, os resultados mostraram o mesmo comportamento gráfico com decaimento da acurácia até aproximadamente 30 h a frente, seguindo com baixa variabilidade da curva até 168 h a frente. Isto é importante por demonstrar que o modelo pode ser aplicado em diferentes regiões com empreendimento eólicos (além de potenciais regiões) e, também, diferentes alturas de turbinas eólicas, pois este modelo computacional híbrido se mostrou generalista com bom desempenho (ao interpretar a estatística descritiva); é mais preciso quando comparado com modelos estatísticos simples (persistência, por exemplo) e de baixo custo computacional se comparado com modelos de simulação numérica. Os gráficos retratados da Figura 38 até a Figura 45 representam as análises feitas para a previsão da velocidade do vento a médio prazo, já os retratados da Figura 46 a Figura 49, estão representando as análises a médio prazo da geração de potência eólica de saída.



Figura 38: Análise estatística RMSE entre a velocidade do vento medida e predita a médio prazo para sítio de Esplanada, Bahia – Brasil. Fonte: Autoria própria.



Figura 39: Análise estatística Fator de 2 entre a velocidade do vento medida e predita a médio prazo para sítio de Esplanada, Bahia – Brasil. Fonte: Autoria própria.

Em termos de medida de tendência central tem-se para o sítio Esplanada a 100 m, 120 m e 150 m, os valores de RMSE médio e Fator de 2 médio iguais a 1,31 m/s e 97,02%; 1,32 m/s e 96,35%; 1,51 m/s e 95,66%, respectivamente.



Figura 40: Análise estatística RMSE entre a velocidade do vento medida e predita a médio

prazo para sítio de Mucugê, Bahia - Brasil.

Fonte: Autoria própria.



Figura 41: Análise estatística Fator de 2 entre a velocidade do vento medida e predita a médio prazo para sítio de Mucugê, Bahia – Brasil.

Fonte: Autoria própria.

Em termos de medida de tendência central tem-se para o sítio Mucugê a 100 m, 120 m e 150 m, os valores de RMSE médio e Fator de 2 médio iguais a 2,51 m/s e 96,43%; 2,48 m/s e 93,77%; 2,87 m/s e 93,54%, respectivamente.



Figura 42: Análise estatística RMSE entre a velocidade do vento medida e predita a médio prazo para sítio de Mucuri, Bahia – Brasil.

Fonte: Autoria própria.



Figura 43: Análise estatística Fator de 2 entre a velocidade do vento medida e predita a médio prazo para sítio de Mucuri, Bahia – Brasil. Fonte: Autoria própria.

Em termos de medida de tendência central tem-se para o sítio Mucuri a 100 m, 120 m e 150 m, os valores de RMSE médio e Fator de 2 médio iguais a 1,90 m/s e 95,30%; 2,01 m/s e 94,95%; 2,24 m/s e 95,03%, respectivamente.



Figura 44: Análise estatística RMSE entre a velocidade do vento medida e predita a médio prazo para sítio de Colônia Eulacio, Soriano – Uruguai.

Fonte: Autoria própria.





Em termos de medida de tendência central tem-se para o sítio Colônia Eulacio a 81,8 m e 101,8 m, os valores de RMSE médio e Fator de 2 médio iguais a 3,22 m/s e 86,23%; 3,47 m/s e 85,26%, respectivamente. O Quadro 8 mostra os valores de RMSE médio e Fator de 2 médio para todos os sítios.

Sítio	RMSE médio [m/s]	Fator de 2 médio [%]
Esplanada 100 m	1,31	97,02
Esplanada 120 m	1,32	96,35
Esplanada 150 m	1,51	95,66
Mucugê 100 m	2,51	96,43
Mucugê 120 m	2,48	93,77
Mucugê 150 m	2,87	93,54
Mucuri 100 m	1,90	95,30
Mucuri 120 m	2,01	94,95

Continua...

Mucuri 150 m	2,24	95,03
Colônia Eulacio 81.8 m	3,22	86,23
Colônia Eulacio 101.8 m	3,47	85,26

Quadro 8: RMSE médio e Fator de 2 médio da previsão da velocidade do vento de 1 h até 168 h a frente.

Fonte: Autoria própria.



Figura 46: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e predita a médio prazo para sítio de Mucuri, Bahia – Brasil. Fonte: Autoria própria.

Em termos de medida de tendência central tem-se para o sítio Mucuri a 100 m, 120 m e 150 m, os valores de Pearson médio para potência eólica iguais a 0,78; 0,74; e 0,70, respectivamente.



Figura 47: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e predita a médio prazo para sítio de Mucugê, Bahia – Brasil.

Fonte: Autoria própria.

Para o sítio Mucugê a 100 m, 120 m e 150 m, os valores de Pearson médio para potência eólica são iguais a 0,45; 0,30; e 0,47, respectivamente.



Figura 48: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e predita a médio prazo para sítio de Esplanada, Bahia – Brasil. Fonte: Autoria própria.

Por fim, em termos de medida de tendência central, tem-se para o sítio Esplanada a 100 m, 120 m e 150 m, os valores de Pearson médio para potência eólica iguais a 0,51; 0,47; e 0,37,

respectivamente. Já para Colônia Eulacio a 81,8 m e 101,8 m, os valores de Pearson médio para potência eólica são iguais a 0,44 e 0,31, respectivamente.



Figura 49: Análise estatística coeficiente de Pearson entre a potência eólica de saída medida e predita a médio prazo para sítio de Colônia Eulacio, Soriano – Uruguai. Fonte: Autoria própria.

Por meio do Quadro 9 pode-se observar o Pearson médio calculado para previsão da potência eólica de saída 1 h a 168 h a frente para todos os sítios.

Sítio	Pearson médio
Mucuri 100 m	0,78
Mucuri 120 m	0,74
Mucuri 150 m	0,70
Mucugê 100 m	0,45
Mucugê 120 m	0,30
Mucugê 150 m	0,47
Esplanada 100 m	0,51
Esplanada 120 m	0,47

Esplanada 150 m	0,37
Colônia Eulacio 81.8 m	0,44
Colônia Eulacio 101.8 m	0,31

Quadro 9: Pearson médio da previsão da potência eólica de saída de 1 h até 168 h a frente. Fonte: Autoria própria.

Entende-se que prever a velocidade do vento e, por consequência, a potência eólica de saída em um empreendimento eólico é algo desafiador, tendo em vista a complexidade dos processos físicos que afetam a variabilidade temporal e espacial desta variável atmosférica. Estudos que realizam uma análise detalhada de previsões para a velocidade de vento e energia eólica 1 semana a frente (ou 168 h) são escassos, principalmente, estudos que envolvem testes com diferentes metodologias aplicando IA e filtragem dos sinais anemométricos via diferentes famílias Wavelets usando dados coletados em alturas superiores a 100 m.

Devido a essa complexidade ainda não há um parâmetro final sobre o grau de acerto que é possível alcançar para prever a velocidade do vento com confiança em diferentes tipos de climas, e assim contribuir de forma significativa com a gestão dos parques eólicos no Brasil e Uruguai por meio da previsão de energia a médio prazo. No entanto, este estudo traz um avanço científico na compreensão da previsibilidade dos ventos e energia eólica em região tropical e subtropical, Brasil e Uruguai respectivamente, contribuindo de forma direta com o operador nacional do sistema elétrico de cada nação.

CAPÍTULO 8

8 CONSIDERAÇÕES FINAIS

8.1 Conclusão

Com o desenvolvimento dos trabalhos apresentados no capítulo 6 e os resultados discutidos no Capítulo 7, todos os objetivos específicos desta pesquisa foram atingidos, pois investigou-se as melhores técnicas de previsão de séries temporais utilizando o aprendizado de máquina supervisionado por meio da inteligência computacional via redes neurais artificiais, aplicandoas a dados observacionais de torres anemométricas advindos de alturas de 80 m, 100 m, 120 m, e 150 m (dados anemométricos: velocidade, direção, temperatura, umidade e pressão atmosférica, por exemplo) coletados no Brasil (sítio representativo do clima tropical) e no Uruguai (sítio representativo do clima subtropical); foi averiguado sobre a utilização do modelo híbrido por intermédio da aplicação da filtragem e decomposição dos sinais temporais usando 6 famílias Wavelets totalizando 48 funções e a convolução matemática para a melhoria da acurácia dos modelos de previsão de séries temporais explorados; um método/modelo híbrido foi projetado para previsão da geração de energia eólica utilizando a aprendizagem de máquina supervisionada via redes neurais artificiais agregado com o processamento de sinais via decomposição Wavelet e a convolução matemática; por fim, foi avaliado e validado o método/modelo criado utilizando dados observacionais de torres anemométricas com anemômetros instalados nos sítios tropicais e subtropical supracitados posicionados nas alturas do hub (rotor) das turbinas eólicas comerciais (isto é: 80 m, 100 m, 120 m e 150 m).

O empirismo antes aplicado na utilização das Wavelets para decomposição dos dados de vento foi substituído pela metodologia de análise da eficácia das funções Wavelets antes da aplicação dos dados filtrados como *input* das redes neurais. A função discreta Meyer ou *dmey* (a qual é uma função ortogonal, indefinidamente derivável com suporte infinito e definida no domínio da frequência) foi comprovada por meio da metodologia científica apresentada nesta tese ser a função mais eficiente para a decomposição dos sinais de velocidade do vento, garantindo maior

acurácia e maior precisão nas previsões de velocidade do vento, de energia eólica e fenômenos de rampa de energia eólica. É importante observar que as funções Wavelet possuem a propriedade de localização no tempo e na frequência, característica base da utilização de Wavelet em análise de sinais de vento, por exemplo. Além disso, destaca-se que a transformada Wavelet não se baseia na suposição de estacionaridade de séries temporais para a efetivação da decomposição. A Wavelet atua localmente no tempo, o que permite a análise espectral de séries temporais na presença de não-estacionaridade.

Assim, como os objetivos específicos desta pesquisa foram alcançados, efetivou-se o objetivo geral da tese com a avaliação e a implementação das melhorias na previsão da geração de energia eólica a curto e médio prazo, 1 h a 168 h à frente, em resolução espacial de microescala (ou escala local, a qual apresenta processos atmosféricos da ordem de 0,001 km a 1.0 km) usando modelos de previsão baseados em inteligência computacional e processamento de sinais para o estado da Bahia, região Nordeste do Brasil (sítio tropical), e para Colônia Eulacio, Departamento de Soriano, no Sudoeste do Uruguai (sítio subtropical). Tal esforço visou atender à demanda do setor de produção e distribuição de energia elétrica no Brasil e no Uruguai, com a finalidade de possibilitar um melhor aproveitamento da energia eólica nos empreendimentos atuais e em futuros projetos de exploração, produção e comercialização dessa fonte alternativa de energia. Ressalta-se que este modelo de previsão híbrido, advindo da inteligência computacional, bem ajustado originou um ferramental de baixo custo computacional destinado a fornecer tais previsões às concessionárias, geradoras e distribuidoras de energia elétrica e, inclusive, aos operadores nacionais do sistema elétrico de cada nação.

8.2 Sugestões de trabalhos futuros

Para a continuidade desta averiguação científica, sugere-se como trabalhos futuros:

 a) A implementação do código computacional para aprendizado de máquina supervisionado via redes neurais artificias com a automação da definição dos hiperparâmetros mais eficientes durante a fase de treinamento com a finalidade de otimizar o processo. Com esta implementação para definição automatizada dos hiperparâmetros, pode-se também iniciar a averiguação do comportamento da previsão a longo prazo (1 mês a frente) utilizando o modelo híbrido implementado neste trabalho.

- b) A aplicação desta metodologia híbrida (IA + Wavelets) para previsão a médio prazo (1 h a 168 h a frente) da radiação e, assim, da energia solar em região tropical e subtropical.
- c) A análise da eficiência de cada família Wavelet para filtragem passa baixa e passa alta do sinal de radiação solar comparando com as análises para decomposição da velocidade do vento, realizando uma análise da manutenção da energia do sinal medido e sua previsibilidade a médio prazo.
- d) Aplicar esta metodologia híbrida usando dados de vento e radiação solar medidos offshore em regiões tropicais e subtropicais, com a finalidade de comparar com os resultados já alcançados no ambiente de exploração onshore. Para, portanto, contribuir com a desenvoltura da geração de energia sustentável no ambiente offshore.
- e) Realizar simulações utilizando aprendizado de máquina semisupervisionado para previsão de energia eólica e solar, fazendo um comparativo com os resultados gerados neste trabalho (aprendizado de máquina supervisionado).
- f) Modelar e simular a previsão do fenômeno de efeito esteira e escoamento turbulento do vento em parques eólicos aplicando modelo híbrido por meio da inteligência computacional via aprendizado de máquina supervisionado e transformada Wavelet.
CAPÍTULO 9

9 REFERÊNCIAS BIBLIOGRÁFICAS

ABEEolica. (2021). **ENERGIA EÓLICA: Os bons ventos do Brasil.** Infovento nº 19, 11 de fevereiro de 2021. Disponível em: http://abeeolica.org.br/wp-content/uploads/2021/02/2021_02_18_InfoWind19.pdf Acesso em: 29/05/2021.

ABHISHEK, K. et al. (2012). Weather forecasting model using Artificial Neural Network. Kumar Abhishek; M.P. Singh; Saswata Ghosh; Abhishek Anand. Procedia Technology 4 (2012) 311 – 318. Published by Elsevier Ltd. DOI: <https://doi.org/10.1016/j.protcy.2012.05.047>

AGHAJANI, A.; KAZEMZADEH, R.; EBRAHIMI, A. (2016). A novel hybrid approach for predicting wind farm power production based on Wavelet transform, hybrid neural networks and imperialist competitive algorithm. Afshin Aghajani; Rasool Kazemzadeh; Afshin Ebrahimi. Energy Conversion and Management, Volume 121, 1 August 2016, Pages 232-240. DOI: https://doi.org/10.1016/j.enconman.2016.05.024>

AHMADI, M. and KHASHEI, M. (2021). Current status of hybrid structures in windforecasting.Engineering Applications of Artificial Intelligence.Mehrnaz Ahmadi, MehdiKhashei.Volume99,March2021,104133.DOI:<https://doi.org/10.1016/j.engappai.2020.104133>

AHMED, A. and KHALID, M. (2018). An intelligent framework for short-term multi-step wind speed forecasting based on Functional Networks. Adil Ahmed; Muhammad Khalid. Applied Energy. Volume 225, 1 September 2018, Pages 902-911. 2018. DOI: https://doi.org/10.1016/j.apenergy.2018.04.101>

AHRENS, C.D. (2009). **Meteorology Today: An Introduction to Weather, Climate, and the Environment.** C. Donald Ahrens. Ninth Edition, 621 p., Brooks/Cole, Cengage Learning, 2009.

AILLIOT, P. and Monbet, V. (2012). **Markov-switching autoregressive models for wind time series**. Pierre Ailliot and Valérie Monbet. Environmental Modelling & Software, Volume 30, April 2012, Pages 92-101. DOI: https://doi.org/10.1016/j.envsoft.2011.10.011

ALY, H.H.H. (2020). An intelligent hybrid model of neuro Wavelet, time series and Recurrent Kalman Filter for wind speed forecasting. Hamed H. H. Aly. Sustainable Energy

Technologies and Assessments, Volume 41, October 2020, 100802. DOI: https://doi.org/10.1016/j.seta.2020.100802>

ALIPOUR, M. et al. (2020). A novel electrical net-load forecasting model based on deep neural networks and wavelet transform integration. Mohammadali Alipour, Jamshid Aghaei, Mohammadali Norouzi, Taher Niknam, Sattar Hashemi and Matti Lehtonen. Energy (2020), Volume 205, 15 August 2020, 118106. DOI: <https://doi.org/10.1016/j.energy.2020.118106>

AMJADY, N. and KEYNIA, F. (2008). Day ahead price forecasting of electricity markets by a mixed data model and hybrid forecast method. Nima Amjady; Farshid Keynia. International Journal of Electrical Power & Energy Systems. Volume 30, Issue 9, November 2008, Pages 533-546. DOI: https://doi.org/10.1016/j.ijepes.2008.06.001

AMJADY, N. and KEYNIA, F. (2009). Short-term load forecasting of power systems by combination of Wavelet transform and neuro-evolutionary algorithm. N. Amjady; F. Keynia. Energy, Volume 34, Issue 1, January 2009, Pages 46-57. DOI: https://doi.org/10.1016/j.energy.2008.09.020>

AMJADY, N.; DARAEEPOUR, A.; KEYNIA, F. (2010). **Day-ahead electricity price forecasting by modified relief algorithm and hybrid neural network.** N. Amjady; A. Daraeepour; F. Keynia. IET Generation, Transmission & Distribution (2010),4(3):432. DOI: http://dx.doi.org/10.1049/iet-gtd.2009.0297>

AMJADY, N.; KEYNIA, F. and ZAREIPOUR, H. (2011). Wind power prediction by a new forecast engine composed of modified hybrid neural network and enhanced particle swarm optimization. Nima Amjady; Farshid Keynia; Hamidreza Zareipour. IEEE Transactions on Sustainable Energy (Volume: 2, Issue: 3, July 2011). DOI: <10.1109/TSTE.2011.2114680>

CADENAS, E.; RIVERA, W. (2009). Short term wind speed forecasting in La Venta, Oaxaca, Mexico, using artificial neural networks. Erasmo Cadenas; Wilfrido Rivera. Renewable Energy, Volume 34, Issue 1, January 2009, Pages 274-278. 2009. DOI: https://doi.org/10.1016/j.renene.2008.03.014>

CANALENERGIA. (2018). **PLD horário é adiado para 2020.** Disponível em: https://www.canalenergia.com.br/noticias/53062195/pld-horario-e-adiado-para-2020-diz-ccee>. Acesso em: 04/01/2019.

CAO, J.; FARNHAM, D.J.; LALL, U. (2017). **Spatial-temporal wind field prediction by Artificial Neural Networks.** Jianan Cao; David J. Farnham; Upmanu Lall. Cornell University. Diponível em: https://arxiv.org/ftp/arxiv/papers/1712/1712.05293.pdf>. Acesso em: 14/01/2019.

CASTRO, N. et al. (2014). **A Formação do preço da energia elétrica: Experiências internacionais e o modelo brasileiro.** Texto de Discussão do Setor Elétrico TDSE nº 62. Nivalde de Castro; Roberto Brandão; Nelson Hubner; Guilherme Dantas; Rubens Rosental. Novembro de 2014. Disponível em: < https://www.projetobolsadeenergia.com.br/docs/5/A_formacao_preco_texto.pdf>. Acesso em: 26/03/2021.

CATALAO, J.P.S.; POUSINHO, H.M.I.; MENDES, V.M.F. (2011). **Hybrid Wavelet-PSO-ANFIS approach for short-term wind power forecasting in Portugal.** J. P. S. Catalao; H. M. I. Pousinho; V. M. F. Mendes. IEEE Transactions on Sustainable Energy (Volume: 2, Issue: 1, Jan. 2011). DOI: <10.1109/TSTE.2010.2076359>

CCEE. (2019). Câmara de Comercialização de Energia Elétrica. **CCEE lança Download de Dados com informações sombra do preço horário**. Disponível em: https://www.ccee.org.br/portal/faces/pages_publico/noticias-

opiniao/noticias/noticialeitura?contentid=CCEE_646404&_adf.ctrl-

state=10taudspr7_1&_afrLoop=339106646972906#!%40%40%3Fcontentid%3DCCEE_6464 04%26_afrLoop%3D339106646972906%26_adf.ctrl-state%3D10taudspr7_5>. Acesso em: 27/03/2019.

CCEE (2021). Câmara de Comercialização de Energia Elétrica. **Com quem se relaciona**. Disponível em: https://www.ccee.org.br/portal/faces/pages_publico/onde-atuamos/com_quem_se_relaciona?_adf.ctrl

CHANG, W.Y. (2013). Application of Backpropagation Neural Network for Wind Power Generation Forecasting. Wen-Yeau Chang. International Journal of Digital Content Technology and its Application, 7, 502-509. 2013. DOI: <10.4156/jdcta.vol7.issue4.61>

CHAVES, G.L.D. (2016). **Gestão de sistemas de energia.** / Adan Lucio Pereira ... [et al.]; Gisele de Lorena Diniz Chaves, Marielce de Cássia Ribeiro Tosta (organizadoras). – Curitiba: CRV, 2016. 372p.

CHEN, J.; ZENG, G.Q.; ZHOU, W.; DU, W; LU, K.D. (2018). Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization. Jie Chen, Guo-Qiang Zeng, Wuneng Zhou, Wei Du, Kang-Di Lu. Energy Conversion and Management, Volume 165, 1 June 2018, Pages 681-695. DOI: https://doi.org/10.1016/j.enconman.2018.03.098>

CHENG, W.Y.Y. et al. (2017). Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation. William Y.Y. Cheng, Yubao Liu, Alfred J. Bourgeois, Yonghui Wu, Sue Ellen Haupt. Renewable Energy 107 (2017) 340e351. DOI: http://dx.doi.org/10.1016/j.renene.2017.02.014>

CHOLLET, F. (2018). **Deep Learning with Python.** (1st ed.). Manning Publications Co. Disponível em:

<http://faculty.neu.edu.cn/yury/AAI/Textbook/Deep%20Learning%20with%20Python.pdf>

CHUANAN, Y.; YONGCHANG, Y. (2011). A hybrid model to forecast wind speed based on Wavelet and neural network. Chuanan Yao; Yongchang Yu. 2011 International Conference on Control, Automation and Systems Engineering (CASE). IEEE; 2011. p. 1–4. DOI: <10.1109/ICCASE.2011.5997893>

CONEJO, A.J.; PLAZAS, M.; ESPINOLA, R.; Molina, A.B. (2005). **Day-ahead electricity price forecasting using the Wavelet transform and ARIMA models.** Antonio J. Conejo; Miguel A. Plazas; Rosa Espínola; Ana B. Molina. IIEEE Transactions on Power Systems, Volume: 20, Issue: 2, May 2005. DOI: <10.1109/TPWRS.2005.846054>

CREA-BA, (2018). **Energia eólica: Bons ventos na Bahia.** Revista do conselho regional de Engenharia e Agronomia da Bahia. v. 16, n. 60, Segundo trimestre de 2018. Salvador: CREA-BA. ISSN 1679-2866. Disponível em: <http://www.creaba.org.br/Imagens/FCKimagens/Pdf/Revista_CREA_60.pdf>. Acesso em: 18/01/2019.

DAUBECHIES, I. (1992). **Ten lectures on Wavelets, SIAM.** Ingrid Daubechies. 1992. DOI: https://doi.org/10.1137/1.9781611970104

DALTO, M. et al. (2014). **Neural network based ultra-short term wind forecasting.** Mladen Dalto; Mario Vašak; Mato Baotic; Jadranko Matuško; Kristian Horvath. University of Zagreb, Faculty of Electrical Engineering and Computing. 2014.

DERECZYNSKI, C.P. e MENEZES, W.F. (2015). **Meteorologia da Bacia de Campos.** Claudine Pereira Dereczynski, Wallace Figueiredo Menezes. In: Martins, R.P., Grossmann-Matheson, G.S., editores. Meteorologia e Oceanografia. Rio de Janeiro: Elsevier. Habitats, v. 2. p. 1-54. DOI: https://doi.org/10.1016/B978-85-352-6208-7.50008-8

DINIZ, C.R. e SILVA, I.B. (2008). **Metodologia científica: Tipos de métodos e sua aplicação**. Célia Regina Diniz; Iolanda Barbosa da Silva. Aula 04, 24p., Campina Grande; Natal: UEPB/UFRN – EDUEP, 2008.

DHIMAN, H.S.; Deb, D.; Balas, V. E. (2020). **Chapter 7 - Ramp prediction in wind farms**. Book chapter. Harsh S. Dhiman, Dipankar Deb, Valentina Emilia Balas. Supervised Machine Learning in Wind Forecasting and Ramp Event Prediction, Wind Energy Engineering, 2020, Pages 101-139. DOI: https://doi.org/10.1016/B978-0-12-821353-7.00018-1

DORADO-MORENO, M. et al. (2020). Multi-task learning for the prediction of wind power ramp events with deep neural networks. M. Dorado-Moreno, N. Navarin, P.A.

Gutiérrez, L. Prieto, A.Sperduti, S.Salcedo-Sanz, C.Hervás-Martínez. Neural Networks, Volume 123, March 2020, Pages 401-411. DOI: https://doi.org/10.1016/j.neunet.2019.12.017>

DUAN, J. et al. (2021). Short-term wind speed forecasting using recurrent neural networks with error correction. Jikai Duan, Hongchao Zuo, Yulong Bai, Jizheng Duan, Mingheng Chang, Bolong Chen. Energy, Volume 217, 15 February 2021, 119397. DOI: https://doi.org/10.1016/j.energy.2020.119397>

FERREIRA, C.; GAMA, J.; MATIAS, L.; BOTTERUD, A.; WANG, J.; and INESC Porto. (2011). A survey on wind power ramp forecasting. United States: N. p., 2011. Web. DOI: <10.2172/1008309>

FREEDMAN, J.; M. MARKUS; and R. PENC. (2008). Analysis of West Texas Wind Plant Ramp-up and Ramp-down Events. AWS Truewind LLC, Albany, N.Y.

GIL, A.C. (2002). **Como elaborar projetos de pesquisa.** Antônio Carlos Gil. 4. ed. São Paulo: Atlas, 2002.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. (2017). **Deep Learning**. Book. Cambridge, MA : MIT Press, [2017]. Ian Goodfellow; Yoshua Bengio; Aaron Courville. Series: Adaptive computation and machine learning series. ISBN 9780262035613. 773p. 2017.

HAQUE, A.U.; MANDAL, P.; MENG, J.; SRIVASTAVA, A.K.; TSENG, T-L; SENJYU, T. (2013). **A novel hybrid approach based on Wavelet transform and fuzzy ARTMAP networks for predicting wind farm power production.** Ashraf Ul Haque; Paras Mandal; Julian Meng; Anurag K. Srivastava; Tzu-Liang Tseng; Tomonobu Senjyu. IEEE Transactions on Industry Applications, Volume: 49, Issue: 5, Sept.-Oct. 2013. DOI: <10.1109/TIA.2013.2262452>

HAYKIN, S. (1998). Neural Networks: A Comprehensive Foundation. Prentice Hall PTR, Upper Saddle River, NJ, 1998.

HUANG, J.; HENRY, S. and van DAM, C.P. (2010). **Appendix B - Wind Energy Forecasting: A Review of State-of-the-Art and Recommendations for Better Forecasts.** Junhui Huang, Henry Shiu, and C. P. van Dam. California Renewable Energy Forecasting, Resource Data and Mapping, 2010.

HUANG, L. and WANG, J. (2018). Forecasting energy fluctuation model by Wavelet decomposition and stochastic recurrent Wavelet neural network. Lili Huang, Jun Wang. Neurocomputing, Volume 309, 2 October 2018, Pages 70-82. DOI: https://doi.org/10.1016/j.neucom.2018.04.071

HWANG, M. Y. et al. (2011). **Prediction of Wind Power Generation and Power Ramp Rate with Time Series Analysis**. Mi Yeong Hwang; Cheng Hao Jin; Yang Koo Lee; Kwang Deuk Kim; Jung Hoon Shin; Keun Ho Ryu. Awareness Science and Technology (iCAST), 2011 3rd International Conference on Awareness Science and Technology (iCAST). DOI: <https://doi.org/10.1109/ICAwST.2011.6163182>

IBGE. (2019). Instituto Brasileiro de Geografia e Estatística. **Informações por Cidade e Estado**. Disponível em: https://www.ibge.gov.br/cidades-e-estados/ba/esplanada.html. Acesso em: 25/06/2020.

JONES, M.T. (2017). Arquiteturas de aprendizado profundo: O surgimento da inteligência artificial. M. Tim Jones. Publicado em 04/Out/2017. Disponível em: https://www.ibm.com/developerworks/br/library/cc-machine-learning-deep-learning-architectures/index.html>. Acesso em: 14/01/2019.

KALMIKOV, A. (2017). **Chapter 2 - Wind Power Fundamentals.** Alexander Kalmikov. Wind Energy Engineering. A Handbook for Onshore and Offshore Wind Turbines. 2017, Pages 17-24. DOI: https://doi.org/10.1016/B978-0-12-809451-8.00002-3

KAMATH, C. (2010). **Understanding Wind Ramp Events through Analysis of Historical Data**. pp.1–6 in Proceedings of the IEEE PES Transmission and Distribution Conference and Expo, New Orleans, La., April.

LI, X. et al. (2019). Rolling bearing health prognosis using a modified health index based hierarchical gated recurrent unit network. Xingqiu Li; Hongkai Jiang; Xiong Xiong; Haidong Shao. Mechanism and Machine Theory, Volume 133, March 2019, Pages 229-249. DOI: https://doi.org/10.1016/j.mechmachtheory.2018.11.005>

LI, Y.; WU, H.; LIU, H. (2018). Multi-step wind speed forecasting using EWT decomposition, LSTM principal computing, RELM subordinate computing and IEWT reconstruction. Yanfei Li; Haiping Wu; Hui Liu. Energy Conversion and Management. Volume 167, 1 July 2018, Pages 203-219. 2018. DOI: https://doi.org/10.1016/j.enconman.2018.04.082>

LIU, H.; MI, X.; LI, Y. (2018). Wind speed forecasting method based on deep learning strategy using empirical Wavelet transform, long short term memory neural network and Elman neural network. Hui Liu; Xi-wei Mi; Yan-fei Li. Energy Conversion and Management. Volume 156, 15 January 2018, Pages 498-514. 2018. DOI: https://doi.org/10.1016/j.enconman.2017.11.053

LIU, H.; WU, H.; LI, Y. (2020). **Multi-step wind speed forecasting model based on Wavelet matching analysis and hybrid optimization framework.** Sustainable Energy Technologies and Assessments 40 (2020) 100745. DOI: https://doi.org/10.1016/j.seta.2020.100745>

LOUREIRO, F. P. (2004). **Modelagem Acústica no Domínio da Transformada Wavelet**. Dissertação de Mestrado. Felipe Prado Loureiro. Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro – RJ, 2004. DOI: https://doi.org/10.17771/PUCRio.acad.4915>

LUCAS, E.A.; ARCE, A.M.G.; MORAES, M.R.; BOEZIO, G.C.; OTTIERI, J.C. (2016). Statistical description of diurnal cycle of wind profile in the first 100 meters of height of the Planetary Boundary Layer, in Colonia Eulacio Uruguay. Ciência e Natura v.38 Ed. Especial-IX Brazilian Micrometeorology Workshop 2016, p. 426– 434. DOI: http://dx.doi.org/10.5902/2179460X20308>

LUTGENS, F.K. and TARBUCK, E.J. (1995). **The Atmosphere: An Introduction to Metorology**. Frederick K. Lutgens and Edward J. Tarbuck. Prentice Hall, Inc., New Jersey, 1995, 6th ed.

MALLAT, S. (1989). **A Theory for Multiresolution Signal Decomposition - The Wavelet Representation.** IEEE on Pattern Analysis and Machine Intelligence, vol. 11, No.7, Jul. 1989, pp.674-693.

MANDAL, P.; ZAREIPOUR, H.; ROSEHART, W.D. (2014). Forecasting aggregated wind power production of multiple wind farms using hybrid Wavelet–PSO–NNs. Paras Mandal; Hamidreza Zareipour; William D. Rosehart. Int J Energy Res 2014; 38:1654–66. DOI:

MARTINS, F.R.; GUARNIERI, R.A.; PEREIRA, E.B. (2008). **O aproveitamento da energia eólica.** Rev. Bras. Ensino Fís., São Paulo, v.30, n.1, p.1304.1-1304.13, 2008. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-11172008000100005&lng=en&nrm=iso>. Acesso em: 02/02/2019. DOI: http://dx.doi.org/10.1590/S1806-11172008000100005>

MOREIRA, J.R.S. (2017). **Energias renováveis, geração distribuída e eficiência energética** / Alberto Hernandez Neto ... [et al.]; organização José Roberto Simões Moreira. – 1. ed. – Rio de Janeiro: LTC, 2017. 393p.

MORI, H.; UMEZAWA, Y. (2009). Application of NBTree to Selection of Meteorological Variables in Wind Speed Prediction. Hiroyuki Mori and Yasushi Umezawa. Transmission & Distribution Conference & Exposition: Asia and Pacific, Seoul, Korea, 18 December 2009. DOI: https://doi.org/10.1109/TD-ASIA.2009.5356831

NASCIMENTO, E.G.S. (2016). **Desenvolvimento de ferramentas computacionais para simulação da dispersão de gases liberados por veículos espaciais no Centro de Lançamento de Alcântara**. Tese de doutorado. Erick Giovani Sperandio Nascimento. UFES, Vitória - ES, 2016.

NOAA. (2021). ESRL's Global Monitoring Laboratory (GML) of the National Oceanic and Atmospheric Administration (NOAA). **Trends in Atmospheric Carbon Dioxide**. Disponível em: < https://www.esrl.noaa.gov/gmd/ccgg/trends/data.html>. Acesso em: 06/01/2021.

NOGAY, H.S.; AKINCI, T.C.; EIDUKEVICIUTE, M. (2012). Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey. H. Selcuk Nogay; Tahir Cetin Akinci; Marija Eidukeviciute. Journal of Energy in Southern Africa, Cape Town, v. 23, n. 4, p. 2-7, 2012. Disponível em: http://www.scielo.org.za/scielo.php?script=sci_arttext&pid=S1021-447X2012000500001&lng=en&nrm=iso. Acesso em: 25/06/2020.

OLIVEIRA, S.S. (2013). Análise do potencial eólico do estado da Paraíba utilizando modelos de mesoescala. 129f. Tese (Programa de Pós-Graduação em Meteorologia). Soetânia Santos de Oliveira. Universidade Federal de Campina Grande – UFCG – Campina Grande, 2013.

OUYANG, T.; ZHA, X.; and L. QIN. (2013). A Survey of Wind Power Ramp Forecasting. Energy and Power Engineering, Vol. 5 No. 4B, 2013, pp. 368-372. DOI: 10.4236/epe.2013.54B071

OUYANG, T. et al. (2019). **Prediction of wind power ramp events based on residual correction.** Tinghui Ouyang, Xiaoming Zha, Liang Qin, Yusen He, Zhenhao Tang. Renewable Energy, Volume 136, June 2019, Pages 781-792. DOI: https://doi.org/10.1016/j.renene.2019.01.049

PAIXÃO, J.L. et al. (2017). **Wind generation forecasting of short and very short duration using Neuro-Fuzzy Networks: A case study.** Joelson L. Paixão; Jonas Rigodanzo; Jordan P. Sausen; Júlia Rambo Hammarstron; Alzenira da Rosa Abaide; Luciane N. Canha; Moisés M. Santos. The 7th International Conference on Modern Power Systems (MPS 2017). 978-1-5090-6565-3/17/\$31.00 ©2017 IEEE. DOI: <10.1109/MPS.2017.7974446>

PELLETIER, F.; MASSON, C.; TAHAN, A. (2016). **Wind turbine power curve modelling using artificial neural network.** Francis Pelletier, Christian Masson, Antoine Tahan. Renewable Energy, Volume 89, April 2016, Pages 207-214. DOI: https://doi.org/10.1016/j.renene.2015.11.065>

PINTO, M.O. (2014). **Fundamentos de Energia Eólica** / Milton de Oliveira Pinto. – [Reimpr.]. – Rio de Janeiro: LTC, 2014. 368p.

POTTER, C.W.; E. GRIMIT; and B. NIJSSEN. (2009). **Potential Benefits of a Dedicated Probabilistic Rapid Ramp Event Forecast Tool.** pp. 1–5 in Proceedings of the IEEE Power Systems Conference and Exposition–PSCE '09, Seattle, Wash., March. QIN, Y. et al. (2019). **Hybrid forecasting model based on long short term memory network and deep learning neural network for wind signal.** Yong Qin, Kun Li, Zhanhao Liang, Brendan Lee, Fuyong Zhang, Yongcheng Gu, Lei Zhang, Fengzhi Wu, Dragan Rodriguez. Applied Energy. Volume 236, 15 February 2019, Pages 262-272. DOI: https://doi.org/10.1016/j.apenergy.2018.11.063>

QUADROS, L.C. (2015). Emprego de redes neurais artificiais na correção de concentrações simuladas pelo modelo de qualidade do ar MODELAR. 106f. Dissertação (Programa de Pós-Graduação em Engenharia Ambiental). Lis Campos de Quadros. Universidade Federal do Paraná – UFPR. Curitiba, 2015.

RAFFI, S. and Rajagopal, R. (2012). **Wind Power Ramps: Detection and Statistics**. Raffi Sevlian; Ram Rajagopal. 2012 IEEE Power and Energy Society General Meeting. 2012. DOI: >

REN21. (2020). **Renewables 2020 Global Status Report** (Paris: REN21 Secretariat). ISBN 978-3-948393-00-7. Disponível em: ">https://www.ren21.net/reports/global-status-report/?gclid=CjwKCAjw88v3BRBFEiwApwLevXhcmpLVjwsXuIdI49YJHJ-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-report/?gclid=CjwKCAjw88v3BRBFEiwApwLevXhcmpLVjwsXuIdI49YJHJ-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-report/?gclid=CjwKCAjw88v3BRBFEiwApwLevXhcmpLVjwsXuIdI49YJHJ-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8twWlht7wUPRBbmFgZCe_fSgozZBoCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8tw%PotFgozZboCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8tw%PotFgozZboCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8tw%PotFgozZboCgSEQAvD_BwE>">https://www.ren21.net/reports/global-status-6rE8tw%PotFgozZboCgSEQAvD_BwE>">https://www.ren21.net/report6gozZboCgSEQAvD_BwE>">https://www.ren21.net/report6gozZboCgSEQAvD_BwE>">https://www.ren21.net/report6gogozZboCgSEQAvD_BwE>"">https://www.ren21.net/report6gog

REIS, A. J. R.; SILVA, A. P. A. da. (2004). Aplicação da transformada Wavelet discreta na previsão de carga a curto prazo via redes neurais. Agnaldo J. Rocha Reis; Alexandre P. Alves da Silva. Sba Controle & Automação, Campinas, v. 15, n. 1, p. 101-108, Mar. 2004. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592004000100013&lng=en&nrm=iso>. Acesso em: 15/09/2020. DOI: ">https://doi.org/10.1590/S0103-17592004000100013>

ROBERTSON, A. W.; Kirshner S.; and Smyth P. (2003). **Hidden Markov Models for Modeling Daily Rainfall Occurence over Brazil**. A. W. Robertson, S. Kirshner and P. Smyth. Report UCI-ICS-03-27, Information and Computer Sciences, University of California, Irvine (California) 2003.

RUSSEL, S. and NORVIG, P. (2010). Artificial Intelligence: A Modern Approach. Stuart J. Russell and Peter Norvig. Third Edition. Pearson Education, Inc., 1153p.

SANTHOSH, M.; VENKAIAH, C.; KUMAR, D.M.V. (2018). Ensemble empirical mode decomposition based adaptive Wavelet neural network method for wind speed prediction. Madasthu Santhosh; Chintham Venkaiah; D. M. Vinod Kumar. Energy Conversion and Management. Volume 168, 15 July 2018, Pages 482-493. 2018. DOI: https://doi.org/10.1016/j.enconman.2018.04.099>

SANTOS, J.A.F.A. e TORRES, E.A. (2014). **Evolução da Energia Eólica na Bahia no âmbito da Matriz Energética Brasileira.** Anais do V Simpósio Brasileiro de Sistemas Elétricos, Foz do Iguaçu – PR, Brasil. 22-25/04/2014. ISSN 2177-6164. 2014. SANTOS, M.A. (2013). Fontes de Energia Nova e Renovável. Marco Aurélio dos Santos. – 1.ed. – Rio de Janeiro: LTC. 2013. 197p.

SILVA, N. F. (2006). Fontes de energia renováveis complementares na expansão do setor elétrico brasileiro: o caso da energia eólica. Tese de doutorado em planejamento estratégico. COPPE/UFRJ. Rio de Janeiro, abril de 2006.

SILVEIRA, T. e KOZAKEVICIUS, A. (2016). **Transformada Wavelet de Haar: conceitos, formulações e aplicações**. Thiago da Silveira e Alice Kozakevicius. Sociedade Brasileira de Matemática. IV Colóquio de Matemática da Região Sul, 1ª edição, ISBN 978-85-8337-098-7. Rio Grande - RS - FURG, 2016.

SOVIERZOSKI, M. A. (2010). **Convolução de sinais: definição, propriedades e ferramentas.** Miguel Antonio Sovierzoski. Revista Ilha Digital, ISSN 2177-2649, volume 2, páginas 81 – 95, 2010. Disponível em: http://ilhadigital.florianopolis.ifsc.edu.br/index.php/ilhadigital/article/view/24

STULL, R.B. (1988). An Introduction to Boundary Layer Meteorology. Kluwer Academic Publishers, 666p., 1988.

SUN, S.; QIAO, H.; WEI, Y.; WANG, S. (2017). A new dynamic integrated approach for wind speed forecasting. Shaolong Sun; Han Qiao; Yunjie Wei; Shouyang Wang. Appl Energy 2017;197(June):151–62. DOI: https://doi.org/10.1016/j.apenergy.2017.04.008

TASCIKARAOGLU, A.; UZUNOGLU, M. (2014). A review of combined approaches for prediction of short-term wind speed and power. Renew Sustain Energy Rev 2014; 34:243–54. DOI: https://doi.org/10.1016/j.rser.2014.03.033

TAYLOR, J. W. (2017). **Probabilistic forecasting of wind power ramp events using autoregressive logit models**. European Journal of Operational Research, volume 259, issue 2, 1 june 2017, pages 703-712. DOI: https://doi.org/10.1016/j.ejor.2016.10.041

TONG, W. (2010). **Fundamentals of wind energy.** Chapter 1, WIT Press. Wei Tong. Kollmorgen Corporation, Virginia, USA. WIT Transactions on State of the Art in Science and Engineering, Vol 44, © 2010 WIT Press. DOI: <10.2495/978-1-84564-205-1/01>

VAREJÃO-SILVA, M.A. (2006). **Meteorologia e Climatologia**. Mario Adelmo Varejão-Silva. Versão Digital 2, Recife, 2006.

VIEIRA, R.G.; ZUBEN, F.J.V.; BALLINI, R. (2016). **Previsão de Curto Prazo para a Geração de Energia Eólica usando um Modelo Ensemble de Máquinas de Aprendizado.** Rafael Giordano Vieira; Fernando Jose Von Zuben; Rosangela Ballini. SBC ENIAC-2016, Recife - PE, p.349. 2016.

WASILEWSKIA, J.; BACZYNSKIB, D. (2017). Short-term electric energy production forecasting at wind power plants in pareto-optimality context. Jacek Wasilewski; Dariusz Baczynski. Renewable and Sustainable Energy Reviews. Volume 69, March 2017, Pages 177-187. 2017. DOI: https://doi.org/10.1016/j.rser.2016.11.026>

YU, R. et al. (2019). **LSTM-EFG for wind power forecasting based on sequential correlation features.** Ruiguo Yu; Jie Gao; Mei Yu; Wenhuan Lu; Tianyi Xu; Zhao Mankun; Zhang Jie; Zhang Ruixuan; Zhuo Zhang. Future Generation Computer Systems, Volume 93, April 2019, Pages 33-42. DOI: https://doi.org/10.1016/j.future.2018.09.054>

ZAREIPOUR, H.; Dongliang H.; and Rosehart W. (2011). **Wind Power Ramp Events Classification and Forecasting: A Data Mining Approach**. Hamidreza Zareipour; Dongliang Huang; William Rosehart. 2011 IEEE Power and Energy Society General Meeting, Detroit, USA, 2011. DOI: < https://doi.org/10.1109/PES.2011.6039625>

ZHANG, J. et al. (2014). Ramp forecasting performance from improved short-term wind power forecasting. Jie Zhang; Bri-Mathias Hodge; Anthony Florita; Jeffrey Freedman. Proceedings of the ASME 2014 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference. IDETC/CIE 2014. August 17-20, 2014, Buffalo, New York, USA. Disponível em: https://www.nrel.gov/docs/fy14osti/61730.pdf>. Acesso em: 19/09/2020.

ZHOU, B. et al. (2021). Short-term prediction of wind power and its ramp events based on semi-supervised generative adversarial network. Bin Zhou, Haoran Duan, Qiuwei Wu, Huaizhi Wang, Siu Wing Or, Ka Wing Chan, Yunfan Meng. International Journal of Electrical Power & Energy Systems, Volume 125, February 2021, 106411. DOI: https://doi.org/10.1016/j.ijepes.2020.106411

ZUCATELLI, P.J.; NASCIMENTO, E.G.S.; AYLAS, G.Y.R.; SOUZA, N.B.P.; KITAGAWA, Y.K.L.; SANTOS, A.A.B.; ARCE, A.M.G.; MOREIRA, D.M. (2019a). Short-term wind speed forecasting in Uruguay using computational intelligence. Heliyon. Volume 5, Issue 5, May 2019, e01664. DOI: https://doi.org/10.1016/j.heliyon.2019.e01664>

ZUCATELLI, P.J.; NASCIMENTO, E.G.S.; ARCE, A.M.G.; MOREIRA, D.M. (2019b). **Short-Range Wind Speed Predictions in Subtropical Region Using Artificial Intelligence.** Journal of Systemics, Cybernetics and Informatics. Volume 17 - Number 4 - Year 2019. ISSN: 1690-4524. Disponível em: <http://www.iiisci.org/journal/sci/Abstracts.asp?var=&previous=ISS1904>. Acesso em: 28/06/2020.

ZUCATELLI, P.J.; NASCIMENTO, E.G.S.; SANTOS, A.A.B.; MOREIRA, D.M. (2019c). Short-term wind speed forecasting in tropical region using Wavelets and artificial intelligence. p. 365-372. In: Anais do V Simpósio Internacional de Inovação e Tecnologia. São

Paulo: Blucher, 2019. ISSN 2357-7592, DOI: <10.5151/siintec2019-46>. Disponível em: <https://www.proceedings.blucher.com.br/article-details/previso-da-velocidade-do-vento-a-curto-prazo-em-regio-tropical-utilizando-Wavelets-e-inteligncia-artificial-33286>. Acesso em: 28/06/2020.

ZUCATELLI, P.J.; NASCIMENTO, E.G.S.; SANTOS, A.A.B.; ARCE, A.M.G.; MOREIRA, D.M. (2019d). **Study of the Wind Speed Forecasting Applying Computational Intelligence** [Online First], IntechOpen, DOI: 10.5772/intechopen.89758. Disponível em: https://www.intechopen.com/online-first/study-of-the-wind-speed-forecasting-applying-computational-intelligence). Acesso em: 26/06/2020.

ZUCATELLI, P.J.; NASCIMENTO, E.G.S.; SANTOS, A.A.B.; MOREIRA, D.M. (2020). Nowcasting prediction of wind speed using computational intelligence and Wavelet in Brazil. International Journal for Computational Methods in Engineering Science and Mechanics. DOI: https://doi.org/10.1080/15502287.2020.1841335>

ZUCATELLI, P.J.; NASCIMENTO, E.G.S.; SANTOS, A.A.B.; ARCE, A.M.G.; MOREIRA, D.M. (2021). An investigation on deep learning and wavelet transform to nowcast wind power and wind power ramp: A case study in Brazil and Uruguay. Energy. DOI: https://doi.org/10.1016/j.energy.2021.120842>

APÊNDICE A

Anais de Congresso 1: Short-term wind speed forecasting in tropical region using Wavelets and artificial intelligence

A pesquisa intitulada "Short-term wind speed forecasting in tropical region using Wavelets and artificial intelligence" faz parte de Anais de Congresso e foi apresentada no V International Symposium on Innovation and Technology (V SIINTEC) em 2019, evento organizado pelo SENAI CIMATEC em Salvador – Bahia. O trabalho foi publicado nos Anais de Congresso Blucher Engineering Proceedings (DOI: 10.5151/siintec2019-46) ISSN: 2357-7592. <https://www.proceedings.blucher.com.br/article-details/previso-da-velocidade-do-vento-acurto-prazo-em-regio-tropical-utilizando-wavelets-e-inteligncia-artificial-33286>. Esta pesquisa foi pioneira na aplicação do modelo híbrido envolvendo o processamento de sinais via decomposição Wavelet e inteligência computacional para previsão da velocidade do vento até 12 h a frente usando dados atmosféricos medidos a 100 m no sítio tropical Mucuri, extremo sul da Bahia. Por meio desta pesquisa foi descoberto de forma empírica que a função Wavelet discreta Meyer é a mais precisa na filtragem passa baixa e passa alta dos sinais de velocidade. Tal resultado vai ao encontro de resultados publicados posteriormente por pesquisadores chineses usando dados de vento de sítios da China, também de forma empírica. Este trabalho foi base fundamental para o desenvolvimento do Artigo 4 citado no capítulo 6 subtópico 6.4.



PREVISÃO DA VELOCIDADE DO VENTO A CURTO PRAZO EM REGIÃO TROPICAL UTILIZANDO WAVELETS E INTELIGÊNCIA ARTIFICIAL

Pedro Junior Zucatelli¹; Erick Giovani Sperandio Nascimento²; Alex Álisson Bandeira Santos²; Davidson Martins Moreira²

 ¹Federal University of Espírito Santo, Av. Fernando Ferrari, 514, Goiabeiras, 29075-910; Vitória/Espírito Santo; pedrojrzucatelli@gmail.com
²Manufacturing and Technology Integrated Campus SENAI CIMATEC, Av. Orlando Gomes, 1845, Piatã, 41650-010; Salvador/Bahia

Resumo: Neste trabalho, é apresentado a previsão da velocidade do vento a curto prazo na região tropical de Mucuri, Bahia, Brasil, aplicando algoritmo de aprendizado de máquina supervisionado por meio da Rede Neural *Multilayer Perceptron*, Rede Neural Recorrente e Decomposição Wavelet, isto para a série temporal horária representativa deste local. Para treinar a Rede Neural Artificial (RNA) e validar a técnica, dados anemométricos de um mês foram coletados por uma torre anemométrica com altura de 100 m. Diferentes famílias de Wavelets e diferentes configurações de RNA foram aplicadas para este local e altura. Com base nos resultados alcançados, pode-se concluir que o método proposto (RNN + Meyer Wavelets) apresentou os melhores resultados no horizonte de previsão de curto prazo, isto é, 12 h à frente.

Palavras-Chave: Ciência Atmosférica; Ciência Computacional; Energia.

SHORT-TERM WIND SPEED FORECASTING IN TROPICAL REGION USING WAVELETS AND ARTIFICIAL INTELLIGENCE

Abstract: In this paper, the short-term wind speed forecasting in the tropical region of Mucuri, Bahia, Brazil, applying supervised machine learning algorithm by Multilayer Perceptron Neural Network, Recurrent Neural Network technique and Wavelet Packet Decomposition to the hourly time series representative of the site is presented. To train the Artificial Neural Network (ANN) and validate the technique, data for one month were collected by an anemometric tower at height of 100.0 m. Different Wavelet families and different ANN configurations were applied for this site and height. Based on the outcomes of the study cases and results, it can be concluded that the proposed method (RNN + Meyer Wavelets) performed the best results in short-term forecasting horizon (12 h ahead).

Keywords: Atmospheric Science; Computer Science; Energy.



1. INTRODUCTION

The reduction of emissions of greenhouse gases into the atmosphere has led many countries to increasingly seek the development of alternative sources of energy generation, including solar and wind energy, as well as the implementation of policies for sustainable energy sources [1]. In wind energy terms, it is known that the variability of wind direction and speed throughout the day makes it difficult to decide whether or not to drive wind turbines, because in practice, it is verified that the wind resource presents temporal variations in several orders of magnitude. The use of computational models can help both the identification of locations with high wind potential and, when used operationally in daily integrations, in the short-term energy generation forecast [2]. References [3], [4] and [5] showed results of mathematical modeling and numerical simulation for short-term wind speed predictions with computational intelligence techniques, especially using Multilayer Perceptron (MLP) and Recurrent Neural Networks (RNN) with Feedforward and Backpropagation training algorithm, all with good results achieved and low associated errors.

According to the literature [6], the Empirical Wavelet Transform (EWT) can effectively identify and extract a finite number of intrinsic modes of a wind speed time series. The use of wind power generation is very challenging for current power system operations. One reason for this is that wind power is an intermittent energy, which has strong randomness and instability [7]. Another reason is that wind power is a non-dispatchable energy source, which cannot be controlled by operators in the same way as other electric power sources [8]. These problems can effectively be resolved if wind speed can be predicted accurately [9]. Therefore, improving the accuracy of short-term wind speed forecasting and developing new studies on this, are crucial for the operation of wind power plants, as in [10], [11], [12] and [13]. Furthermore, it is possible to cite recent studies of short-term wind speed forecasting, for example: [14], [15] and [5]. In all studies, when increasing the forecast interval there is an increase in the associated error of the forecasting.

In this context, this paper aimed to define the most efficient Wavelet Family, MLP and RNN configuration with Levenberg-Marquardt Backpropagation training algorithm, to predict the wind speed for 1 hour, and then infer the forecasting for 3, 6, 9 and 12 hours ahead, using as reference observational data collected from a anemometric tower installed at 100.0 m, located in the tropical region of the Mucuri city, Bahia state, Brazil northeast, for the period between November 30, 2015 until December 31, 2015. The reason for choosing this period is due to be a dry season, where the water contribution for electric energy generation is compromised, being necessary the participation of alternative sources to complement the energy demand. This study is a novel investigation related to the operation of wind power plants for Mucuri. The main contributions of this study are provided as follows: a) The innovative aspect of this work is that it uses an approach to train the model for the next hour forecasting, then recursively inferring the forecasting for the following hours, in addition to applying this artificial intelligence method targeting short-range wind speed forecasting for this height in a tropical region. b) No previous studies applied computational intelligence for short-range wind speed forecasting for this height in such a humid tropical climate region (or humid coastal region). Therefore, the results constitute a significant contribution to the scientific community. c) The short-range wind



speed forecasting model is an important contribution for reliable large-scale wind power forecasting and integration in Brazil. To reach the objective of the present work, the paper is organized as follows: section 2 presents the methodology adopted in the paper, section 3 is the numerical results and discussions, and finally, section 4 presents the conclusions.

2. METHODOLOGY

With respect to the computational procedure to perform this work, was adopted the computational intelligence model using Wavelets Packet Decomposition, Multilayer Perceptron, that is a class of feedforward artificial neural network, and Recurrent Neural Network with Levenberg-Marguardt Backpropagation training algorithm for short-range wind speed forecasting at Mucuri. According to [16], this type of neural network is the most usual for studies of this nature. Reference [17] describes that the aforementioned algorithm is the main neural network training algorithm. It is known that ANN are implemented through layers with interconnected nodes, also called neurons, and the definition of the number of layers is very variable, depending on the characteristics of each problem. They require at least three layers, being an input layer, a hidden layer and an output layer [18]. As all ANN needs to be trained, validated and tested, [19] describes that network training occurs in two phases in which each phase runs through the network in one direction. These two phases are called forward and backward. The forward phase defines the network output for a given input pattern. The backward phase uses the desired output and the output provided by the network to update the weights of its connections.

There are different possibilities for structuring an ANN, since it is necessary to select the type of neuron, the number of input parameters, the number of hidden layers, the type of training, and testing different configurations are usually employed for architecture, according to [20]. To develop an ANN model it is necessary to have a set of input parameters and an output set. These sets will be subdivided for use in two different steps: network training and validation of the produced estimates. The correct selection of the predictors is fundamental for a good performance of the model [21].

The Mucuri city is located at an altitude of 7.0 m in relation to the sea level and it has a territorial area of 1,775 km², approximately. The Mucuri's anemometer tower is located in a coastal plain, at a distance of 340.0 m from the sea, with latitude 18°1'31.52"S and longitude 39°30'51.69"W. The software used to program and perform this computational procedure was MATLAB version 7.10.0 2010, together with the NNTool (Neural Network Toolbox) graphical interface and Wavelet Analyzer. It is possible to observe, in Table 1, the information of each MLP and RNN configuration analyzed in this paper. The number of input nodes depends on the architecture being analyzed. In architecture 1 (Arch. 1), the input nodes are day, month, year, hour, wind speed (x-axis and y-axis component), air temperature, air humidity and air pressure; in architecture 2 (Arch. 2), the value depends on the Wavelet level applied to wind speed decomposition.



Table	1. MLP	and	RNN	conf	igura	tions
-------	--------	-----	-----	------	-------	-------

MLP and RNN config. and Layer	Arch. 1 MLP and RNN input node	Arch. 2 RNN + Wavelets input node	1 st hidden layer	2 nd hidden layer	Output node
Config. I	9	8; 10 or 12	9 Neurons	j la j	1
Config. II	9	8; 10 or 12	6 Neurons		1
Config. III	9	8; 10 or 12	3 Neurons	73	1
Config. IV	9	8; 10 or 12	1 Neuron		1
Config. V	9	8; 10 or 12	9 Neurons	6 Neurons	1
Config. VI	9	8; 10 or 12	6 Neurons	3 Neurons	1
Config. VII	9	8; 10 or 12	1 Neuron	1 Neuron	1

Each ANN presented in Table 1, from configurations I to VII, was trained (using Levenberg–Marquardt Backpropagation training algorithm), validated and tested to determine which would be the most efficient to perform short-term (1, 3, 6, 9 and 12 hours) wind speed forecasting. The activation functions that define the outputs of the neurons in terms of their activity levels, inserted in this simulation, were the sigmoidal function in the form of the hyperbolic tangent function (characterized as continuous, increasing, differentiable and non-linear) for hidden layers and linear function to the output layer. The Figure 1 shows the time series used in the models which consists of 744 data in total, corresponding to hourly mean data for each of the period November 30, 2015, 2:00 p.m. to December 31, 2015, 1:00 p.m.. The training set with 550 data was used for the models' training and validation. The prediction set consisting of 194 data was used to verify their accuracy during the prediction stage. As one can observe in this figure, there is noticeable data randomness and it is difficult to find a series tendency or seasonality.

Figure 1. Original wind speed time series.



In this work the neural network was trained to perform the forecasting of 1 hour ahead and then, using it, the trained network was applied to recursively infer the forecasting for the next hours of the wind speed. The computational cost of this methodology, as applied in [5], is smaller than if it were necessary to train to predict the next 12 h for each input/sample of anemometric data. Therefore, to perform the prediction, the first phase is to identify what ANN (MLP and RNN) architecture can better perform the one hour forecasting of the wind speed for each height. Afterward,



this predicted wind speed value is assigned as input for the second hour forecasting. So, it is calculated the forecast of the wind speed for the second hour. This procedure, highlighted in Figure 2, is repeated until the *n*th hour of the forecasting is reached. In this schema, the final result of the wind speed forecasting (ws) is: $ws = \sqrt{u^2 + v^2}$. Next, the same schematic idea is used with the insertion of Wavelet decompositions. Figure 3 is the schematic example of the procedure used to compute the wind speed forecasting for 1, 3, 6, 9 and 12 hours ahead forward from start time using RNN + Wavelet decomposition. In this idea, the final result of the wind speed forecasting is the sum of the predicted detail and approximation components.



Figure 3. Schematic of the procedure used to compute the wind speed forecasting for 1, 3, 6, 9 and 12 hours ahead forward from start time using RNN + Wavelet.



The Wavelet families applied to wind speed data decomposition were: Biorthogonal 3.9 level 3, Coiflet 5 level 3, Daubechies 7 level 3, Daubechies 8 level 5, Daubechies 9 level 7, Meyer level 3 and Symlet 7 level 3. In recent research, hybrid prediction models in wind power and wind speed forecasting have been proposed and investigated, which mainly contain the data preprocessing and forecast modeling [22]. The main technologies for these two modeling types are the signal decomposition algorithms and the prediction algorithms [23]. Thus, as the forecast time increases, it is expected that the quality of the predicted wind speed degrades by a certain degree, which will be evaluated in the next section: results and discussions.

3. RESULTS AND DISCUSSIONS

Whit upont x-axis

Wind speek y-axts component (v)

Ar britaniaan

Ar faridly

Airgreisure

The statistical treatment employed in the results are Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), R^2 coefficient of determination, Pearson's correlation coefficient (r) and percentage of data of factor of two. For these statistical indicators values close to 0.0 (zero) are adequate for the MAE, MSE, RMSE, MAPE errors, and values close to 1.0 (one) are adequate for the R^2 and r coefficients. Table 2 is a table comparison of the MSE and R^2 to MLP, RNN, and RNN + Wavelet. It shows that the RNN + Meyer Wavelet decomposition has the best result, as can be verified MSE = 2.89 and R^2 = 0.70.



Table 2. Table comparison of the MSE and R² to MLP, RNN, and RNN + Wavelet.

Model	Time horizon	MSE	R ²	
MLP		10.56	0.02	
RNN		7.37	0.33	
RNN + Biorthogonal Wavelets		5.43	0.58	
RNN + Coiflet Wavelets		3.96	0.59	
RNN + Meyer Wavelets	12 h ahead	2.89	0.70	
RNN + Symlet Wavelets		7.18	0.36	
RNN + Daubechies 7 Wavelets		4.93	0.56	
RNN + Daubechies 8 Wavelets		3.97	0.67	
RNN + Daubechies 9 Wavelets		4.47	0.58	

Table 3 shows the evaluation metrics of the prediction results obtained by the best proposed model, RNN + Meyer Wavelet. The percentage of the data of a factor of two for wind speed forecasting 12 h ahead is 98.90%. Figure 4 illustrate the short-range wind speed forecasting and the factor of two to RNN + Meyer Wavelet.

	Prediction horizon	MAE	MSE	RMSE	MAPE	Pearson	R ²	Percentage of the data of a factor of two
Γ	1 h	0.67	0.73	0.85	8.79%	0.95	0.91	100.0%
1	3 h	1.32	2.57	1.60	17.06%	0.85	0.73	97.38%
1	6 h	1.45	3.24	1.80	18.77%	0.81	0.66	95.74%
Γ	9 h	1.38	2.85	1.69	17.73%	0.83	0.70	98.38%
	12 h	1.37	2.89	1.70	17.30%	0.83	0.70	98.90%

Table 3. Statistical results (Errors and Regression): RNN + Meyer Wavelet.

Figure 4. Wind speed forecasting at 12 h ahead (RNN + Meyer Wavelet): a) The results of twelve-step predictions of the wind speed series. b) Comparison data of a factor of two (wind predicted/wind anemometer versus time) of the results obtained with the forecast model (twelve-step predictions) and the real data. c) Comparison data of a factor of two (wind predicted/wind anemometer versus wind anemometer) of the results obtained with the forecast model (twelve-step predictions) and the real data.





These results are important to continue research on the role of the Wavelets transforms in the decomposition of the time series of the wind speed for later wind power forecasting. It should be emphasized that the computational cost of using computational intelligence in studies such as those carried out in this work increases as the expected workload increases, but it is still lower when compared to the cost of mathematical modeling and numerical simulation for prediction of wind speed using atmospheric models such as Weather Research and Forecasting (WRF). This is because in the WRF are implemented and solved the equations of transport phenomena and fluid mechanics, such as the Euler equations for compressible and non-hydrostatic fluid, in the form of fluxes, using conservative variables [24]. The proposed model can be used to identify optimal locations of wind turbines and forecast irregular wind energy, for different heights. Short-term wind energy forecasting can be improved using this model to enhance the wind power quality 12 h ahead.

4. CONCLUSION

In the light of the statistical results recorded in this work, the application of computational intelligence is a viable alternative for the predictability of wind speed and, in this way, wind power generation, mainly due to the low computational cost, however one must choose the RNN + Wavelet decomposition architecture that best suits the project, as well as quantitatively and qualitatively analyzes the available data that will feed the network, since these variables directly impact the results of the forecast. These results are presented as a novelty, since other works that used this computational model to predict wind speed for 1, 3, 6, 9 and 12 hours ahead in Brazil, especially in the Bahia state, were not found in the literature, particularly for very high positions of the anemometers, where wind turbines are usually positioned. Especially, it can be pointed out that the study presented good results, and, as the forecast time increases, the produced results not degrade, as expected, making it possible to use this technique to produce satisfactory forecasts of wind speed for short-term applications (till 12 hours ahead) with low computational costs, in order to help wind farm operators in decision-making processes. It is suggested as future work compare these results with the output produced by meteorological modelling (WRF model).

ACKNOWLEDGMENT

We thank FIEB and SENAI CIMATEC for their computational support.



5. REFERENCES

- CHENG, W.Y.Y., Liu, Y., Bourgeois, A.J., Wu, Y. and Haupt, S.E., 2017. Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation. Renewable Energy 107, 340-351.
- 2 PENG, H., Liu, F. and Yang, X., 2013. A hybrid strategy of short-term wind power prediction. Renewable Energy 50, 590-595.
- WASILEWSKIA, J. and Baczynski, D., 2017. Short-term electric energy production forecasting at 3 wind power plants in pareto-optimality context. Renewable and Sustainable Energy Reviews 69, 177-
- LIU, H., Mi, X., Li, Y., 2018. Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short-term memory neural network and Elman neural network. Hui Liu; Xi-wei Mi; Yan-fei Li. Energy Conversion and Management. Volume 156, 15 January 2018, Pages 498-514. 2018.
- 5 ZUCATELLI, P.J., Nascimento, E.G.S., Aylas, G.Y.R., Souza, N.B.P., Kitagawa, Y.K.L., Santos, A.A.B., Arce, A.M.G., Moreira, D.M., 2019. Short-term wind speed forecasting in Uruguay using computational intelligence. Heliyon, Volume 5, Issue 5, May 2019, e01664.
- 6 HU, J., Wang, J., Xiao, L., 2017. A hybrid approach based on the Gaussian process with tobservation model for short-term wind speed forecasts. Renew Energy 2017; 114:670-85.
- ZHANG, J., Wei, Y., Tan, Z., Wang, K., and Tian, W., 2017. A Hybrid Method for Short-TermWind Speed Forecasting. Sustainability 9, 596.
- 8 ERDEM, E. and Shi, J., 2011. ARMA based approaches for forecasting the tuple of wind speed and
- direction. Appl. Energy 88, 1405–1414. LIU, H.P., Shi, J. and Erdem, E., 2010. Prediction of wind speed time series using modified Taylor Kriging method. Energy 35, 4870–4879.
- 10 LI, G., Shi, J. and Zhou J., 2011. Bayesian adaptive combination of short-term wind speed forecasts from neural network models. Renew Energy, 36, 352 – 9.
- AKINCI, T.C., 2011. Short term wind speed forecasting with ANN in Batman, Turkey. Electron Electr Eng 1(107), 41-5.
- 12 NOGAY, H.S., Akinci, T.C. and Eidukeviciute, M., 2012. Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey. J. energy South. Afr. 23(4), 2-7.
- OKUMUS, I. and Dinler, S., 2016. Current status of wind energy forecasting and a hybrid method for hourly predictions. Energy Conversion and Management 123, 362-371.
- 14 LIU, D., Wang, J. and Wang, H. 2015. Short-term wind speed forecasting based on spectral clustering and optimized echo state networks. Renew Energy 78, 599-608
- 15 HU, Q., Zhang, R. and Zhou, Y., 2016. Transfer learning for short-term wind speed prediction with deep neural networks. Renew Energy 85, 83-95.
- ¹⁶ QIN, S., Liu, F., Wang, J. and Song, Y., 2015. Interval forecasts of a novelty hybrid model for wind speeds. Energy 1, 8-16.
- 17 CERVONE, G., Clemente-Harding, L., Alessandrini, S. and Monache, L.D., 2017. Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble. Renewable Energy 108, 274-286.
- ¹⁸ RUSSEL, S. and Norvig, P., 2010. Artificial Intelligence: A Modern Approach. Stuart J. Russell and Peter Norvig. Third Edition. Pearson Education, Inc., 1153p.
- PELLETIER, F., Masson, C. and Tahan, A., 2016. Wind turbine power curve modelling using artificial 19 neural network. Renewable Energy 89, 207-214.
- 20 HAYKIN, S., 1999. Neural Networks: A Comprehensive Foundation. Simon Haykin. Second Edition. Pearson Education Inc. Hamilton, Ontario, Canada, 823p.
- MORI, H. and Umezawa, Y., 2009. Application of NBTree to Selection of Meteorological Variables in Wind Speed Prediction, transmission & Distribution Conference & Exposition: Asia and Pacific, Seoul, Korea, 2009.
- 22 SUN S, Qiao H, Wei Y, Wang S., 2017. A new dynamic integrated approach for wind speed forecasting. Appl Energy 2017;197(June):151-62.
- TASCIKARAOGLU A, Uzunoglu M., 2014. A review of combined approaches for prediction of shortterm wind speed and power. Renew Sustain Energy Rev 2014; 34:243-54.
- 24 SKAMAROCK, W.C., Klemp, J.B., Dudhia, J., Gill, D.O., Barker, D.M., Huang, X.Y., Wang, W. and Powers, J.G., 2008. A Description of the Advanced Research WRF Version 3 (NCAR Technical Note), Mesoscale and Microscale Meteorology Division do NCAR. Boulder, Colorado, USA.