

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MODELO HÍBRIDO BASEADO EM SÉRIES TEMPORAIS E REDES NEURAIS PARA
PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA

DAVID BARBOSA DE ALENCAR

TD:10/2018

UFPA/ITEC/PPGEE
Campus Universitário de Guamá
Belém – Pará – Brasil
2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DAVID BARBOSA DE ALENCAR

MODELO HÍBRIDO BASEADO EM SÉRIES TEMPORAIS E REDES NEURAIIS PARA
PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA

UFPA/ITEC/PPGEE
Campus Universitário de Guamá
Belém – Pará – Brasil
2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DAVID BARBOSA DE ALENCAR

MODELO HÍBRIDO BASEADO EM SÉRIES TEMPORAIS E REDES NEURAIS PARA
PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA

Tese de doutorado apresentada à coordenação do Programa de pós-graduação em Engenharia Elétrica (PPGEE) do Instituto de Tecnologia (ITEC) da Universidade Federal do Pará (UFPA) como parte dos requisitos finais para obtenção do grau de Doutor em Engenharia Elétrica.

UFPA/ITEC/PPGEE
Campus Universitário de Guamá
Belém – Pará – Brasil
2018

Ficha catalográfica

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

- B238m Barbosa de Alencar, David
 MODELO HÍBRIDO BASEADO EM SÉRIES TEMPORAIS E REDES NEURAIAS PARA PREVISÃO
 DA GERAÇÃO DE ENERGIA EÓLICA / David Barbosa de Alencar. — 2018
 120 f. : il. color
- Tese (Doutorado) - Programa de Pós-graduação em Engenharia Elétrica (PPGEE), Instituto de
 Tecnologia, Universidade Federal do Pará, Belém, 2018.
 Orientação: Profa. Dra. Carolina de Mattos Affonso
 Coorientação: Prof. Dr. Roberto Célio Limão de Oliveira.
1. Energia eólica. 2. Velocidade do vento. 3. Séries temporais. 4. SARIMA. 5. Redes Neurais Artificiais.
 I. de Mattos Affonso, Carolina, *orient.* II. Título
-

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA - ITEC
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

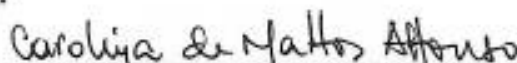
MODELO HÍBRIDO BASEADO EM SÉRIES TEMPORAIS E REDES NEURAI PARA
PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA

AUTOR: DAVID BARBOSA DE ALENCAR

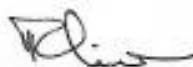
TESE DE DOUTORADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO
COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO
JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA
ELÉTRICA NA ÁREA DE SISTEMAS DE ENERGIA ELÉTRICA.

APROVADA EM: 30/08/2018

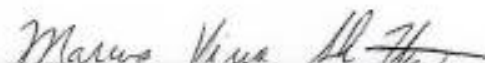
BANCA EXAMINADORA:



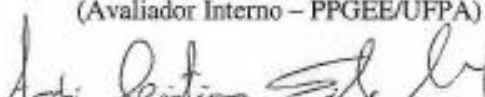
Prof.ª Dr.ª Carolina de Mattos Affonso
(Orientadora – UFPA)



Prof. Dr. Roberto Célio Limão de Oliveira
(Co-Orientador – PPGEE/UFPA)



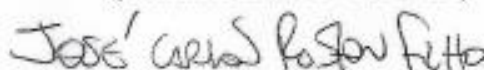
Prof. Dr. Marcus Vinícius Alves Nunes
(Avaliador Interno – PPGEE/UFPA)



Prof. Dr. André Cristiano Silva Melo
(Avaliador Externo – UEPA)



Prof. Dr. Jandecy Cabral Leite
(Avaliador Externo – ITEGAM)



Prof. Dr. José Carlos Reston Filho
(Avaliador Externo – UFAM)

VISTO:

Prof.ª Dr.ª Maria Emilia de Lima Tostes
(Coordenadora do PPGEE/ITEC/UFPA)

Dedicatória

À Deus, meus pais Alexandre e Nely, irmãos José Neto e Ana Priscila, à família Gisele (esposa), Camila (filha) e Gabriele (Cunhada).

AGRADECIMENTOS

Agradeço à Deus por tudo e por conceder-me o fascínio pelo conhecimento e propiciar-me disciplina e força para continuar estudando.

Aos meus pais Alexandre Ferreira de Alencar e Nely Barbosa de Alencar por terem instruído-me neste caminho do qual não me desviei. Aos meus irmãos por estarem sempre presentes na minha vida e por terem orgulho de mim.

Agradeço à minha esposa Gisele de Freitas Lopes e minha filha Camila Lopes, pela compreensão que têm pela minha dedicação aos estudos. Agradeço à Gabriele Lopes no apoio computacional em diversos títulos.

Agradeço aos familiares, parentes, colegas e amigos que esperam por minhas vitórias, e aos colegas de aula que sempre me ajudaram.

Agradeço à minha Orientadora, Professora Carolina de Mattos Affonso, e ao meu Coorientador Professor Roberto Célio Limão que já me acompanha desde o mestrado, pela paciência, confiança, pelo apoio nos momentos que quis me desviar, mas suas orientações me trouxeram sempre para o caminho correto.

Agradeço ao meu amigo Dr. Jandecy Cabral Leite, por dedicar sua vida ao ITEGAM e por proporcionar oportunidade de mudança de vida à muitos, por ter acreditado em meu potencial, e ter me dado apoio constante nesta jornada.

Agradeço ao Dr. José Carlos Reston Filho que me ajudou nos passos iniciais do software utilizado neste trabalho e nas orientações que foram cruciais nos momentos decisivos.

Agradeço ao Ph.D. P.E. Jorge Laureano Moya Rodríguez que deu apoio no entendimento aos recursos de inteligência computacional e orientações gerais.

Aos meus amigos de turma do curso de doutorado e do ITEGAM, Jorge Almeida Brito Júnior, Manoel Henrique Reis Nascimento, Carlos Alberto Freitas de Oliveira, Nadime Mustafa, Milton Fonseca Júnior e outros que fizeram parte da caminhada, também aos colegas e amigos conquistados neste curso.

Agradeço aos professores do programa de pós-graduação em engenharia elétrica do ITEC-UFPA, e todos os outros que me guiaram por esse novo caminho.

Agradeço aos meus amigos e colegas da Moto Honda de onde tive que sair para poder conquistar o sonho do doutorado.

Agradeço ao Governo do Estado do Amazonas, e Fundação de Amparo à pesquisa do Amazonas - FAPEAM, pela concessão da bolsa de estudo.

Epígrafe

*“Entrega o teu caminho ao Senhor, confia nele, e o mais ele fará”
Salmos 37:5*

LISTA DE FIGURAS

Figura 1.1: Número de usinas eólicas em operação comercial em todo o país no ano 2017.	18
Figura 2.1: Comportamento dos ventos.	29
Figura 2.2: Esquema geral de funcionamento de um aerogerador.	30
Figura 2.3: Desenho esquemático de turbina eólica.	31
Figura 2.4: Curva de Potência da Turbina.	35
Figura 3.1: Metodologia Box-Jenkins para a modelagem de séries temporais.	51
Figura 3.2: Modelo básico de um neurônio artificial.	53
Figura 3.3: Exemplos de arquiteturas de Redes Neurais Artificiais (RNA).	54
Figura 3.4: Fluxo de processamento do algoritmo backpropagation.	56
Figura 4.1: Exemplo de validação de dados da SONDA.	65
Figura 4.2: Comportamento das séries temporais componentes do banco de dados do estudo	66
Figura 4.3: Diagrama de blocos do modelo híbrido proposto	68
Figura 5.1: Diagrama de blocos do modelo primeira etapa – SARIMA	73
Figura 5.2: Diagrama de blocos do modelo segunda etapa – SARIMA+RN1.	75
Figura 5.3: Diagrama de blocos do modelo híbrido proposto etapa final (SARIMA+RN1+RN2).	76
Figura 5.4: Curva de potência do aerogerador WES100.	78
Figura 5.5: Geração de energia anual em kWh.	79
Figura 5.6: Velocidade prevista ultra curto prazo minutos em m/s.	85
Figura 5.7: Potência gerada prevista ultra curto prazo minutos kW.	86
Figura 5.8: Velocidade prevista curto prazo horas em m/s.	88
Figura 5.9: Potência gerada prevista Curto Prazo horas em kW	89
Figura 5.10: Velocidade prevista médio prazo dias em m/s.	91
Figura 5.11: Potência Gerada Prevista Médio Prazo Dias em kW.	92
Figura 5.12: Velocidade prevista médio prazo semanas em m/s.	94
Figura 5.13: Potência Gerada Prevista médio Prazo em semanas em kW.	95
Figura 5.14: Velocidade prevista longo prazo meses em m/s.	97
Figura 5.15: Potência Gerada Prevista longo Prazo em meses em kW.	98
Figura 5.16: Velocidade prevista longo prazo anos em m/s	100
Figura 5.17: Potência Gerada Prevista médio Prazo em anos em kW.	101
Figura 5.18: Energia média anual Prevista Longo Prazo em anos em kWh.	102
Figura 5.19: Velocidade Prevista (horas) em m/s - Macau/RN.	106
Figura 5.20: Potência Prevista (horas) em KW - Macau/RN.	107
Figura 5.21: Velocidade Prevista (horas) em m/s - Petrolina/PE.	107
Figura 5.22: Potência Prevista (horas) em kW - Petrolina/PE.	108

LISTA DE TABELAS

Tabela 1. 1: Comparação dos diferentes modelos e erros encontrados na literatura.	23
Tabela 2.1: Curva de Potência da Turbina.	36
Tabela 3.1: Classificação das escalas de tempo para a previsão do vento.	38
Tabela 4.1: Localização das diferentes estações eólicas.	63
Tabela 4.2: Atributos das variáveis do banco de dados.	65
Tabela 4.3; Correlação entre as séries temporais.	67
Tabela 4.4: Análise estatística dos dados das séries temporais.	67
Tabela 5.1: Padrão dos horizontes de previsão.	72
Tabela 5.2: Modelo SARIMA para cada horizonte.	74
Tabela 5.3: Resultados dos Erros para Previsão Multipassos Ultra Curto Prazo (Minutos).	82
Tabela 5.4: Resultados dos Erros para Previsão Multipassos Curto Prazo (Horas).	87
Tabela 5.5: Resultados dos Erros para Previsão Multipassos Médio Prazo (Dias).	90
Tabela 5.6: Resultados dos Erros para Previsão Multipassos Médio Prazo (Semanas).	93
Tabela 5.7: Resultados dos Erros para Previsão Multipassos Longo Prazo (Meses).	96
Tabela 5.8: Resultados dos Erros para Previsão Multipassos Longo Prazo (Anos).	99
Tabela 5.9: Resultados dos Erros para previsão nas diferentes estações do ano.	103
Tabela 5.10: Resultados dos Erros para previsão da velocidade do vento com três e cinco variáveis.	104
Tabela 5.11: Resultados dos Erros entre diferentes bases de dados -Petrolina/PE e Macau/RN.	105

LISTA DE ABREVIATURAS

ABEEÓLICA	Associação Brasileira de Energia Eólica
ACF	Função de autocorrelação
ANEEL	Agência Nacional de Energia Elétrica
AR	Autoregressivo
ARIMA	<i>Autorregressive Integrated Moving Average</i>
ARMA	<i>Autorregressive Moving Average</i>
BAL	Balanceamento
BSRN	<i>Baseline Surface Radiation Network</i>
CL	Correlação linear
CNPE	Conselho Nacional de Pesquisa Energética
CP	Curto prazo
DP	Desvio padrão
EPE	Empresa de pesquisa energética
IEEE	<i>Institute Of Electrical and Eletronics Engineers</i>
LP	Longo prazo
MA	Moving average
MAE	Erro Médio Absoluto
MAPE	Erro Médio Percentual Absoluto
MLP	<i>Multilayer Perceptron</i>
MME	Ministério de minas e energia
MP	Médio prazo
NARX	<i>Nonlinear Autoregressive Exogenous</i>
NWP	<i>Numeric Weather Prediction</i>
ONS	Operador nacional do sistema
PACF	<i>Partial Autocorrelation Function</i>
PCA	<i>Principal Components Analysis</i>
PIM	Polo Industrial de Manaus
PROCEL	Programa Nacional de Conservação de Energia
RMSE	Erro Médio Quadrático
RNA	Redes Neurais Artificiais
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>
UCP	Ultracurto prazo
VMED	Velocidade média

RESUMO

A geração de energia elétrica através de turbinas eólicas é uma das alternativas praticamente inesgotáveis de geração de energia elétrica. Ela é considerada uma fonte de energia limpa, porém ainda necessita de muita pesquisa para desenvolvimento de ciência e tecnologias que assegurem uma uniformidade na geração, propiciando uma maior participação desta fonte na matriz energética tanto no Brasil quanto no mundo, pois o vento apresenta bruscas variações na velocidade, densidade e em outras variáveis importantes. Nos sistemas elétricos de base eólica, cada horizonte de previsão é aplicado em um determinado segmento específico, previsão de minutos, horas, semanas, meses e anos futuros do comportamento do vento, desta forma pode-se avaliar a disponibilidade de energia para o próximo período, uma informação relevante no despacho das unidades geradoras e no controle do sistema elétrico. Esta tese teve como proposta, desenvolver modelos de previsão a ultra curto, curto, médio e longo prazo da velocidade do vento, baseado em técnicas de inteligência computacional, usando modelos de Redes Neurais Artificiais, SARIMA e modelos híbridos e prever a capacidade da geração de potência para cada horizonte. Para aplicação da metodologia utilizou-se as variáveis meteorológicas do banco de dados do sistema de organização nacional de dados ambientais SONDA, estação de Petrolina, do período de 01 de janeiro de 2004 à 31 de março de 2017. O desempenho dos modelos foi comparado com 5, 10 e 20 passos para frente, considerando minutos, horas, dias, semanas, meses e anos como horizonte de previsão. O modelo híbrido obteve melhor resposta na previsões dentre as quais destacou-se o horizonte de horas.

PALAVRAS CHAVE: Energia eólica; Velocidade do vento; Séries temporais; SARIMA; Redes Neurais Artificiais; Previsão.

ABSTRACT

The electric power generation through wind turbines is one of the practically inexhaustible alternatives sources of electric power. It is considered a source of clean energy, but still requires a lot of research to develop science and technologies that ensure uniformity in generation, providing a greater participation of this source in the energy matrix in Brazil as in the world, because the wind presents abrupt variations speed, density, and other important variables. In wind-based electrical systems, each forecast horizon is applied to a specific segment, forecast of minutes, hours, weeks, months, and future years of wind behavior, in order to evaluate the availability of energy for the next period, relevant information in the dispatch of the generating units and in the control of the electric system. This thesis aimed to develop ultra-short, short, medium and long-term prediction models of wind speed, based on computational intelligence techniques, using Artificial Neural Networks, SARIMA models and hybrid models and to predict the generation capacity of power for each horizon. For the application of the methodology, the meteorological variables of the database of the national environmental data system SONDA, Petrolina station, were used for the period from January 1st, 2004 to March 31st, 2017. The performance of the models was compared with 5, 10 and 20 steps forward, considering minutes, hours, days, weeks, months and years as the forecast horizon. The hybrid model obtained better response in the forecasts, among which the hour horizon was highlighted.

KEYWORDS: Wind power; Wind speed; Time series; SARIMA; Artificial Neural Networks; Forecasting.

SUMÁRIO

CAPÍTULO 1	16
1. INTRODUÇÃO	16
1.1. Motivação.....	16
1.2. Objetivos	19
1.3. Contribuição e Relevância do tema	19
1.4. Importância	20
1.5. Delimitação da Pesquisa.....	20
1.6. Estado da Arte	21
1.7. Estrutura da tese	25
1.8. Considerações Finais	25
CAPÍTULO 2.....	26
2. PANORAMA DA ENERGIA EÓLICA.....	26
2.1. Visão Histórica.....	26
2.2 Recursos Eólicos	28
2.3 Características Básicas da Tecnologia Eólica.....	30
2.3.1. Principais componentes de um aerogerador	31
2.4. Produção de Energia Eólica.....	32
2.5. Considerações Finais	36
CAPÍTULO 3.....	38
3. MÉTODOS E MODELOS PARA PREDIÇÃO E CLASSIFICAÇÃO DE SÉRIES TEMPORAIS	38
3.1 Modelos de previsão de velocidade de ventos	38
3.1.1 Modelo Físico.....	39
3.1.2 Modelos Estatísticos	40
3.1.3 Modelos Híbridos	40
3.2 Séries Temporais	41
3.2.1 Séries Temporais Estacionárias	42
3.2.2 Séries Temporais Não-Estacionárias	43
3.3 Modelos de Box-Jenkins	44
3.3.1 Modelo Autorregressivo (AR).....	44
3.3.2. Modelo de Médias Móveis (MA).....	45
3.3.3 Modelos Autorregressivos de Médias Móveis (ARMA)	46
3.3.4. Modelos Autorregressivos Integrados de Médias Móveis (ARIMA)	47

3.3.5 Modelo auto-regressivo integrado sazonal de médias móveis SARIMA	48
3.4 A Metodologia Box-Jenkins	49
3.5 Redes Neurais Artificiais	52
3.5.1 Algoritmo de Retropropagação (Backpropagation)	55
3.6. Uso de Wavelets	57
3.7. Considerações finais	58
CAPÍTULO 4	61
4. METODOLOGIA	61
4.1 Introdução	61
4.2 Etapas da pesquisa	61
4.3. Banco de dados	63
4.4. Modelo de previsão proposto	67
4.5 Considerações finais	70
CAPÍTULO 5	71
5. RESULTADOS OBTIDOS, VALIDAÇÃO EXPERIMENTAL E ANÁLISE	71
5.1 Introdução	71
5.2. Apresentação dos modelos propostos e comparativos	71
5.2.1 Modelo SARIMA	73
5.2.2 Modelo SARIMA+RN1	75
5.2.3 Modelo híbrido proposto (SARIMA+RN1+RN2)	76
5.2.4 Modelo Redes Neurais Artificiais	77
5.3. Previsão da Velocidade e da Potência	78
5.4. ANÁLISE DOS RESULTADOS	80
5.4.1 Previsão a ultra curto prazo - UCP (minutos)	80
5.4.2 Previsão à Curto Prazo - CP (horas)	87
5.4.3 Previsão a Médio Prazo - MP (dias)	90
5.4.4 Previsão a Médio Prazo - MP (semanas)	93
5.4.5 Previsão a Longo Prazo - LP (meses)	96
5.4.6 Previsão a Longo Prazo - LP (anos)	99
5.4.7 Comportamento do modelo em diferentes estações do ano	102
5.4.8 Comportamento do modelo sem considerar a temperatura e a pressão.	103
5.4.9 Comportamento dos modelos em diferentes bases de dados	104
5.4.9.1 Gráficos do comportamento dos modelos em diferentes bases de dados	106
CAPÍTULO 6	109
6. CONCLUSÕES	109
6.1 SUGESTÕES PARA TRABALHOS FUTUROS	110

REFERÊNCIAS.....	111
------------------	-----

CAPÍTULO 1

1. INTRODUÇÃO

1.1. Motivação

O aumento da demanda de energia elétrica no Brasil é crescente, de tal forma que, o Operador Nacional do Sistema Elétrico (ONS) (FILHO *et al.*, 2014) aponta que já no início de 2014, foi quebrado mais um recorde de demanda instantânea de energia elétrica ao Sistema Interligado Nacional (SIN), com um total de 85.708 megawatts médios (MWm).

Apesar de permanecer predominantemente hidrelétrica, a estrutura da matriz elétrica brasileira mudou bastante nos últimos anos. Em 2001, quando o país sofreu um racionamento de energia elétrica, 90% da capacidade instalada era hidrelétrica e somente 10% eram termelétricas. Em razão do racionamento foi instituído o Programa Prioritário de Termelétricas que contribuiu para a alteração da matriz brasileira.

A tendência é que as alterações na matriz continuem e o Plano Decenal de Expansão da Energia projeta uma participação das hidrelétricas de 57% em 2024. Então, a participação das termelétricas, mas, principalmente as fontes eólica e solar ganhariam maior destaque, somadas todas as fontes renováveis (hidrelétricas, eólicas, solar e biomassa) a tendência é que continuem a representar 80% a 85% da potência instalada no Brasil até 2024 (MOREIRA, 2017).

Em 2015 o cenário mostrou a fragilidade da matriz energética brasileira, com características parecidas com a crise de 2001, mas desta vez apoiada pelo uso das termelétricas que conseguiram suprir a demanda de energia, uma estratégia que por um lado atende a demanda mas que por outro lado agride de forma irreversível e desnecessária o meio ambiente.

As termoelétricas são deletérias ao meio ambiente, pois há liberação de gases responsáveis pelo efeito estufa, provenientes da queima de combustíveis fósseis, além de ocasionar o aumento do preço da energia pelo uso da geração térmica.

Por essa razão há uma necessidade crucial na evolução paralela da oferta com a demanda de energia elétrica, e devido ao crescimento desenfreado e tantos danos causados ao meio ambiente, tem-se a necessidade do uso de fontes alternativas de geração de energia limpa e renovável.

A energia eólica tem sido inserida de forma expressiva na matriz energética em diversos países. No Brasil, este processo ainda está em desenvolvimento, e a inserção da geração eólica na matriz energética brasileira tem ocorrido de forma gradativa, com o objetivo de diversificação para minimizar a falta de recursos hídricos na época de estiagem, além dos impactos causados por crises internacionais que afetam o mercado de combustíveis fósseis (MARTINS *et al.*, 2008).

A produção de energia eólica em operação comercial no SIN, entre janeiro e julho de 2017, foi 25,3% superior à geração no mesmo período do ano 2016, segundo dados consolidados do boletim mensal divulgado pela Câmara de Comercialização de Energia Elétrica (CCEE, 2018).

Ao todo, 446 usinas eólicas estão em operação comercial no país, somando 11,3 GW de capacidade instalada, incremento de 19,7% frente à capacidade das 371 unidades geradoras existentes em julho de 2016, segundo os dados da CCEE. Se consideradas as usinas em fase de teste, o país já possui 12,18 GW de capacidade instalada e 486 parques eólicos.

As usinas eólicas em operação produziram um total de 3.794 MW médios frente aos 3.029 MW médios gerados no mesmo período de 2016 (CCEE, 2018). Na figura 1.1 se oferece uma comparação dos estados com maior geração de energia eólica no Brasil.




Figura 1.1: Número de usinas eólicas em operação comercial em todo o país no ano 2017.
Fonte: (BARBOSA, 2017).

Apesar das diversas vantagens relacionadas ao uso da energia eólica, a mesma é uma fonte de energia não despachável, ou seja, não controlada, cuja disponibilidade depende do recurso natural primário que é o vento. Variações na velocidade do vento que podem ocorrer em curtos intervalos de tempo implicam em variações na produção de eletricidade.

Assim, a produção da energia eólica varia de acordo com as condições climatológicas, tendo, portanto, um comportamento estocástico. Neste sentido, faz-se necessário o desenvolvimento de métodos precisos para realizar a previsão dos ventos para geração de energia eólica, possibilitando assim sua inserção na matriz energética de forma confiável e segura.

1.2. Objetivos

Objetivo Geral.

Desenvolver um modelo de previsão da velocidade do vento para geração de energia eólica, utilizando metodologia baseada em um sistema híbrido composto pelos modelos Autorregressivo Integrado de Médias Móveis considerando a Sazonalidade (SARIMA) e Redes Neurais Artificiais (RNA), utilizando variáveis explanatórias.

Objetivos específicos.

- Analisar de forma comparativa os diferentes métodos de previsão da velocidade do vento e da energia eólica;
- Desenvolver um modelo híbrido para a previsão da velocidade do vento e da energia eólica;
- Programar e aplicar o novo modelo;
- Comparar os resultados obtidos com os modelos já existentes;

1.3. Contribuição e Relevância do tema

Embora existam vários trabalhos na literatura relacionados com séries temporais e o seu uso para previsão da velocidade do vento e da energia eólica, existe uma lacuna pertinente aos modelos híbridos e a comparação de resultados por diferentes abordagens.

Os modelos mais utilizados para a previsão de energia eólica podem ser citados os seguintes: modelo auto-regressivo de médias móveis (ARMA) (BIZRAH e AL-MUHAINI, 2017), modelo auto-regressivo integrado de médias móveis (EYMEN e KÖYLÜ, 2018), redes neurais artificiais (YADAV e SAHU, 2017) e ondaletas (CHANG *et al.*, 2017). Dentre os trabalhos mais destacados com o uso de sistemas híbridos, pode-se destacar o trabalho de (CADENAS e RIVERA, 2009) que combina o modelo ARIMA com uma Rede Neural Artificial.

No tema relacionado com o tempo para o qual é feita a previsão, se destacam quatro cenários: ultra curto prazo (NIU *et al.*, 2018), curto prazo (SONG *et al.*, 2018), médio prazo (WANG *et al.*, 2015) e longo prazo (AZAD *et al.*, 2014). Dentre eles os mais usados na literatura revisada são a previsão a ultracurto prazo e a curto prazo.

Partindo da premissa dos diversos modelos existentes na literatura e as dificuldades encontradas em lidar com as diferenças de resultados, métodos e intervalos de tempo, despertou o interesse em conhecer, analisar e propor métodos mais precisos para a previsão da velocidade do vento e da energia eólica para os diferentes prazos temporais.

Portanto, o ineditismo dessa proposta se apresenta pela necessidade de ter um modelo de previsão mais consistentes para prever a velocidade do vento e a energia eólica para os diferentes cenários de tempo. Este modelo baseou-se na integração do modelo SARIMA com duas Redes Neurais Artificiais.

1.4. Importância

A cada dia o mundo procura por novas fontes de energia renovável, dentre elas a mais utilizadas e de maior destaque é a energia eólica, mas ela apresenta uma forte restrição quanto ao seu emprego, devido à grande dificuldade em prever suas variações, causando grandes incertezas quanto ao seu planejamento e uso mais eficiente.

O Brasil ainda carece de uma matriz energética diversificada – uma vez que hoje depende, principalmente, das hidrelétricas e termelétricas – mas a fonte que mais cresce no país atualmente é a energia eólica.

A participação dessa alternativa renovável vai saltar dos atuais 3% para 8% neste ano 2018. Segundo o último boletim da Associação Brasileira de Energia Eólica - ABEEOLICA, divulgado na segunda semana de fevereiro de 2018, em seis anos, a capacidade instalada dessa fonte no país vai aumentar quase 300% (EOLICA, A, 2018). Portanto, é importante o Brasil ter métodos mais precisos de previsão da velocidade do vento e da energia eólica.

1.5. Delimitação da Pesquisa

As delimitações desta pesquisa abrangem o escopo da previsão da velocidade do vento por diferentes métodos e para diferentes cenários de tempo.

O modelo híbrido desenvolvido pode ser aplicado para qualquer cenário de tempo e para qualquer cidade ou parque eólico do Brasil e do mundo, permitindo uma melhor previsão ao combinar o modelo SARIMA com duas Redes Neurais Artificiais. O método é capaz de prever a velocidade do vento e a potência e energia eólica a gerar em função de dados meteorológicos e do tipo de turbina eólica utilizada.

Neste estudo foi considerado apenas o aere gerador WES100, e a base de dados principal foi da cidade de Petrolina-PE.

1.6. Estado da Arte

A previsão da velocidade do vento pode ser realizada em um horizonte de curto prazo ou longo prazo de acordo com a aplicação em questão. Para a previsão de curto prazo utiliza-se um intervalo de previsão maior do que 30 minutos e menor do que 6 horas. Este horizonte de tempo é usualmente necessário para realizar o despacho das unidades geradoras, atendimento da carga, comercialização de energia e etc.

Já o horizonte de longo prazo, é utilizado para planejar a manutenção dos parques eólicos, comissionamento dos geradores e para programação da manutenção da rede (LEI et al., 2009).

A previsão da geração de energia eólica é uma tarefa complexa devido à aleatoriedade e intermitência do vento (ZHANG *et al.*, 2014). Neste sentido, diversos trabalhos têm sido publicados na literatura propondo metodologias para previsão da velocidade do vento (MONFARED *et al.*, 2009; OLAOFE e FOLLY, 2012; LIU, Y. *et al.*, 2017).

Segundo (MAKWANA e GANDHI, 2018), a injeção de energia eólica é de natureza intermitente e é um dos fatores mais importantes a levar em conta para definir os limites de desvio de energia em valores aceitáveis. Os autores propõem uma previsão de energia eólica de curto prazo baseada em redes neurais artificiais usando uma rede neural *feedforward*.

Foram estudados diferentes algoritmos de treinamento e o erro médio de porcentagem absoluta de cada um foi calculado. Os resultados mostram que o uso do algoritmo de treinamento neural do tipo Levenberg-Marquardt proporciona uma melhor precisão do que outros algoritmos de treinamento. Este artigo demonstra que ainda hoje em dia estão sendo realizadas numerosas pesquisas em relação à previsão da energia eólica.

(ZHANG *et al.*, 2014) apresentam uma revisão histórica sobre a modelagem e previsão da geração de energia eólica onde aparece o uso de redes neurais e dos modelos regressivos. (DUMITRU e GLIGOR, 2017) desenvolvem um trabalho para a predição da energia eólica usando também redes neurais e aplicam o modelo na zona sudeste de Europa. Os resultados obtidos foram satisfatórios, o que demonstra uma tendência ao uso das redes neurais para a previsão da energia eólica.

Enquanto muitos meteorologistas estão se movendo para gerar previsões probabilísticas, as previsões de energia também podem ser projeções pontuais e cenários sem probabilidades associadas. Os métodos de previsão de densidade empírica fornecem uma alteração probabilística às previsões de pontos existentes.

(KAACK *et al.*, 2017) estabelecem as bases para avaliar o desempenho desses métodos quando se tem uma configuração escassa de dados de previsões de longo prazo. Os resultados podem dar aos analistas de políticas e outros usuários a confiança em estimar incertezas de previsão com métodos empíricos.

A energia eólica aumentou nos últimos anos para atender a crescente demanda de energia. A previsão precisa de energia eólica a curto prazo é importante para uma ótima programação dos parques eólicos. Aumentar a precisão pode ajudar os operadores de sistemas de energia a aumentar a confiabilidade do fornecimento de energia.

(BABY *et al.*, 2017) desenvolveram uma Rede Neural Não-Linear com Entradas Exógenas (NARX) para prever a velocidade e a potência do vento por hora. As variáveis meteorológicas são tomadas como variáveis exógenas, ou variáveis explanatórias, para a previsão da velocidade do vento. A área geográfica em estudo é Jaisalmer em Rajasthan.

Os dados de vento são obtidos para este local do Laboratório Nacional de Energia Renovável (NREL) por um ano. A comparação da previsão de velocidade do vento do modelo NARX com o modelo de regressão linear e o modelo de persistência também é realizada. O desempenho dos resultados do teste é feito usando medidas de erro estatístico como MAE, RMSE e MAPE. Segundo os autores, os resultados obtidos com a rede NARX são promissores.

É essencial prever a velocidade do vento com exatidão para garantir com segurança a integração da energia eólica no sistema, além do uso das Redes Neurais, está sendo utilizado os modelos híbridos. (HAN *et al.*, 2017) desenvolvem dois modelos híbridos não paramétricos para a previsão probabilística da velocidade do vento. Para comparações, uma Rede Neural Artificial com *backpropagation*, máquina de vetor de suporte e modelos florestais aleatórios também são introduzidos para a modelagem híbrida.

Através da realização de vários testes nas séries temporais reais de velocidade do vento, o desempenho de previsão de modelos simples e híbridos é comparado e avaliado em detalhes. Os resultados deste estudo mostram que os modelos híbridos não paramétricos geralmente

superam os resultados gerados por outros modelos e apresentam performances de previsão mais robustas.

Segundo (DONG *et al.*, 2017), uma questão crucial na indústria de energia eólica, é a difícil e desafiadora tarefa de prever a energia com precisão devido à sua não-linearidade, não sazonalidade e caos. Os autores também desenvolvem um novo modelo híbrido para prever a energia eólica, que combina uma estratégia de processamento integrada e uma rede neural linear difusa local otimizada. São usadas as transformações discretas de Wavelet e a análise de espectro singular para filtrar os ruídos e extrair as tendências das séries originais de energia eólica, respectivamente.

Os resultados numéricos de dois experimentos demonstram que o modelo híbrido proposto é uma abordagem eficaz para prever a energia eólica, e a precisão da predição é altamente melhorada em comparação com modelos de previsão convencionais.

Existem ainda os modelos híbridos, que combinam diferentes métodos de previsão com o objetivo de extrair o máximo benefício de cada método utilizado (DONG *et al.*, 2017; HAN *et al.*, 2017; JIANG *et al.*, 2017; LIU, J. *et al.*, 2017; LIU, Y. *et al.*, 2017).

Em relação aos diferentes erros que estão presentes na previsão da energia eólica tem se desenvolvido muitos trabalhos devido ao fato que este é um dos principais problemas quanto a previsão da velocidade do vento e da energia eólica. Na tabela 1.1 se oferece um resumo dos principais trabalhos encontrados na revisão da literatura relacionados com os diferentes métodos de previsão, cenários e erros obtidos.

Tabela 1. 1: Comparação dos diferentes modelos e erros encontrados na literatura.

Autor	Intervalo	Passos de previsão	Modelo	Erro		
				RMSE	MAE	MAPE
LI, C. <i>et al.</i> , 2018	30 min.	1,2 e 3	Case (IM Area2)	RMSE	MAE	MAPE
			GSO-ELM	2,4968	1,9661	22,3474
			VMD-ELM	0,9331	0,7495	8,4499
			VMD-GSO-ELM	0,8968	0,7338	8,2088
			Proposto	0,8332	0,6538	7,4309
SUN <i>et al.</i> , 2017	15 min	1, 3 e 5	Case (Site 3)	RMSE	MAE	MAPE
			PCA-SVR	2,0706	1,1217	28,0006
			PCA-CVR	1,6591	1,0899	28,7098
			KPCA-SVR	1,1825	1,0047	26,0715
			KPCA-CVR	2,0407	1,1049	27,7919
			PCA-SVR-COR	1,1877	0,9317	25,2087
			PCA-CVR-COR	1,2792	1,0029	24,8213
			KPCA-CVR-COR	0,7396	0,7446	20,4011
SHARIFIAN <i>et al.</i> , 2018	1 hora	3, 6, 12, 24, 36		RMSE %	MAPE	
			Fuzzy NN, 3	3,38	0,88	

			Fuzzy NN, 6	5,87	1,46	
			Fuzzy NN, 12	9,14	2,34	
			Fuzzy NN, 24	12,04	2,71	
			Fuzzy NN, 36	13,75	3,55	
KAPLAN e TEMIZ, 2017	10 min	1, 2, 3		RMSE	MAE	MAPE
			ICEEMDAN-BP	0,4909	0,3498	5,66
			ICEEMDAN-ENN	0,6327	0,4524	7,79
			ICEEMDAN-WNN	0,9854	0,6663	9,79
			ICEEMDAN-GRNN	0,9113	0,6731	11,65
			Proposed Model	0,4435	0,3123	5,13
CHANG <i>et al.</i> , 2017	10 min	6, 24, 72	Case II	RMSE%	MAPE	
			BPNN	28,051	27,331	
			RBFNN	26,432	24,498	
			ANFIS	4,871	3,931	
			RBFNN-EF	4,872	3,930	
			IRBFNN-EF	4,701	3,871	
AZAD <i>et al.</i> , 2014	Dia, mês, ano	1, 24, 30	RNA	MAE		
			Local: MERSING	0,94		
			Local: Kuala	0,8		
WANG, D <i>et al.</i> , 2017	1 dia	1, 2, 4, 6	Case II	RMSE	MAE	MAPE
			Persistence Method	2,040	1,663	69,374
			PSRBPNN	1,501	1,219	55,823
			PSRWNN	1,363	1,187	51,384
			PSRGAWNN	1,352	1,139	47,535
			EEMD-PSRGAWNN	0,662	0,521	20,167
			VMD-PSRGAWNN	0,368	0,276	11,441
XIAO <i>et al.</i> , 2017	10 min	1, 2, 3	Site 1	MAE	MAPE	
			SSA-CG-BA-RBFNN	0,2799	5,1002	
			SSA-CG-BA-GRNN	0,2334	4,2507	
			FEEMD-CG-BA-RBFNN	0,2963	5,3953	
			FEEMD-CG-BA-GRNN	0,2581	4,7022	
LI, H. <i>et al.</i> , 2018	10 min	1, 2, 3	Spring – A			
			EMD-ARIMA	0,4083	9,0714	
			EMD-BA-ENN	0,6841	18,7744	
			EMD-BA-BPNN	0,5258	12,4630	
			NCFM	0,3800	8,2900	
SCHICKER <i>et al.</i> , 2017	1 hora	1, 2, 6, 12, 24, 36		MAE		
			AROME	1,36		
			ALARO	1,28		
			ANN AROME+ALARO	0,93		
			iANN AROME	0,96		
			iANN AROME+ALARO	0,94		
			INCA	1,33		
CHENG <i>et al.</i> 2017	1 hora	1, 2, 3	Caso 1	MAE		
			CTRL	1,96		
			WS	1,34		
SUN, G <i>et al.</i> , 2018	10 min	1~24 1, 8, 16, 24	Farm 1	RMSE	NMAE	
			Persistence	12,51	19,48	
			ARIMA	14,63	24,53	
			FFNN	6,39	6,82	
			ED þ IPSO-WNN	4,52	6,02	
			Proposed Method	3,49	4,90	

Fonte: O Autor

Da análise do estado da arte pode-se concluir que a previsão da velocidade do vento e da energia eólica é um tema de muito interesse e que existem inúmeras publicações sobre esta

temática. Existe uma tendência a utilizar modelos híbridos e a conseguir previsões mais precisas. Salvo algum engano do autor, não existe na literatura pesquisada, dentro dos modelos híbridos, um modelo que combine o método SARIMA com duas redes neurais, e ainda mais que aborde todos os possíveis cenários de tempo para a previsão.

1.7. Estrutura da tese

No **Capítulo 1**, introdução, são apresentados os elementos que motivaram a realização desta tese, abordando os aspectos introdutórios sobre a problemática do assunto, contendo a justificativa, objetivos a serem alcançados, revisão bibliográfica, a descrição e a estrutura da tese.

O **Capítulo 2** apresenta a fundamentação teórica sobre teoria dos ventos e potência de geração de energia eólica.

O **Capítulo 3** trata sobre as técnicas de predição de séries temporais, dando especial enfoque aos métodos: SARIMA e Redes Neurais Artificiais. Aborda também a redução da dimensão do espaço de entrada pelo uso da técnica de Análise dos Componentes Principais (PCA) e a estratégia de balanceamento de amostras de treinamento utilizadas nas redes neurais. Aborda também a utilização de Wavelet na previsão de séries temporais.

O **Capítulo 4** mostra as aplicações metodológicas desenvolvidas no trabalho, destacando a representação da solução, a organização do banco de dados, as etapas de pré-processamento dos dados e a solução de modelagem híbrida utilizando o SARIMA e RNA.

No **Capítulo 5** são apresentados os resultados obtidos com os modelos de previsão de velocidade do vento propostos, além realizar a avaliação da precisão obtida por meio destes resultados.

O **Capítulo 6** apresenta as principais conclusões obtidas com esta pesquisa e sugestões para trabalhos futuros.

1.8. Considerações Finais

Este capítulo apresentou os principais objetivos desta tese de doutorado, além da contribuição e relevância deste estudo, bem como as limitações da tese. O próximo capítulo irá apresentar os principais aspectos relacionados com a energia eólica, suas características e as principais expressões matemáticas relacionadas com esta energia.

CAPÍTULO 2

2. PANORAMA DA ENERGIA EÓLICA

2.1. Visão Histórica

A tecnologia da energia eólica e os dispositivos de vento mais simples datam de milhares de anos atrás, com os moinhos de vento de eixo vertical encontrados nas fronteiras persa-afegão cerca de 200 AC e os moinhos de vento de eixo horizontal dos Países Baixos e do Mediterrâneo no ano 1300 DC (FLEMING e PROBERT, 1984; MUSGROVE *et al.*, 2010; KALDELLIS e ZAFIRAKIS, 2011)

A produção de energia eólica, no cenário mundial, vem surgindo ao longo dos últimos anos como uma das principais alternativas de energia renovável, contudo, a tecnologia que iniciou a evolução dessa indústria eólica não é algo recente.

Segundo (MARTINS *et al.*, 2008), a conversão da energia cinética dos ventos em energia mecânica vem sendo utilizada pela humanidade há mais de 3000 anos. Algumas das primeiras aplicações da energia eólica foram os moinhos de vento utilizados para moagem de grãos e bombeamento de água em atividades agrícolas.

Segundo (DUTRA, 2011), o primeiro registro histórico da utilização da energia eólica para bombeamento de água e moagem de grãos através de cata-ventos é proveniente da Pérsia, por volta de 200 A.C. Contudo, a evolução do aproveitamento da energia eólica é descrita por (GASCH e TWELE, 2011), de acordo com sua pesquisa detalham, em síntese, a evolução da tecnologia da energia eólica desde seu emprego em moinhos de vento a partir de 1700 a.c. até os modernos aerogeradores de eletricidade.

Ainda em (DUTRA, 2011), acredita-se que antes da invenção dos cata-ventos na Pérsia, a China (por volta de 2000 a.c.) e o Império Babilônico (por volta 1700 a.c) também utilizavam cata-ventos rústicos para irrigação, pois ainda não se dispunham de rios em todos os lugares para o aproveitamento em rodas d'água, a percepção do vento como fonte natural de energia possibilitou o surgimento de moinhos de ventos substituindo a força motriz humana ou animal nas atividades agrícolas.

Os moinhos de vento na Europa influenciaram a economia agrícola por vários séculos, além disso, leis foram criadas envolvendo a concessão de moinhos e o “direito ao vento” (lei proibindo a plantação de árvores próximas ao moinho). E com o desenvolvimento tecnológico

das pás e do sistema de controle, o uso dos moinhos de vento promoveu a otimização de diversas atividades (FEAM, 2013).

Para a geração de energia elétrica, as primeiras tentativas feitas com o uso da energia eólica datam no final do século XIX. A primeira turbina eólica usada para produzir eletricidade data de 1888, como resultado do desejo de Charles F. Brush para alimentar um grande número de lâmpadas incandescentes em sua grande propriedade em Cleveland, Ohio, o primeiro gerador eólico que fornecia 12 kW em corrente contínua (JONCAS, 2010).

Conforme historiadores, um dos primeiros passos para o desenvolvimento de turbinas eólicas de grande porte para aplicações elétricas foi dado na Rússia em 1931. O aerogerador Balaclava (assim chamado) era um modelo avançado de 100 kW conectado, por uma linha de transmissão de 6,3 kV de 30 km, a uma usina termelétrica de 20 MW. Essa foi a primeira tentativa bem sucedida de se conectar um aerogerador de corrente alternada com uma usina termelétrica (SHEPHERD, 1994).

A energia eólica tornou-se popular novamente quando os preços do petróleo dispararam quando ocorreu a eclosão da Segunda Guerra Mundial (JONCAS, 2010), desta forma, a Segunda Guerra Mundial (1939-1945) contribuiu para o desenvolvimento dos aerogeradores de médio e grande porte visto que os países estavam empenhando grandes esforços no sentido de economizar combustíveis fósseis.

A crise internacional do petróleo ocorrida na década de 1970, com os preços subindo como resultado do embargo de imposto sobre, os Estados Unidos e a maioria dos países europeus no início da década de 1970, despertou o interesse e investimentos suficientes para viabilizar o desenvolvimento e a aplicação de equipamentos de geração de energia eólica (JONCAS, 2010).

Então, o mundo então começou a utilizar o vento como fonte de energia em escala comercial, passando por um intenso desenvolvimento tecnológico nos anos 90.

Atualmente, além de ser reconhecida como uma das fontes de energia que mais cresce no mundo, a taxas superiores a 28% ao ano, é reconhecida mundialmente por ser uma importante fonte de energia renovável para geração de eletricidade sem emissão de dióxido de carbono e gases poluentes durante sua operação (FEAM, 2013).

Em um mundo globalizado, a crescente dependência da humanidade por recursos energéticos e questões como mudança climática, poluição e os impactos econômicos decorrentes da dependência de combustíveis fósseis estimulou ainda mais os investimentos em energias renováveis, dentre as quais a energia eólica se destaca (JUNFENG *et al.*, 2006).

2.2 Recursos Eólicos

A energia eólica é uma alternativa limpa e renovável para produção de energia elétrica, apresentando grande aceitação social (SANTOS, 2009). No aspecto social, as usinas eólicas não provocam grandes impactos ambientais como nos aproveitamentos hidrelétricos e permitem a compatibilidade entre a produção de eletricidade a partir do vento e o uso da terra para a pecuária e a agricultura.

A energia eólica é, basicamente, aquela obtida da energia cinética (do movimento) gerada pela migração das massas de ar provocada pelas diferenças de temperatura existentes na superfície do planeta (BAROUDI *et al.*, 2007; CHENG e ZHU, 2014). A geração eólica ocorre pelo contato do vento com as pás do cata-vento, elementos integrantes da usina. Ao girar, essas pás dão origem à energia mecânica que aciona o rotor do aero gerador, que produz a eletricidade.

De acordo com (DUTRA, 2011), as regiões tropicais recebem os raios solares quase que perpendicularmente e por isso são mais aquecidas do que as regiões polares. Conseqüentemente, o ar quente que se encontra nas baixas altitudes das regiões tropicais tende a subir, sendo substituído por uma massa de ar mais frio que se desloca das regiões polares.

O vento é resultante do deslocamento de massas de ar, originado pelos efeitos das diferenças de pressão atmosférica entre duas regiões distintas e influenciadas por efeitos naturais como continentalidade, maritimidade, latitude, altitude, e a rugosidade do solo, entre outros (FEAM, 2013). O deslocamento de massas de ar determina a formação dos ventos. A Figura 2.1 mostra esse mecanismo.




Figura 2.1: Comportamento dos ventos.
Fonte: AMARANTES, 2001.

De acordo com (DUTRA, 2011), tendo em vista que a velocidade do vento pode variar significativamente em curtas distâncias (algumas centenas de metros), os procedimentos para avaliar o local, no qual se deseja instalar turbinas eólicas, devem levar em consideração todos os parâmetros regionais que influenciam nas condições do vento. Entre os principais fatores de influência no regime dos ventos destacam-se:

- A variação da velocidade com a altura;
- A rugosidade do terreno, que é caracterizada pela vegetação, utilização da terra e construções;
- Presença de obstáculos nas redondezas;
- Relevo que pode causar efeito de aceleração ou desaceleração no escoamento do ar.

Deve-se levar em consideração também que existem diversos fatores benéficos que contribuem enormemente para o aumento da utilização da energia eólica ao redor do mundo, principalmente o fato de que ela não emite poluentes ou CO₂ durante sua operação.

De acordo com (TERCIOTE, 2002), os fatores que impulsionam o uso da energia eólica, são diversos: Reduz a dependência de combustíveis fósseis, sendo o vento um recurso abundante e renovável; As centrais eólicas ocupam um pequeno espaço físico e permitem a continuidade de atividades entre os aerogeradores (pastagens e agricultura); Melhora a economia local e oferta de empregos. Estudos realizados na Escócia calculam ser entre 500 a 1500 empregos associados a cada 0,3 a 1 GW de potência instalada; A emissão de poluentes é mínima, não contribuindo para a mudança climática global, chuva ácida, etc; É uma indústria em grande ascensão e com bom potencial no Brasil (principalmente em algumas regiões do

litoral nordestino); Contribui para a diversidade de suprimento de energia e pode ser conectada à rede; A tecnologia está completamente dominada e ainda em grande desenvolvimento, com redução constante de custos de construção e geração.

2.3 Características Básicas da Tecnologia Eólica

A geração de energia elétrica a partir da energia proveniente dos ventos é realizada através do uso de turbinas eólicas.

A turbina eólica é constituída por uma série de componentes, responsáveis pela produção da energia elétrica em três etapas: a captação da energia cinética contida no vento, a conversão da energia cinética em energia mecânica e a transformação da energia mecânica em energia elétrica propriamente dita, pelo gerador elétrico, ao final do processo (LEITE *et al.*, 2006). Estes processos estão demonstrados na Figura 2.2.

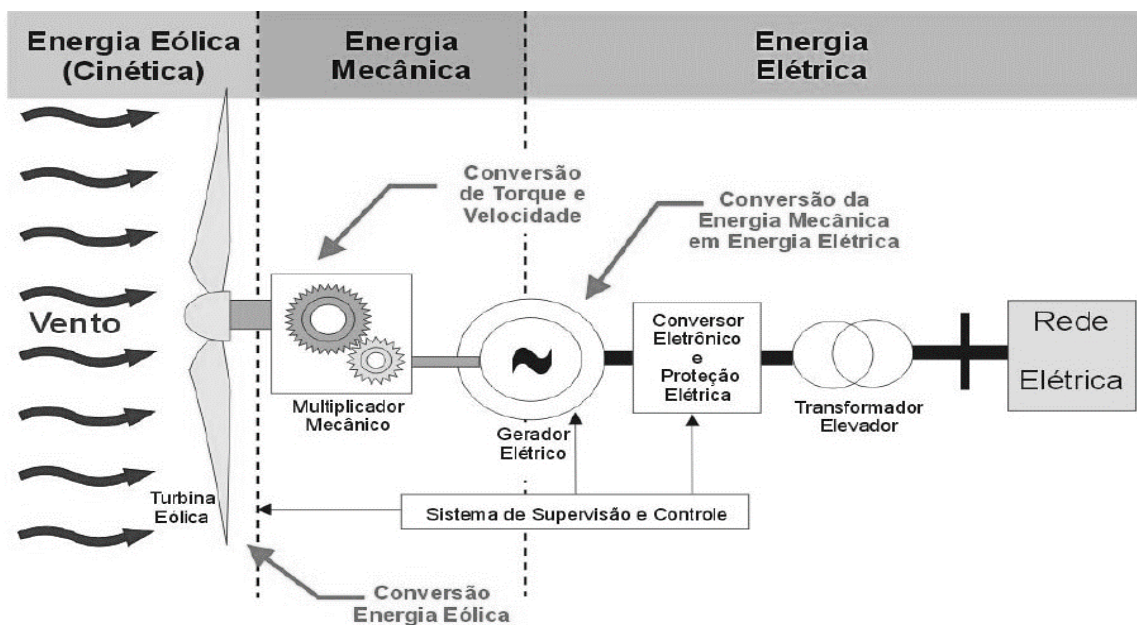


Figura 2.2: Esquema geral de funcionamento de um aerogerador.
Fonte: (PAVINATTO, 2005).

O vento atinge as pás do rotor que se movimentam. Esse movimento é transferido para um sistema de engrenagens que multiplicam a frequência do rotor. Essa velocidade é transmitida para o gerador elétrico responsável por produzir a eletricidade por meio do fenômeno de indução eletromagnética. Dependendo da tecnologia utilizada pelo aerogerador, o multiplicador mecânico e o conversor eletrônico não são necessários (PICOLO *et al.*, 2014).

2.3.1. Principais componentes de um aerogerador

Aerogeradores são equipamentos usados para produção de energia elétrica a partir da energia cinética do vento. A potência de destes equipamentos varia desde algumas centenas de watts até vários megawatts. A Figura 2.3 mostra os principais componentes de uma turbina eólica do tipo mais comum, isto é, de eixo horizontal.




Figura 2.3: Desenho esquemático de turbina eólica.
Fonte: (CBEE, 2014).

Para efeito de estudo, em um contexto geral da conversão eólica, devem ser considerados os seguintes componentes segundo (DE SALLES, 2004; CASTRO, 2007; NUNES e MANHÃES, 2010):

- Torre: Geralmente de estrutura tubular sustenta a Nacele e o rotor acima do solo para capturar a energia contida nos ventos onde a rugosidade é menor.
- Nacele: Contém os principais componentes da turbina: caixa de engrenagens, controlador de freio e o gerador elétrico. Protege os componentes de elementos externos.
- Pás do rotor: Captam o vento e convertem sua potência ao centro do rotor.

- Rotor: Sistema de captação de energia cinética dos ventos a qual converte em energia mecânica no seu eixo (idem).
- Transmissão (Caixa de Multiplicação): Transmite a energia mecânica do eixo do rotor para o gerador.
- Gerador elétrico: Converte a energia mecânica em energia elétrica. Converte o torque do giro do rotor em eletricidade. É uma bobina girando num campo magnético.
- Mecanismos de controle: Usam sensores para o bom funcionamento e a segurança do sistema para melhor aproveitar o vento.
- O controlador: move o rotor para alinhá-lo com a direção do vento.
- Os freios: detêm a rotação do eixo em caso de sobrecarga de energia ou falha no sistema.
- Anemômetro (sistema de vento): Mede a intensidade e a velocidade dos ventos, normalmente de 10 em 10 minutos.

2.4. Produção de Energia Eólica

O potencial de energia elétrica produzida a partir da geração eólica é obtido através da energia cinética dos ventos, que é convertida em energia mecânica, por um processo que transforma a força do vento em um torque que age sobre as pás do rotor.

A energia cinética de translação é dada no instante que o vento movimenta as pás, e a energia cinética de rotação é dada no instante que as pás produzem o torque eletromecânico eixo da turbina que é transferido para o gerador.

A formulação mostrada a seguir foi obtida em (BERNSTEIN, 2002; PATEL, 2005; SANTOS, 2009; ANVARI *et al.*, 2016). A quantidade de energia gerada pelos ventos é uma função da sua velocidade (v) e massa (m) e é dada pela equação de energia cinética.

A energia cinética é representada pela equação (2.1):

$$E_c = \frac{1}{2}mv^2 \quad (2.1)$$

Onde:

E_c = energia Cinética [J];

m = massa do ar que escoar através da área A de varredura das pás [Kg];

v = velocidade da massa de ar em movimento (vento) [m/s].

Como uma turbina eólica é classificada, normalmente, pela potência e não pela energia, tem-se o cálculo da potência disponível no vento que é obtido a partir da razão entre a energia e o tempo, a potência dos ventos é a energia cinética por unidade de tempo (t), onde a unidade de tempo padrão é um segundo (s).

A potência disponível do vento é deduzida pela equação (2.2):

$$P_d = \frac{E}{\Delta t} = \frac{mv^2}{2t} \quad (2.2)$$

Onde:

P_d = potência disponível do vento [W];

E = energia cinética do vento [J];

t = unidade de tempo [s].

Como a densidade do ar é razão da massa pelo volume, o termo m/t pode ser chamado de taxa de fluxo de massa (\dot{m}). A taxa de massa (\dot{m}) pode ser definida como sendo a massa por unidade de tempo, representada pelo produto da densidade do ar (ρ) e pela vazão de ar (Q).

O fluxo de massa é dado pela equação (2.3):

$$\dot{m} = \rho Q \quad (2.3)$$

Onde:

\dot{m} = fluxo de massa de ar [kg/s];

ρ = massa específica do ar [Kg/m³];

Q = vazão volumétrica [m³/s].

A vazão (Q) é a quantidade de ar que passa através de uma área especificada. Pode ser calculada através do produto da velocidade do vento (v) pela área no qual o fluxo de ar atravessa as pás do rotor da turbina (A).

A vazão é dada pela equação (2.4):

$$Q = vA \quad (2.4)$$

Onde:

v = velocidade do vento [m/s];

A = área da seção transversal [m²].

Por conseguinte, a taxa de fluxo de massa (\dot{m}) pode ser reescrita pela combinação da equação (2.3) e (2.4), resultando na equação (2.5):

$$\dot{m} = \rho vA \quad (2.5)$$

Substituindo a equação (2.5) na equação (2.2), obtemos o potencial eólico que é a potência disponível no vento que passa pela seção A , transversal ao fluxo de ar.

A Potência disponível no vento é dada pela equação (2.6):

$$P = \frac{1}{2} \rho A v^3 \quad (2.6)$$

Onde:

P = potência do vento [W];

ρ = massa específica do ar [Kg/m^3];

A = área da seção transversal [m^2];

v = velocidade do vento [m/s];

A potência disponível no vento, porém, não pode ser totalmente aproveitada pela turbina eólica para a geração de eletricidade. Segundo (DUTRA, 2011), para levar em conta esta característica física, é introduzido um índice denominado coeficiente de potência C_p , que pode ser definido como a fração da potência eólica disponível que é extraída pelas pás do rotor.

(THOMAS e CHERIYAN, 2012), afirmam que de acordo com a Lei de Betz, nenhuma turbina eólica pode converter mais de 59,3% da energia cinética do vento em energia mecânica transformar um rotor ($C_p \leq 59.3\%$), ou seja, 59,3% da energia contida no fluxo de ar podem ser teoricamente extraídas por uma turbina eólica (OLIVEIRA, 2008).

Sendo assim, a máxima potência que pode ser extraída por uma turbina eólica é dada pela equação (2.7):

$$P = \frac{1}{2} \rho A v^3 C_p \quad (2.7)$$

Onde:

C_p = coeficiente de potência.

O coeficiente de potência (BRAGA *et al.*, 2000) é obtido através do produto da eficiência mecânica (η_m), eficiência elétrica (η_e) e da eficiência aerodinâmica da turbina eólica. Todos os três fatores dependem da velocidade do vento e da potência gerada, ou seja, a velocidade do rotor deve mudar em resposta à mudança de velocidade do vento.

Os controles de velocidade e potência em sistemas de energia eólica têm três regiões distintas, a Figura 2.4 mostra estas regiões.




Figura 2.4: Curva de Potência da Turbina.
Fonte: (PATEL, 2005).

A curva de linha contínua representa a potência e as curvas tracejadas, a eficiência do rotor. De acordo com (PATEL, 2005), as regiões da curva de potência podem ser descritas como se segue:

- Região de C_p constante ótima, gerando linearmente aumento de potência com o aumento da velocidade do vento;
- Região de potência limitada, gerando uma potência constante, mesmo em maiores ventos, através da diminuição da C_p eficiência do rotor;
- Região de desligamento de energia, onde a geração de energia é desacelerada até zero, a velocidade do vento se aproxima do limite de corte.

Tipicamente, a turbina começa a funcionar (*cut-in*) quando a velocidade do vento excede 4 a 5 m/s, e é desligado a velocidades superiores a 25 a 30 m/seg. A região constante C_p é o modo normal de operação.

Segundo (PATEL, 2005; MANWELL *et al.*, 2010), para manter uma C_p constante, o sistema de controle aumenta a velocidade do rotor em resposta ao aumento da velocidade do vento apenas até um certo limite.

Quando esse limite for atingido, o controle passa para a região limitador de velocidade. Se a velocidade do vento continuar a aumentar, o sistema aproxima-se da limitação da potência do gerador elétrico. Quando isto ocorre, a velocidade da turbina é reduzida, e o coeficiente de potência C_p move-se mais longe a partir do valor ótimo. A potência de saída do gerador permanece constante no limite do projeto.

Quando o limite de velocidade e limite de potência não podem ser mantidos sob uma rajada de vento extremo, é cortada a operação de produção de energia.

A velocidade do vento não aumenta com a altura indefinidamente, de acordo com (TONG, 2010), o efeito da altura sobre a velocidade do vento é principalmente devido a rugosidade na superfície da terra e pode ser estimada utilizando a equação (2.8) de Potência de Hellmann que relaciona a velocidade do vento em duas alturas diferentes:

$$\frac{V_2}{V_1} = \left(\frac{h_2}{h_1}\right)^\alpha \quad (2.8)$$

Onde:

V_1 = velocidade do vento medida na altura h_1 de referência;

V_2 = velocidade do vento estimado em altura h_2 , e

α = coeficiente de atrito da superfície do solo.

O coeficiente de atrito α é baixo para o terreno suave e alta para os mais ásperos. Os valores de α para classes terreno típicos são dados na Tabela 2.1.

Tabela 2.1: Curva de Potência da Turbina.

Tipo de Terreno	Coefficiente de Atrito
Lago, Oceano e Solo liso	0,10
Florestas no nível do solo	0,15
Culturas altas, sebes e arbustos	0,20
Campo arborizado, com muitas árvores	0,25
Cidades pequenas com algumas árvores e arbustos	0,30
Área da cidade com edifícios altos	0,40

Fonte: (PATEL, 2005).

2.5. Considerações Finais

A produção de energia eólica, no cenário mundial, vem surgindo ao longo dos últimos anos como uma das principais alternativas de energia renovável, contudo, a tecnologia que iniciou à evolução dessa indústria eólica não é algo recente.

A potência que pode gerar uma turbina eólica depende das características construtivas da mesma e da velocidade do vento, a grande importância de poder fazer uma previsão da velocidade do vento o mais exata possível para poder fazer uma previsão da energia eólica em qualquer lugar. O próximo capítulo faz uma análise dos diferentes métodos e modelos que podem ser usados para a previsão da velocidade do vento e, porém, da energia eólica.

CAPÍTULO 3

3. MÉTODOS E MODELOS PARA PREDIÇÃO E CLASSIFICAÇÃO DE SÉRIES TEMPORAIS

3.1 Modelos de previsão de velocidade de ventos

Com a variabilidade inerente do recurso do vento, é muitas vezes útil ser capaz de prever a velocidade do vento algum tempo à frente. Por exemplo, pode ser útil, a partir de uma perspectiva de controle ser capaz de prever as variações de turbulência de curtíssimo prazo, de alguns segundos a alguns minutos. Em alguns casos, a previsão da velocidade do vento, ou de produção de energia, pode ser necessária em um horizonte de horas ou um a dois dias.

Existem diferentes métodos para realizar a previsão da energia eólica. Estes métodos são classificados segundo as escalas de tempo e segundo as metodologias e estão disponíveis na literatura.

A classificação das escalas de tempo e dos métodos para a previsão da potência ou energia do vento, combinando alguns trabalhos existentes na literatura, pode ser dividida em 4 categorias (DONGMEI *et al.*, 2011; WANG *et al.*, 2011; ZHAO *et al.*, 2011):

- Previsão de ultra-curto prazo: De alguns minutos a 1 hora à frente.
- Previsão de curto prazo: De uma hora para várias horas à frente.
- Previsão de médio prazo: De várias horas a 1 semana à frente.
- Previsão de longo prazo: A partir de 1 semana a 1 ano ou mais à frente.

A Tabela 3.1 apresenta a escala de tempo específico tendo em vista o funcionamento dos sistemas de energia elétrica.

Tabela 3.1: Classificação das escalas de tempo para a previsão do vento.

Escala de Tempo	Alcance	Aplicações
Ultracurto prazo	De alguns minutos a 1 hora à frente	Compensação do mercado de eletricidade
		Operações de rede em tempo real
		Ações de regulação
Curto prazo	De uma hora para várias horas à frente	Planejamento do despacho econômico de carga
		Decisões razoáveis de carga
		Segurança operacional no mercado da eletricidade
Médio prazo	De várias horas a 1 semana à frente	Decisões de compromisso das unidades
		Decisões de compromisso de reserva
		Gerador on-line / off-line decisões
Longo prazo	A partir de 1 semana a 1 ano ou mais à frente	Planejamento da manutenção
		Gestão da operação
		Custo de funcionamento ótimo
		Estudo de viabilidade para projetos de parques eólico

Fonte: (DONGMEI *et al.*, 2011; WANG *et al.*, 2011; ZHAO *et al.*, 2011).

Os modelos de previsão de vento podem ser classificados, de forma geral, nas três categorias seguintes: (i) modelo físico, (ii) modelo estatístico e computacional, e (iii) modelo híbrido (MANWELL *et al.*, 2010; GASCH e TWELE, 2011; FOLEY *et al.*, 2012).

3.1.1 Modelo Físico

O modelo físico também conhecido pelo termo em inglês *Numeric Weather Prediction* (NWP), descreve a relação física entre a velocidade do vento, as condições atmosféricas, topografia local e o resultado do parque eólico. Este modelo consiste em vários submodelos, que juntos proporcionam a tradução a partir da previsão de vento em um determinado ponto da rede.

O modelo é baseado na baixa atmosfera ou a previsão do tempo numérica (NWP) usando dados de previsão do tempo, como a temperatura, a pressão, a rugosidade da superfície e obstáculos e foi desenvolvido por meteorologistas para a previsão meteorológica de área em grande escala (LEI *et al.*, 2009).

Em geral, a velocidade local do vento obtida a partir do serviço meteorológico e transformada para às turbinas de vento no parque eólico e convertida em energia eólica (WANG *et al.*, 2011).

Os métodos físicos são para aumentar a resolução do modelo NWP real, a fim de atingir uma previsão precisa do clima (ZHAO *et al.*, 2011). Os métodos físicos são processados em supercomputadores, pois eles precisam desenvolver muitos cálculos.

De acordo com (WU e HONG, 2007), estes modelos levam em considerações vários fatores, incluindo a ocorrência de obstáculos, rugosidade da superfície local e suas alterações, e os efeitos da orografia, a escala da velocidade do vento local dentro de parques eólicos e layouts de parques eólicos, no entanto, a recolha da informação das condições do terreno é uma das principais dificuldades na implementação de modelos físicos.

Segundo (FOLEY *et al.*, 2012), os modelos físicos geralmente fazem uso de bases de dados globais de medições meteorológicas ou de modelos de mesoescala atmosféricas, mas requerem grandes sistemas computacionais, a fim de obter resultados precisos, em outras palavras, os modelos meteorológicos de alta resolução são muitas vezes mais precisos, mas exigem muito tempo com alta computação para produzir previsões, e, como consequência, eles não atualizam com frequência as suas saídas.

Portanto, o desempenho de modelos físicos é muitas vezes satisfatório para horizontes temporais longos (maior do que 6 horas à frente), e eles são, por outro lado inadequado para previsões em curto prazo (vários minutos à uma hora), devido à dificuldade de aquisição de informação e computação complexa (WU e HONG, 2007).

3.1.2 Modelos Estatísticos

Os modelos estatísticos são fáceis de modelar e de menor custo quando comparados com outros modelos. Basicamente, os métodos estatísticos usam dados históricos para realizar uma previsão ao longo das próximas horas, e são adequados para curtos períodos de tempo. A desvantagem destes métodos é que o erro de predição aumenta à medida que aumenta o tempo de predição, ou seja, as séries temporais estatísticas são principalmente destinadas a previsões de curto prazo (WU e HONG, 2007; CHANG, 2014).

Os modelos estatísticos usualmente utilizam métodos de análise de séries temporais, entre eles: auto regressive - AR, auto regressive moving average - ARMA, e auto regressive integrated moving average – ARIMA, também utilizam a inteligência artificial (Redes Neurais e Lógica Fuzzy). Em geral, estes modelos têm apresentando bom desempenho no que se refere à previsão da velocidade do vento.

3.1.3 Modelos Híbridos

A combinação de abordagens diferentes, tais como as abordagens físicas e modelos estatísticos ou combinando curto e médio prazo, etc, é comumente referida como uma abordagem de modelo misto ou híbrido (SOMAN *et al.*, 2010).

De acordo com (CHANG, 2014), o objeto dos modelos híbridos é se beneficiar das vantagens de cada modelo e obter um desempenho global de previsão melhor do que o resultado de um modelo individualmente.

Uma vez que a informação contida no método de previsão individual é limitada, o método híbrido pode maximizar a informação disponível, integrar informações dos modelos individuais e fazer o melhor uso das vantagens de vários dos métodos de previsão, melhorando assim a precisão da previsão.

Muitos tipos de modelos híbridos são utilizados para prever a energia eólica. Os tipos de combinações podem ser (WU e HONG, 2007; CHANG, 2014):

- Combinação de abordagens físicas e estatísticas;
- Combinação de modelos para o curto prazo e de médio prazo;
- Combinação de modelos estatísticos alternativos;
- Combinação de modelos alternativos de inteligência artificial.

Segundo (OLIVEIRA, 2008), os modelos mistos são usados, quase sempre, em horizontes de previsões curtos (mesoescalas) para ajustar os resultados encontrados através dos modelos NWP.

Diversos trabalhos vêm sendo publicados propondo o gerenciamento de energia utilizando fontes renováveis, como a geração eólica (DONOVAN, 2005; WAN *et al.*, 2010; GONZÁLEZ *et al.*, 2011; YOUSEFBEIGI e AKMANDOR, 2015). No entanto, para implementar a otimização do sistema faz-se necessário realizar a previsão da velocidade do vento em um intervalo de tempo futuro, de acordo com o período de otimização.

Vários artigos na literatura apresentam métodos propondo a previsão da velocidade do vento para a geração de energia eólica. Alguns deles baseiam-se em séries temporais (PAN *et al.*, 2008), outros utilizam redes neurais (CADENAS e RIVERA, 2009; LI e SHI, 2010), lógica fuzzy (MONFARED *et al.*, 2009), modelos bayesianos (SLOUGHTER *et al.*, 2010), enxame de partículas (REN *et al.*, 2014), algoritmos genéticos (LIU *et al.*, 2014), e alguns propõem a combinação dos modelos ARIMA com Redes Neurais (CADENAS e RIVERA, 2010).

3.2 Séries Temporais

Modelagem de séries temporais é uma área de pesquisa dinâmica que tem atraído a atenção das comunidades científicas ao longo das últimas décadas. De acordo com (ADHIKARI e AGRAWAL, 2013), o principal objetivo da modelagem de séries temporais é coletar cuidadosamente e rigorosamente estudar as observações passadas de uma série temporal para desenvolver um modelo adequado, que descreve a estrutura inerente da série.

Este modelo é então utilizado para gerar valores futuros para a série, isto é, para fazer previsões. Previsão de séries temporais, portanto, pode ser denominado como o ato de prever o futuro através da compreensão do passado (RAICHAROEN *et al.*, 2003; GRANGER e NEWBOLD, 2014; BOX *et al.*, 2015; MONTGOMERY *et al.*, 2015).

Para uma previsão de séries temporal bem sucedida depende de um ajuste de um modelo apropriado. Grandes esforços têm sido feitos por pesquisadores ao longo de muitos anos para o desenvolvimento de modelos eficientes para melhorar a precisão da previsão. Como resultado, os vários modelos de séries temporais de previsão importantes têm evoluído na literatura (BROCKWELL e DAVIS, 2013; LIU *et al.*, 2013; BABU e REDDY, 2014).

De acordo com (EHLERS, 2007), algumas características são particulares a este tipo de dados, por exemplo:

- Observações correlacionadas são mais difíceis de analisar e requerem técnicas específicas.
- Deve-se levar em conta a ordem temporal das observações.
- Fatores complicadores como presença de tendências e variação sazonal ou cíclica podem ser difíceis de estimar ou remover.
- A seleção de modelos pode ser bastante complicada, e as ferramentas podem ser de difícil interpretação.
- É mais difícil de lidar com observações perdidas e dados discrepantes devido à natureza sequencial.

Segundo (ADHIKARI e AGRAWAL, 2013), um dos mais populares e freqüentemente usado modelo de séries temporais estocásticas é o Modelo autorregressivo integrado de médias móveis (ARIMA). Neste trabalho, o foco está limitado aos modelos preditores de séries temporais com o uso de filtros ARIMA sazonais (SARIMA), bem como o uso de redes neurais. Contudo, serão abordados também os Modelos autorregressivos (AR), Modelos de médias móveis (MA) e Modelos autorregressivos de médias móveis (ARMA) para possibilitar um melhor entendimento do Modelo SARIMA.

3.2.1 Séries Temporais Estacionárias

Uma das suposições mais frequentes que se faz a respeito de uma série temporal é a de que ela é estacionária, ou seja, ela se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável (MORETTIN e TOLOI, 2006). Todavia, na prática, a maior parte das series temporais encontradas apresentam, em sua natureza, alguma forma de não estacionariedade.

De acordo com (GUJARATI e PORTER, 2011), em linhas gerais, um processo estocástico será chamado de estacionário se sua média e variância forem constantes ao longo do tempo e o valor da covariância entre os dois períodos de tempo depender apenas da distância, do intervalo ou da defasagem entre os dois períodos e não o tempo real ao qual a covariância é computada.

Modelos estacionários são aqueles que assumem que o processo está em equilíbrio. Segundo (SOUZA, 2006), um processo é considerado fracamente estacionário se suas médias e variâncias se mantêm constantes, ao longo do tempo, e a função de autocovariância depende, apenas, da defasagem entre os instantes de tempo. Um processo é fortemente estacionário se todos os momentos conjuntos são invariantes à translação no tempo.

A seguir na sessão 3.3, descreve-se os modelos adequados para séries estacionárias Autoregressivos médias móveis (ARMA), subdividindo em dois outros modelos: o autoregressivo (AR) e médias móveis (MA).

3.2.2 Séries Temporais Não-Estacionárias

Se uma série temporal não é estacionária no sentido há pouco definido, ela é chamada de *série temporal não estacionária*. Em outras palavras, uma série temporal não estacionária terá uma média que varia com o tempo, ou uma variância que varia com o tempo, ou, ainda, ambas (GUJARATI e PORTER, 2011).

De acordo com (FIGUEREDO, 2008), os modelos lineares não estacionários estudados na literatura de referência são aqueles que têm um comportamento “não explosivo”, apresentando assim um comportamento dito homogêneo. São séries tais que, tomando um número finito de diferenças tornam-se estacionárias. Estes modelos são chamados Auto-Regressivos Integrados de Médias Móveis, em inglês AutoRegressive Integrate Moving Average – ARIMA.

As séries não estacionárias possuem tendência, podendo ser de natureza determinística ou estocástica. Em economia, os índices de preços e nível de produto são exemplos da não estacionariedade de séries.

3.3 Modelos de Box-Jenkins

Serão apresentados nesta sessão o modelo de Box-Jenkins para estimação e previsão de séries temporais com base na formulação matemática desenvolvida (HIPEL e MCLEOD, 1994; EHLERS, 2007; MAKRIDAKIS *et al.*, 2008).

Os modelos resultam da combinação de três componentes denominados “filtros”: o componente auto-regressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA). Uma série pode ser modelada pelos três filtros ou apenas um subconjunto deles, resultando em vários modelos, os quais são abordados a seguir

Os modelos ARMA são adequados para séries estacionárias, ou seja, aquelas onde a média é constante por todo tempo. Mas em geral, na prática, as séries são não-estacionárias como, por exemplo, as séries econômicas. Portanto, o modelo que será apresentado para séries de comportamento não-estacionário é o Modelo ARIMA.

3.3.1 Modelo Autorregressivo (AR)

Esta forma de um modelo de séries temporais (do inglês, *Autoregressive models - AR*) é intuitivamente atraente e tem sido amplamente aplicada a conjuntos de dados em diversas áreas.

- Modelo Auto-regressivo de primeira ordem: AR(1)

Utiliza-se um ajuste por um modelo AR(1) quando a variável característica x_t pode ser ajustada pela equação 3.1:

$$x_t = \xi + \phi x_{t-1} + \varepsilon_t \quad (3.1)$$

Onde:

ξ e ϕ são constantes desconhecidas, e

ε_t é o erro independente e normalmente distribuído com média zero e desvio padrão σ .

A condição de estacionariedade é $-1 < \phi < 1$, ou seja, para que a série tenha média constante, ϕ deverá pertencer ao intervalo entre -1 e 1. Em um modelo AR(1), as observações x_t tem média $\xi/(1 - \phi)$, desvio padrão $\sigma/(1 - \phi^2)^{1/2}$, e as observações que estão k períodos separados têm coeficiente de correlação ϕ^k .

- Modelo Auto-regressivo de ordem p : AR(p)

Generalizando o modelo da equação 3.1 para p ordens, obtém-se o modelo da equação 3.2:

$$x_t = \xi + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \varepsilon_t \quad (3.2)$$

O qual é um modelo auto-regressivo de ordem p , um AR(p). Como pode-se perceber, um modelo autoregressivo depende de p observações anteriores, ou seja, a observação x_t é gerada pela média ponderada das p primeiras observações anteriores da variável. Dependendo da ordem do modelo, a quantidade e complexidade das condições de estacionariedade aumentam.

3.3.2. Modelo de Médias Móveis (MA)

O modelo de Médias Móveis (do inglês, *Moving Average* - MA) descreve como uma observação depende diretamente de uma ou mais medições anteriores (HIPEL e MCLEOD, 1994; VALIPOUR *et al.*, 2013; KINGMA e BA, 2014).

- Modelo de Média Móvel de primeira ordem: MA (1)

Suponha-se que a observação x_t , dependa não dos seus valores anteriores, mas da componente aleatória ε_t , como na equação abaixo. Dessa forma, tem-se um modelo de Equação 3.3 MA(1).

$$x_t = \mu + \varepsilon_t - \theta \varepsilon_{t-1} \quad (3.3)$$

Onde:

μ e θ são constantes.

Nesse modelo, a correlação entre x_t e x_{t-1} é $\rho_1 = -\theta / (1 + \theta^2)$, e zero para todas as outras defasagens. A condição de estacionariedade é que o parâmetro q seja finito. Assim, como $q = 1$ esse modelo sempre será estacionário.

- Modelo de Média Móvel de ordem q : MA(q)

Generalizando o modelo da equação 3.3 para q ordens, obtém-se o modelo de equação 3.4:

$$x_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (3.4)$$

Este é o modelo de média móvel de ordem p . Pode-se perceber que cada observação é gerada por uma média ponderada do valor presente e de q valores passados de um processo de ruído aleatório.

O modelo de média móvel é sempre estacionário (pois q é sempre finito) e possui média μ . Assim, o termo do erro ε_t , que possui média 0 e variância σ^2 e tem valores que são não autocorrelacionados, é chamado de ruído aleatório.

3.3.3 Modelos Autorregressivos de Médias Móveis (ARMA)

Uma combinação dos modelos AR(p) e MA(q) resulta em um modelo auto regressivo e de média móvel, ou seja, um ARMA(p,q) do inglês, *autoregressive integrated moving average (ARMA)*.

Se um processo consiste em ambos os parâmetros MA AR é chamado um processo ARMA (HIPEL e McLEOD, 1994) (KARTHIKEYAN e KUMAR, 2013; MARELLI *et al.*, 2013; SHAFAEI e KISI, 2016). Um modelo auto regressivo de média móvel de primeira ordem, um ARMA (1,1), é representado pela equação 3.5:

$$x_t = \xi + \phi x_{t-1} + \varepsilon_t - \theta \varepsilon_{t-1} \quad (3.5)$$

Um processo ARMA (p, q) será estacionário se as condições provenientes da parcela AR do processo forem verificadas. A média de um processo ARMA (p, q) também é dada pela parcela autorregressiva do modelo.

O modelo ARMA (p, q) pode ser representado utilizando os operadores autorregressivos e de média móvel visto anteriormente, resultando no modelo de equação 3.6:

$$\phi(B)x_t = \theta(B)e_t \quad (3.6)$$

O modelo ARMA (p, q) ainda pode ser representado pela equação 3.7:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (3.7)$$

Sendo o processo estocástico estacionário, será usado um modelo ARMA quando o processo apresentar características que não permitam sua descrição através de uma parametrização parcimoniosa de um processo puramente autorregressivo ou puramente médias móveis, pelo fato de seu comportamento incluir características de ambos os tipos de processos então, será considerado um modelo misto, ou seja, é o modelo que tem uma parte AR (p) com $\phi(\mathbf{B}) \leq \mathbf{1}$ com uma MA (q) com $\theta(\mathbf{B}) \leq \mathbf{1}$.

3.3.4. Modelos Autorregressivos Integrados de Médias Móveis (ARIMA)

Quando o processo é não estacionário, a combinação entre os modelos autorregressivos e de média móvel, resulta em um modelo ARIMA (p,d,q), do inglês *Autoregressive Integrated Moving Average* (VALIPOUR *et al.*, 2013; ADEBIYI *et al.*, 2014; CADENAS *et al.*, 2016), onde d é o número de diferenças necessárias para tornar a série estacionária. O modelo da Equação 3.8 é um ARIMA (1,1,1).

$$x_t = x_{t-1} + \phi_1 x_{t-1} - \phi_1 x_{t-2} + e_t - \theta_1 e_{t-1} \quad (3.8)$$

Esse modelo descreve um procedimento não-estacionário (a variável x_t segue uma tendência, como se não existisse um valor fixo para a média). Isso frequentemente ocorre em processos industriais e químicos quando x_t é um processo de saída não controlável, isto é, quando não há ações que possam ser feitas para o controle da variável a fim de atingir o valor objetivo.

De acordo com (GUJARATI e PORTER, 2011), se tivermos que diferenciar uma série temporal d vezes para torná-la estacionária e aplicar-lhe o modelo ARMA (p, q), diremos que a série temporal original é ARIMA (p, d, q), ou seja, é uma série temporal autorregressiva integrada de médias móveis, em que p denota os números dos termos autorregressivos, d o número de vezes que a série deve ser diferenciada antes de tornar-se estacionária e q o número de termos de média móvel.

Ainda segundo (GUJARATI e PORTER, 2011), observa-se que um processo ARIMA ($p, 0, 0$) significa um processo AR (p) puramente estacionário; um ARIMA ($0, 0, q$) significa um processo MA (q) puramente estacionário. Dados os valores de p, d e q , é possível dizer qual processo está sendo modelado.

3.3.5 Modelo auto-regressivo integrado sazonal de médias móveis SARIMA

Os modelos ARIMA exploram a autocorrelação entre os valores da série em instantes sucessivos, mas, quando os dados são observados em períodos inferiores a um ano, a série também pode apresentar autocorrelação para uma estação de sazonalidades.

Os modelos que contemplam as séries que apresentam autocorrelação sazonal são conhecidos como SARIMA (ESPINOSA *et al.*, 2010). O modelo auto-regressivo integrado sazonal de médias móveis (SARIMA) é um método de previsão de séries temporais proposto por Box e Jenkins na década de 1970 (MAO *et al.*, 2018).

A forma geral do modelo SARIMA é a seguinte: SARIMA (p,d,q) (P,D,Q)_s, onde p e q são as ordens do auto-regressivo (AR) e da média móvel (MA), respectivamente, d é a ordem das diferenças, P, D e Q são as ordens sazonais correspondentes, e S representa as etapas das diferenças sazonais, que podem ser calculadas de acordo com as seguintes equações (NOBRE *et al.*, 2001):

$$\phi(B)\Phi(B^s)(1 - B^s)^D (1 - B)^d Z_t = \theta(B)\Theta(B^s)a_t \quad (3.9)$$

Em que:

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (3.10)$$

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (3.11)$$

$$\Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_p B^{sP} \quad (3.12)$$

$$\Theta(B^s) = 1 - \Theta_1 B^s - \dots - \Theta_Q B^{sQ} \quad (3.13)$$

Onde B é o operador de *backward*, Z_t é o valor observado no tempo t ($t = 1, 2, \dots, k$) e a_t é o erro residual no tempo t . Os processos do modelo SARIMA envolvem quatro etapas:

(1) Pré-tratamento da amostra: O ruído não branco, a estacionariedade e a sazonalidade de uma série cronológica são uma condição prévia para a construção de um modelo SARIMA.

No caso de séries temporais de ruído não branco, há uma correlação dos valores observados com uma distribuição não aleatória, e pode ser usada para construir um modelo.

Como o método mais comum de teste de raiz unitária, pode ser adoptado um teste de Dickey-Fuller Aumentado (ADF) para determinar se a série temporal é estacionária. Se a série temporal for não estacionária, a diferenciação poderá ser usada efetivamente para remover essa tendência. Com base nos gráficos sequenciais e experiências práticas, a sazonalidade das séries temporais pode ser explorada.

(2) Identificação e estimativa: Determinação das ordens do modelo SARIMA com base em gráficos para a função de autocorrelação (ACF) e função de autocorrelação parcial (PACF). O método dos mínimos quadrados é utilizado para estimar os parâmetros do modelo.

(3) Diagnóstico e otimização: A disponibilidade do modelo exigiu a verificação por parâmetros e testes de ruído branco. O teste Q foi empregado para diagnosticar o ruído branco dos erros residuais, que são independentes e normalmente distribuídos. A significância de um parâmetro único foi avaliada por meio de teste.

(4) Previsão: O modelo obtido foi aplicado para prever a velocidade do vento e a energia eólica na região de Petrolina. Finalmente, o modelo ótimo foi determinado com a ajuda de testes de precisão, e usado para prever estes parâmetros.

3.4 A Metodologia Box-Jenkins

O objetivo do método Box-Jenkins é identificar e estimar um modelo estatístico que possa ser interpretado como tendo sido gerado pelos dados amostrais. Se esse modelo estimado for utilizado para a previsão, deveremos admitir que suas características são constantes ao longo do período, e, particularmente, ao longo de períodos futuros.

A razão para requerer os dados estacionários é que qualquer modelo que seja inferido com base nesses dados pode ser interpretado como estacionário ou estável e, portanto, fornecer uma base válida para a previsão (POKORNY, 1987; HECKMAN e SERLETIS, 2015; YOUNG, 2015).

A pergunta, obviamente, é: Observando uma série de tempo, como se sabe se ela segue um processo puramente AR (em caso afirmativo, qual é o valor de p) ou um processo puramente MA (em caso afirmativo, qual é o valor de q) ou um processo ARMA (e em caso afirmativo, quais são os valores de p e q) ou um processo ARIMA, caso em que precisamos conhecer os valores de p , d , e q ? A metodologia Box-Jenkins é muito útil na resposta à pergunta anterior (GUJARATI e PORTER, 2011).

De acordo com (ZHANG, 2003), a ideia básica de identificação do modelo é que, se uma série de tempo é gerada a partir de um processo ARIMA, ele deve ter algumas propriedades teóricas de autocorrelação.

Ao combinar os padrões de autocorrelação empíricos com os teóricos, muitas vezes é possível identificar um ou vários modelos possíveis para uma dada série temporal. A base da abordagem metodológica de Box-Jenkins às séries temporais de modelagem é resumida na Figura 3.1 e consiste de três fases interativas: identificação do modelo, de estimativa de parâmetros e de ensaio de diagnóstico e aplicação.

Os conceitos de cada etapa são apresentados de acordo com (ZHANG, 2003; MAKRIDAKIS *et al.*, 2008; GUJARATI e PORTER, 2011; BIGOVIĆ, 2012), para modelos SARIMA:

Fase I: Identificação. Na primeira fase, é necessário encontrar uma classe de modelos SARIMA $(p, d, q)(P, D, Q)$. Em outras palavras, neste estágio descobrem-se os valores apropriados de $(p, d, q)(P, D, Q)$. Em primeiro lugar, a escolha depende das respostas sobre a necessidade para transformar a série, a fim de estabilizar a variância e a diferença dos dados, para obter uma série estacionária.

Estacionariedade é uma condição necessária na construção de um modelo SARIMA sendo útil para a previsão. Uma série temporal estacionária tem a propriedade de suas características estatísticas como a média e a estrutura de autocorrelação são constantes ao longo do tempo. Quando estacionariedade foi alcançado, função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) estão sendo usados. ACF e PACF representam quadro metodológico para a escolha potencial do modelo SARIMA para análise.

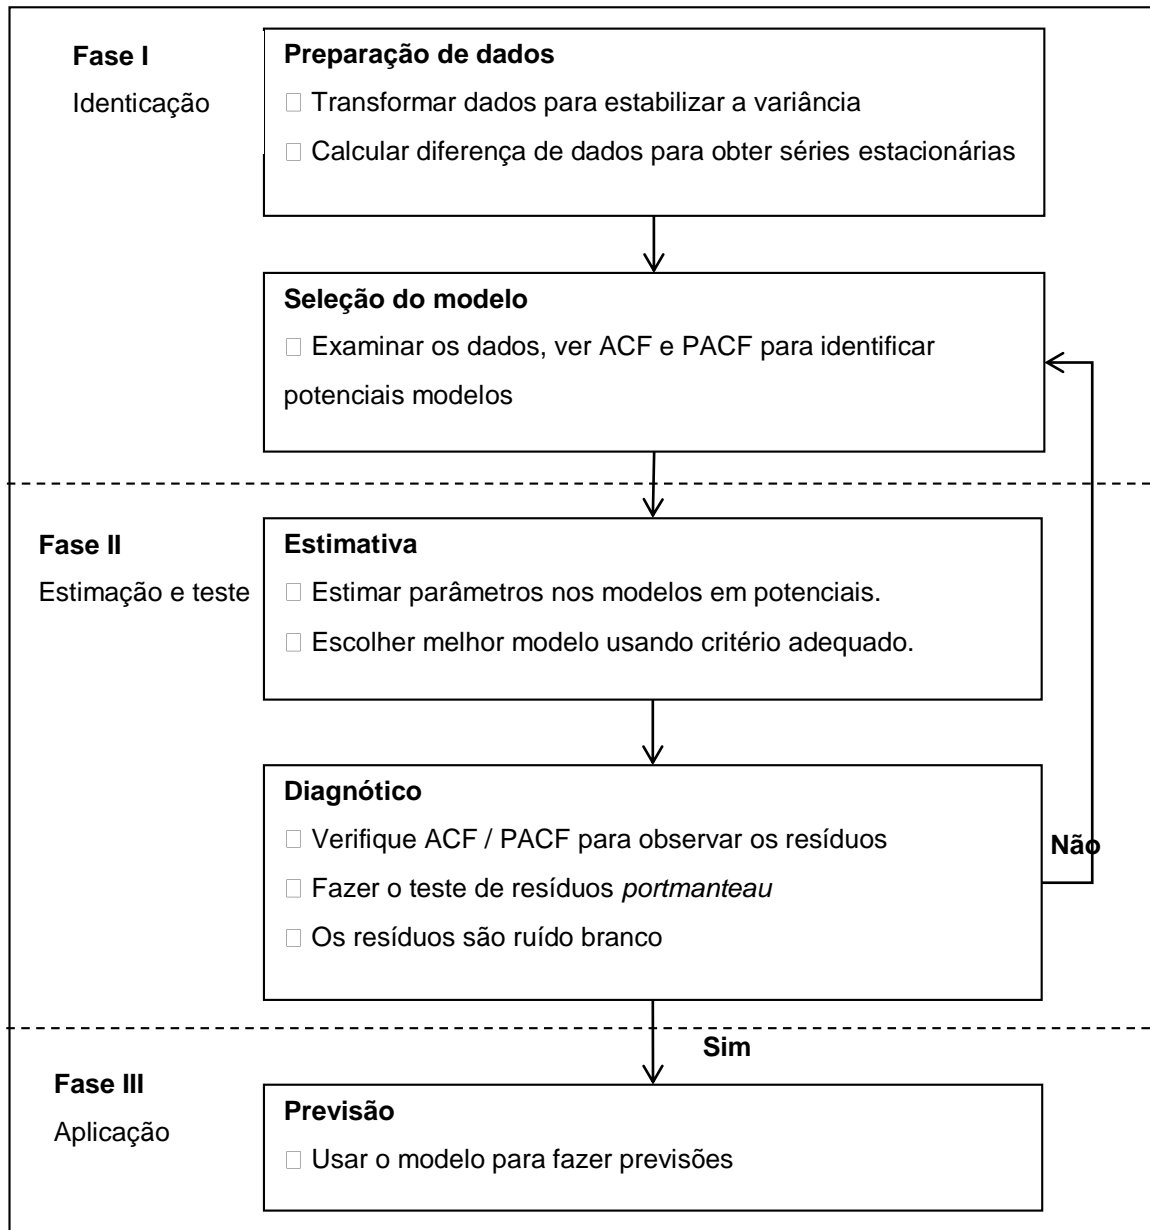


Figura 3.1: Metodologia Box-Jenkins para a modelagem de séries temporais.
 Fonte: (MAKRIDAKIS *et al.*, 2008).

Fase II: Estimação e teste. Depois de identificados os valores apropriados de $(p, d, q)(P, D, Q)$ s, o próximo passo é estimar os parâmetros dos termos autorregressivos e dos termos de média móvel sazonal incluídas no modelo, e ver se o modelo escolhido se ajusta razoavelmente bem aos dados para que seja possível que outro modelo SARIMA possa também fazer o trabalho. Teste do modelo escolhido compreende verificar ACF e PACF para observar resíduos. Os resíduos remanescentes após o ajuste do modelo deve ser ruído branco. Se os resíduos são ruído branco, modelo está adequado e pronto para a terceira etapa. Se não forem, é necessário voltar ao primeiro passo e repetir o procedimento novamente (Ver Figura 3.1).

Fase III: Previsão. A etapa final é a aplicação do modelo escolhido para a previsão. Uma das razões da popularidade da modelagem SARIMA é seu sucesso na previsão.

(KOVAČIĆ, 1995) lista vários princípios, critérios, que caracterizam um bom modelo. Eles são descritos como se segue: 1) Parcimônia, significa que o modelo escolhido deve ser o mais fácil possível, entre outros. 2) Identificabilidade, que permite interpretação do modelo em forma satisfatória. 3) Coerência com os dados, refere-se ao bom ajuste do modelo em relação aos dados. 4) Consistente com a teoria, harmonia dos pedidos com a teoria econômica relacionada ou com o senso comum. 5) Admissibilidade de dados, significa que o modelo não deve prever os valores que não satisfaçam algumas restrições finais. 6) Sucesso de Previsão, refere-se a previsão de precisão obtido pelo modelo.

3.5 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) têm sido amplamente estudadas e utilizadas na previsão de séries temporais. De acordo com (HAYKIN *et al.*, 2009), uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples (neurônios), que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: 1) O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. 2) Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Segundo (OLAOFE e FOLLY, 2012), o arranjo de neurônios em camadas e do padrão de ligação entre camadas são chamados de arquitetura de rede neural. A arquitetura de rede determina o número de pesos de conexão e a forma como os sinais de entrada são processadas na rede. Um neurônio é uma unidade de processamento de informação que é fundamental para o funcionamento de uma rede neural. Para alcançarem bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples denominadas "neurônios" ou "unidades de processamento".

Ainda de acordo com (OLAOFE e FOLLY, 2012), a rede neural é constituída por unidades de processamento, neurônios, altamente interligados, cada um dos quais realizam as seguintes funções: aceitar sinais de entrada a partir do exterior através do elo de ligação (peso), somar os sinais de entrada ponderados pelos pesos e gerar uma saída por meio de uma função de ativação.

(SILVA *et al.*, 2010; GOMIDE, 2012), resumem Redes Neurais Artificiais como modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), sendo as mesmas representadas aqui por vetores/matrizes de pesos sinápticos.

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 um objetivo de projeto desejado (HAYKIN, 2004).

Como um breve histórico, o primeiro modelo neurônio foi introduzido em 1943 por McCulloch e Pitts (ZHANG e ZHANG, 1999), e primeiro colocou o problema da utilização de uma rede de neurônios como um sistema computacional e engloba as principais características de uma rede neural global biológica, isto é, paralelismo e alta conectividade.

Segundo (BRAGA *et al.*, 2000), sua descrição matemática resultou em um modelo com n terminais de entrada x_1, x_2, \dots, x_n (que representam os dendritos) e apenas um terminal de saída y (representando o axônio). Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados w_1, w_2, \dots, w_n cujos valores podem ser positivos ou negativos, dependendo de as sinapses correspondentes serem inibitórias ou excitatórias. O efeito de uma sinapse particular i no neurônio pós-sináptico é dado por $x_i w_i$.

Os pesos determinam "em que grau" o neurônio deve considerar sinais de disparo que ocorrem naquela conexão. Um modelo básico de um neurônio artificial está ilustrado na Figura 3.2

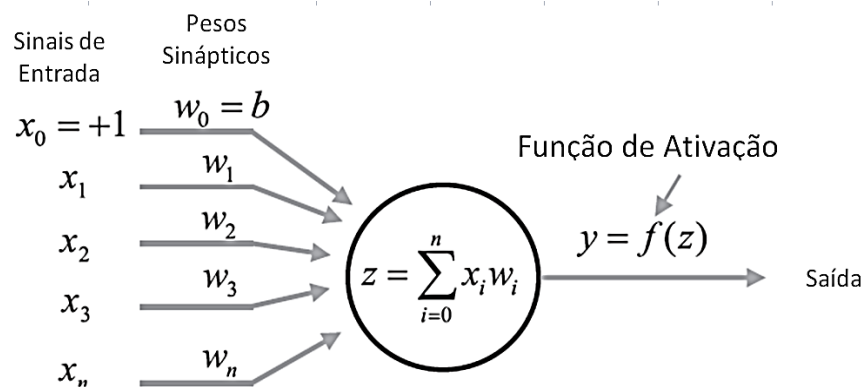


Figura 3.2: Modelo básico de um neurônio artificial.
 Fonte: (LAW WOZNIAK *et al.*, 2014).

Outro parâmetro importante na concepção de Redes Neurais Artificiais é a definição da arquitetura de uma RNA, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede.

De acordo com (DE PÁDUA BRAGA *et al.*, 2007), as redes podem ser classificadas quanto ao número de camadas, podendo-se ter: 1) redes de camada única: só existe um nó entre qualquer entrada e qualquer saída da rede (Figura 3.3 a, e); 2) redes de múltiplas camadas: existe mais de um neurônio entre alguma entrada e alguma saída da rede (Figura 3.3 b, c, d).

Quanto aos nós podem ter conexões do tipo: 1) *feedforward*, ou acíclica: a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de nodos em camadas de índice menor ou igual a i (Figura 3.3 a, b, c); 2) *feedback*, ou cíclica: a saída de algum neurônio na i -ésima camada da rede é usada como entrada de nodos em camadas de índice menor ou igual a i (Figura 3.3 d, e).




Figura 3.3: Exemplos de arquiteturas de Redes Neurais Artificiais (RNA).
Fonte: (DE PÁDUA BRAGA *et al.*, 2007).

As Redes Neurais possuem inúmeras áreas potenciais de aplicações, pois podem ser empregadas em diversos problemas relacionados às engenharias e ciências. Dentre as potenciais áreas de aplicabilidade apontadas por (SILVA *et al.*, 2010), destaca-se as duas áreas seguir que possuem maior correlação com o tema desta tese:

- Aproximador universal de funções: o objetivo consiste em mapear o relacionamento funcional entre as variáveis (tipicamente reais) de um sistema a partir de um conjunto conhecido de seus valores representativos.

As aplicações são as mais diversas possíveis, sendo que envolvem normalmente o mapeamento de processos cuja modelagem por técnicas convencionais são de difícil obtenção;

- Sistemas de previsão: o objetivo consiste em estimar valores futuros de um processo levando-se em consideração diversas medidas prévias observadas em seu domínio. Entre as aplicações disponíveis enquadram-se a previsão de séries temporais, previsões de mercados financeiros, previsões climáticas, etc;

3.5.1 Algoritmo de Retropropagação (*Backpropagation*)

A ideia de utilizar Redes Neurais Artificiais para previsão não é nova. A primeira aplicação remonta a 1964. Devido à falta de um algoritmo de treinamento de redes gerais de multi-camada no tempo, a pesquisa foi muito limitada. O algoritmo de retropropagação (*Backpropagation*) foi desenvolvido em 1986.

O algoritmo de aprendizado mais conhecido para treinamento de redes neurais múltiplas multicamadas é o algoritmo *backpropagation*.

De acordo com (DE PÁDUA BRAGA *et al.*, 2007), a maioria dos métodos de aprendizado para Redes Neurais Artificiais do tipo Redes Perceptron Multicamadas – MLP (original *Multilayer Perceptron*) utiliza variações deste algoritmo. O algoritmo *backpropagation* foi um dos principais responsáveis pelo ressurgimento do interesse em RNAs.

Basicamente, a aprendizagem por retropropagação de erro segundo explica (HAYKIN, 2004), consiste de dois passos através das diferentes camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação.

Nesta regra, os sinais de entrada são apresentados à rede que gera uma saída, que é comparada com a saída desejada, um erro é gerado e este erro aciona um mecanismo de controle

que aplica uma sequência de ajustes corretivos aos pesos sinápticos, a fim de aproximar a saída do resultado desejado, ou seja, a fim de minimizar o erro (HAYKIN, 2004).

De acordo com (DE PÁDUA BRAGA *et al.*, 2007), a fase passo para frente (*forward*) é utilizada para definir a saída da rede para um dado padrão de entrada. A fase passo para trás (*backward*) utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. A Figura 3.4 ilustra estas duas fases.

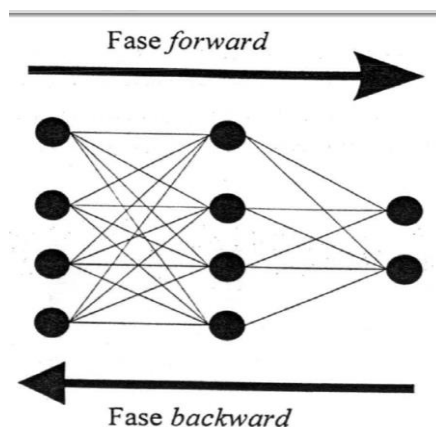


Figura 3.4: Fluxo de processamento do algoritmo *backpropagation*.
Fonte: (DE PÁDUA BRAGA *et al.*, 2007).

O algoritmo *Backpropagation* tem uma arquitetura interna simples que pode classificar as entradas em um conjunto de categorias-alvo. Faz uma rede em camadas aprender um mapeamento funcional entre um conjunto de padrões de entrada e suas respectivas saídas. Para isso, ele usa a função de ativação e treinamento supervisionado e consiste em várias etapas para processar dados (KAENSAR, 2013).

Em suma, as aplicações sucessivas das fases *forward* e *backward* fazem com que os pesos sinápticos e limiares dos neurônios se ajustem automaticamente em cada iteração, implicando-se na gradativa diminuição da soma dos erros produzidos pelas respostas da rede frente às desejadas.

O algoritmo *backpropagation* é baseado na regra delta proposta por Widrow e Hoff (DEMUTH *et al.*, 2014), sendo por isto também chamada de regra delta generalizado. Este algoritmo propõe uma forma de definir o erro dos nodos das camadas intermediárias, possibilitando o ajuste de seus pesos. Os ajustes dos pesos são realizados utilizando-se o método do gradiente (DE PÁDUA BRAGA *et al.*, 2007).

A formulação matemática a seguir é realizada por (DE PÁDUA BRAGA *et al.*, 2007), onde é exposto que a derivação da regra delta generalizada é simples e semelhante à derivação da regra delta. Neste caso, a função de custo a ser minimizada é uma função de erro ou energia, definida pela soma dos erros quadráticos e representada pela Equação 3.14:

$$E = \frac{1}{2} \sum_p \sum_{i=1}^k (d_i^p - y_i^p)^2 \quad (3.14)$$

Onde:

- E é a medida de erro total,
- p é o número de padrões,
- k é o número de unidades de saída,
- d_i é a i -ésima saída desejada e
- y_i é a i -ésima saída gerada pela rede.

Esta equação define o erro total cometido pela rede, ou a quantidade em que, para todos os padrões p de um dado conjunto, as saídas geradas pela rede diferem das saídas desejadas.

Embora o erro total E seja definido pela soma dos erros dos nodos de saída para todos os padrões, será considerado, sem perda de generalidade, que a minimização do erro para cada padrão individualmente levará à minimização do erro total. Assim, o erro passa a ser definido pela Equação 3.15:

$$E = \frac{1}{2} \sum_{j=1}^k (d_j - y_j)^2 \quad (3.15)$$

O algoritmo *backpropagation* procura minimizar o erro obtido pela rede ajustando pesos e limiares para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro. Para isto, ele utiliza um método de gradiente descendente.

3.6. Uso de *Wavelets*

Hoje em dia, são utilizados alguns modelos híbridos que combinam os modelos anteriormente relacionados com o uso de *Wavelets*. (NURY *et al.*, 2017) desenvolvem uma comparação entre duas abordagens, modelos wavelet-ARIMA e wavelet-ANN para séries

temporais de temperatura. A conclusão principal deste artigo é que o modelo wavelet-ARIMA é mais eficaz do que o modelo Wavelet-ANN.

(BONANNO *et al.*, 2015), propõem uma rede neural recorrente *Wavelet* com pré-processamento de dados de entrada semi-paramétricos para a previsão de energia micro-eólica em sistemas de geração integrada. Neste artigo, é apresentado um método melhorado de previsão de velocidade do vento usando um preditor da Rede de Neural Recorrente *Wavelet*.

Os dados de velocidade de entrada são pré-processados por uma abordagem semi-paramétrica. A eficácia do método proposto é demonstrada através de uma previsão de energia eólica ao longo de um ano inteiro.

Ainda há muitas discussões sobre o uso de *Wavelets* para análise de dados ou para usá-los na previsão combinada com outros modelos, como ARIMA ou Redes Neurais Artificiais. Em (SCHLÜTER e DEUSCHLE, 2010) é feita uma análise do uso de *Wavelets* para Previsão de séries temporais. Os autores chegaram a conclusões importantes: afirmam que, para séries temporais com um forte componente aleatório, as *Wavelets* geram poucas melhorias.

Segundo (ZHANG *et al.*, 2017) os dados das séries temporais observados podem exibir componentes diferentes, como tendências, sazonalidade e saltos, caracterizados por diferentes coeficientes em seus respectivos processos geradores de dados. Portanto, ajustar um determinado modelo de séries temporais a dados agregados pode levar tempo e pode levar a uma perda de precisão de previsão.

Ainda em (ZHANG *et al.*, 2017) os autores geram os coeficientes para componentes variáveis nas estimativas com base em análises de multiresolução baseadas em *Wavelets*. Assim, a precisão das previsões com base em dados agregados pode ser melhorada porque a restrição da igualdade entre os coeficientes do modelo para todos os componentes de dados é relaxada.

3.7. Considerações finais

No presente capítulo foi feita uma análise dos diferentes modelos de previsão de velocidade de ventos.

Foram resumidos os diferentes modelos, com as suas expressões de cálculo, entre eles, os modelos físicos, os modelos estatísticos e os modelos híbridos, sendo analisadas, além disso,

as diferentes séries temporais que podem ser usadas para fazer a previsão da velocidade do vento.

As redes neurais artificiais foram evidenciadas por ser parte do modelo proposto para prever a velocidade do vento e a energia eólica prevista. No seguinte capítulo se desenvolvem os aspectos metodológicos usados no trabalho.

CAPÍTULO 4

4. METODOLOGIA

4.1 Introdução

Esta tese de doutorado teve por objetivo desenvolver um modelo de previsão da geração de energia eólica para os horizontes de ultra curto prazo para intervalos de um minuto, curto prazo com intervalos de uma hora, médio prazo com intervalos de semanas, longo prazo com intervalos de meses. Para tal, será utilizado um modelo híbrido que combine as técnicas do modelo auto regressivo integrado de médias móveis sazonais (SARIMA) e Redes Neurais (RNA), este modelo foi inspirado da referencia (FILHO *et al.*, 2014).

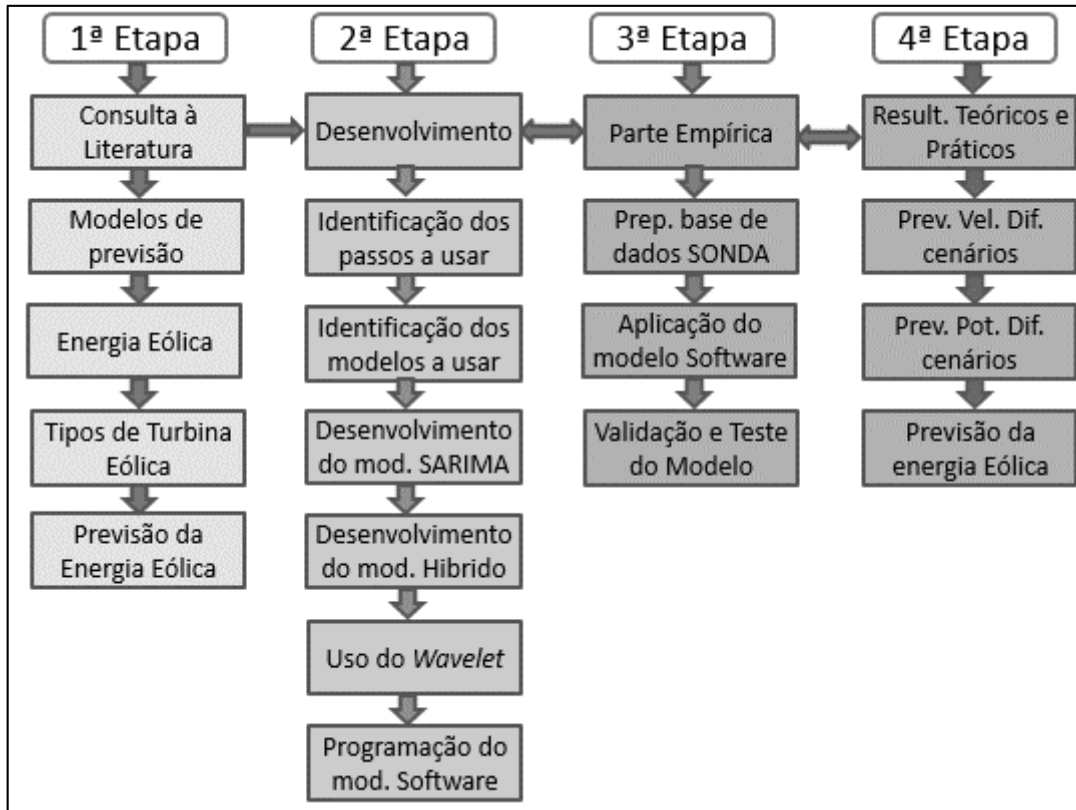
Para realização dessa tese de doutorado, utilizou-se o *software IBM SPSS MODELER PROFESSIONAL* versão 18.0 (IBM, 2017), de acordo com as especificações do produto, é uma plataforma de análise preditiva que foi concebida para fazer chegar à inteligência preditiva às decisões tomadas por indivíduos, grupos, sistemas e pela empresa.

O *software* fornece vários algoritmos avançados e técnicas que incluem análise de texto, análise de entidades, gestão de decisões e otimização, para ajudá-lo a selecionar as ações que terão melhores resultados. Disponível em várias edições, incluindo uma versão baseada na cloud, o SPSS Modeler pode incluir implementações de ambiente de trabalho ou integração em sistemas operativos.

4.2 Etapas da pesquisa

No quadro 4.1 se mostram as diferentes etapas da pesquisa desenvolvida nas quais são descritas na continuação:

Quadro 4.1. Fluxograma das etapas de pesquisa



Fonte: O Autor

Primeira Etapa: Nesta etapa foi definido o problema de pesquisa através de uma profunda revisão da literatura sobre energia eólica, métodos de previsão e previsão da energia eólica, identificando as lacunas nesta área do conhecimento.

Segunda Etapa: Foram identificados os diferentes passos de previsão e quais foram usados na pesquisa. Além disso, foram analisados os diferentes modelos de previsão e sua implementação para os diferentes passos assim como as suas programações em *software*.

Terceira Etapa: Esta etapa corresponde à tomada de dados para rodar o *software* com os diferentes modelos e passos. Foram usados os dados do Sistema de Organização Nacional de Dados Ambientais (SONDA, 2018). Os modelos existentes e o modelo proposto foram testados.

Quarta Etapa: Nesta etapa foram apresentados os resultados depois de ter aplicado o modelo programado no *software* e comparados os resultados. São oferecidas tabelas e curvas de previsão da velocidade do vento, da potência e da energia eólica para diferentes cenários de tempo, para determinada turbina eólica.

4.3. Banco de dados

As séries históricas das variáveis meteorológicas utilizadas foram obtidas no banco de dados disponibilizado pelo sistema de organização nacional de dados ambientais (SONDA, 2018), possíveis acessar no URL <http://sonda.ccst.inpe.br/basedados/>. Os dados complementares foram disponibilizados diretamente com técnicos da estação, pois a atualização até a data estudada não estava disponibilizada *online*.

A série inicia em 01 de janeiro de 2004 e finaliza em 31 de maio de 2017, onde apresenta os dados das seguintes variáveis:

- Temperatura do ar,
- Umidade do ar,
- Pressão atmosférica,
- Velocidade média do vento,
- Direção do vento.

Neste trabalho, decidiu-se por utilizar os dados da estação de Petrolina, Pernambuco, devido a maior concisão de dados disponíveis e da análise da validação dos dados, e também por informações tomadas do atlas eólico do Brasil (AMARANTE e A.L., 2001). A Tabela 4.1 mostra a localização das diferentes instalações eólicas.

Tabela 4.1: Localização das diferentes estações eólicas.

Estação (SIGLA)	Tipo	UF	ID	Latitude	Longitude	Alt.(m)
Belo Jardim (BJD)	A	PE	22	08°22'03" S	36° 25' 46" O	718
Brasília (BRB)	SA	DF	10	15° 36' 03" S	47° 42' 47" O	1023
Cachoeira Paulista (CPA)	S	SP	13	22° 41' 22,65" S	45° 00' 22,28"O	574
Caicó (MOREIRA)	S	RN	20	06° 28' 01" S	37° 05' 05" O	176
Campo Grande (CGR)	S	IVIS	12	20° 26' 18" S	54° 32' 18" O	677
Cuiabá (CBA)	S	IVIT	21	15° 33' 19" S	56° 04' 12" O	185
Ourinhos (ORN)	SA	SP	28	22° 56' 55" S	49° 53' 39" O	446
Palmas (PMA)	S	TO	19	10° 10' 40"S	48° 21' 43" O	216
Petrolina (PTR)	SA	PE	11	09° 04' 08" S	40° 19' 11" O	387
Rolim de Moura (RLM)	S	RO	27	11° 34' 54" S	61° 46' 25" O	252
Sao Luiz (SLZ)	S	IVIA	16	02° 35' 36" S	44° 12' 44" O	40
Sao Joao do Cariri (SCR)	A	PB	25	07° 22' 54" S	36° 31' 38" O	486
Sao Martinlio da Serra (SMS)	AS	RS	08	29° 26' 34" S	53° 49' 23" O	489
Triunfo (TRI)	A	PE	23	07° 49' 38" S	38° 07' 20" O	1123

Fonte: SONDA, (2018).

A rede SONDA de dados, antes de disponibilizar os dados de suas estações, submete-os a um processo de validação que objetiva identificar os dados suspeitos, através desse

processo foi possível garantir a confiabilidade dos dados. Um exemplo do gráfico dos resultados pode ser observado na figura 4.1, a qual apresenta um exemplo da validação dos dados do ano de 2014, essa validação foi realizada em toda base de dados utilizada.

O processo de validação dos dados obtidos pela estação SONDA baseia-se na estratégia de controle de qualidade de dados adotada pela BSRN (*Baseline Surface Radiation Network*). Embora a BSRN trate apenas de radiação solar, sua estratégia de controle de dados foi também aplicada aos dados meteorológicos e anemométricos, sendo para isso adotados os critérios de análise estabelecidos pela Webmet.com.

Foi realizado o *download* dos dados mensais de janeiro de 2004 a março de 2017, o que totalizaram 162 planilhas, extraindo somente as cinco variáveis utilizadas nesta tese, já descritas anteriormente, as quais foram apresentadas em um intervalo de amostra em minutos. Para base de dados inicial foi utilizado uma quantidade de 35.478.000 dados.

Devido à aplicação da metodologia, que conta um passo em minutos, horas, dias, semanas, meses e anos, foi realizado o ajuste dos dados minuto a minuto para os demais horizontes, através da média dos dados.

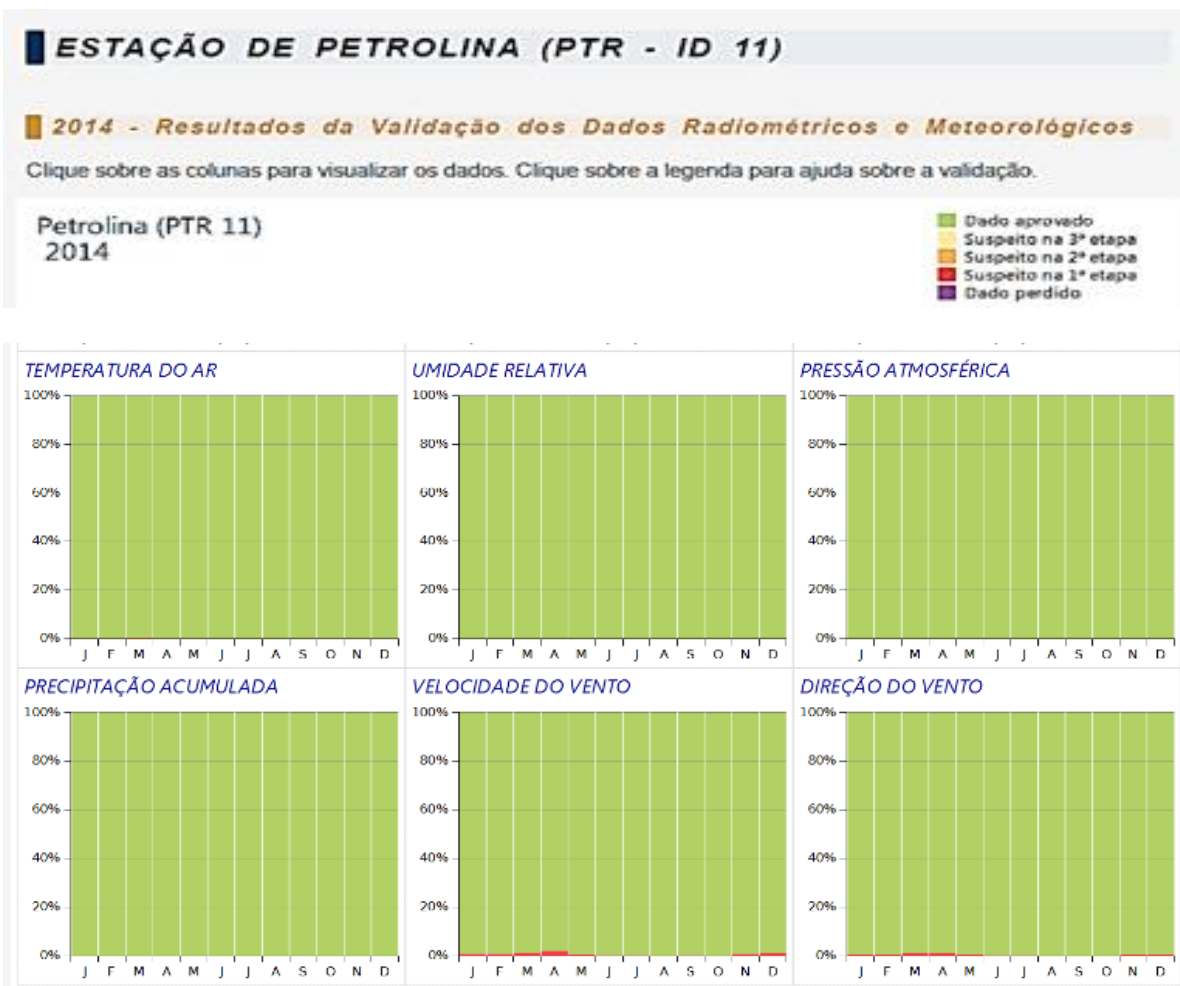


Figura 4.1: Exemplo de validação de dados da SONDA.
Fonte: SONDA, (2018)

A tabela 4.2 descreve as unidades de medida de cada variável que compõe o banco de dados utilizado no desenvolvimento deste estudo. As variáveis do vento são: Temperatura, Umidade, Pressão, Velocidade e Direção.

Tabela 4.2: Atributos das variáveis do banco de dados.

VARIÁVEIS METEOROLÓGICAS	
Temperatura do Ar na Superfície (tp_sfc)	Temperatura do ar superficial em °C
Umidade do Ar (humid)	Umidade relativa do ar em %
Pressão Atmosférica (press)	Pressão atmosférica em milibares
Velocidade do Vento a 10m (ws_10m)	Velocidade média do vento a 10m em m/s
Direção do Vento a 10m (wd_10m)	Direção média do vento a 10m de 0° a 360° (horário)

Fonte: (SONDA, 2018).

A Figura 4.2 apresenta o comportamento das cinco séries temporais componentes do banco de dados do estudo de 2004 à 2017.

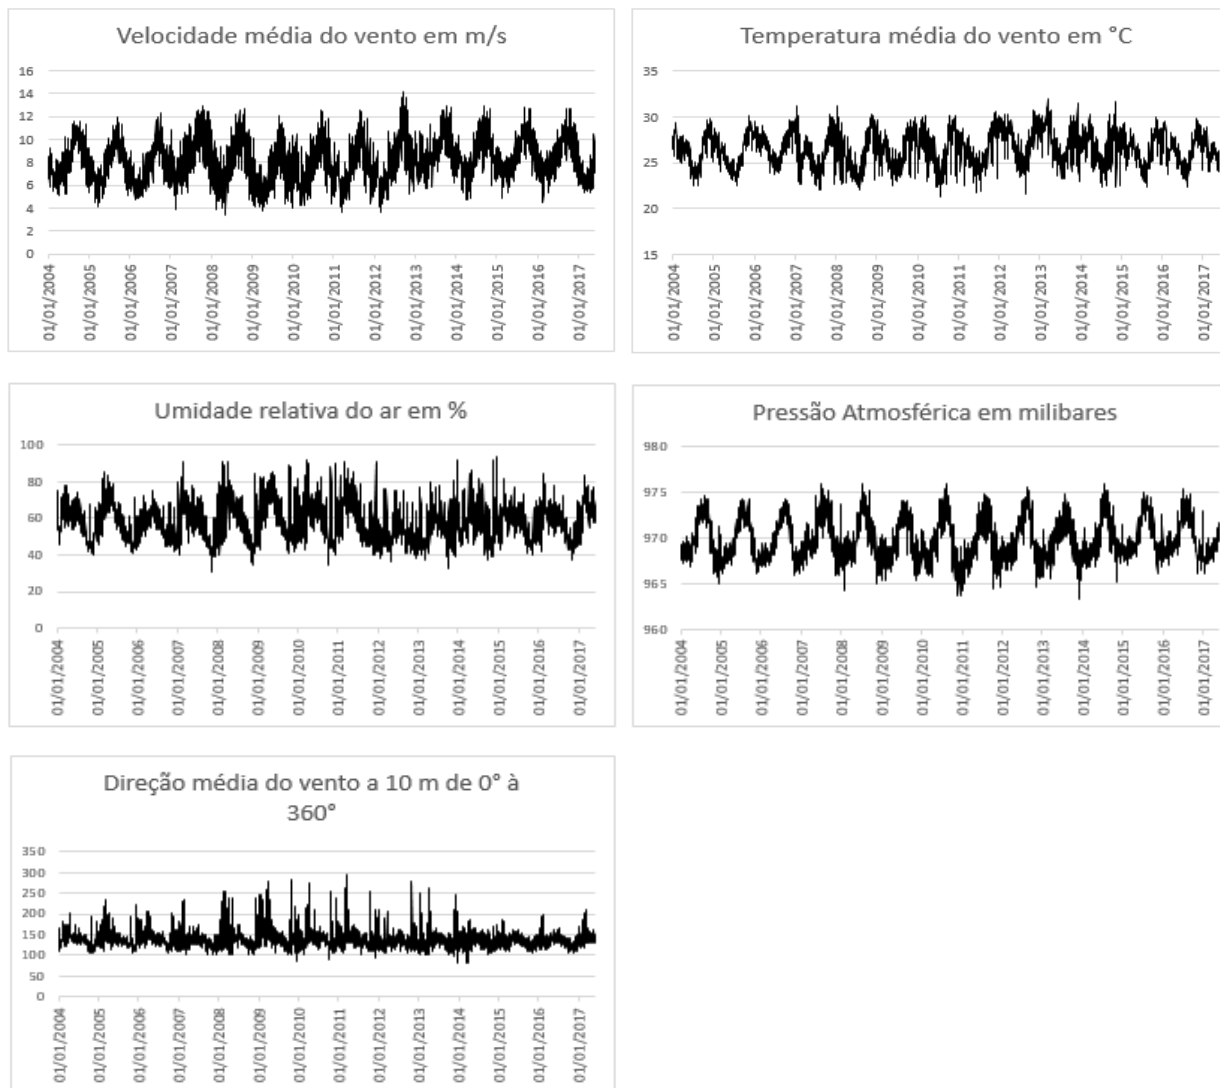


Figura 4.2: Comportamento das séries temporais componentes do banco de dados do estudo
Fonte: SONDA, (2018).

O padrão de comportamento das variáveis apresentadas na figura é muito parecido no que a velocidade média do vento, temperatura media do vento, umidade relativa e pressão atmosférica se referem; isso demonstra que a temperatura, a umidade e a pressão tem uma grande influência na velocidade do vento.

O banco de dados por mais que tenha passado por validação ainda apresentava valores discrepantes, os quais foram descartados por deixar os resultados com erro, e também foram considerados erros de leitura da estação.

A correlação é uma das possíveis relações estatísticas entre variáveis aleatórias. A correlação entre duas variáveis num contexto de séries temporais mede o grau de concordância relativamente ao sentido da evolução dos valores assumidos por cada variável ao longo do tempo. A tabela 4.3 apresenta a correlação entre as séries temporais da base de dados do estudo.

Tabela 4.3; Correlação entre as séries temporais.

	<i>Temperatura</i>	<i>Umidade</i>	<i>Pressão</i>	<i>Velocidade</i>	<i>Direção</i>
Temperatura	1,000				
Umidade	-0,663	1,000			
Pressão	-0,182	0,042	1,000		
Velocidade	-0,097	-0,427	0,125	1,000	
Direção	-0,313	0,536	-0,005	-0,389	1,000

Fonte: Gerado no SPSS MODELER, (2018).

Da Tabela anterior pode ser apreciado que a maior correlação da velocidade é com a umidade, mas num sentido negativo e com a pressão num sentido positivo.

A análise estatística dos dados das séries temporais, apresentando as medidas de posição e de dispersão são apresentadas na Tabela 4.4.

Tabela 4.4: Análise estatística dos dados das séries temporais.

	<i>Temperatura</i>	<i>Umidade</i>	<i>Pressão</i>	<i>Velocidade</i>	<i>Direção</i>
Média	26,531	57,565	969,901	8,103	138,499
Erro padrão	0,026	0,141	0,131	0,026	0,294
Mediana	26,570	56,845	969,360	8,020	136,178
Desvio padrão	1,810	9,840	9,197	1,790	20,568
Variância da amostra	3,276	96,833	84,580	3,204	423,041
Intervalo	10,860	63,150	854,560	10,750	211,700
Mínimo	21,200	31,040	651,390	3,390	82,330
Máximo	32,060	94,190	1505,950	14,140	294,030

Fonte: Gerado no SPSS MODELER, (2018).

Da tabela 4.4 pode-se afirmar que o desvio padrão da velocidade é pequeno em relação ao desvio padrão da pressão e da umidade. O valor médio da velocidade é um valor adequado para o uso da energia eólica.

4.4. Modelo de previsão proposto

O modelo de previsão apresentado é o *modelo híbrido*, o qual é composto pelo modelo SARIMA e pelo modelo de Redes Neurais, pelos quais são propostas as previsões de velocidade do vento para 5, 10 e 20 passos à frente, determinada como variável dependente, utilizando

variáveis explanatórias. A predição é realizada pelo impacto das variáveis explanatórias na variável dependente.

Em função do comportamento irregular das séries temporais, as quais não podem ser definidas como lineares ou não lineares, o modelo de predição é definido por dois modelos.

O modelo SARIMA com uma forte definição na literatura, a qual garante a tratativa do contexto linear da predição com sazonalidade, propicia um modelo linear aceitável na modelagem das séries temporais da previsão do vento.

A parte do modelo de Redes Neurais Artificiais é utilizado nesta tese em complemento à parte não-linear da série temporal, definindo assim o modelo híbrido proposto representado graficamente na figura 4.3, a qual está descrito detalhadamente.

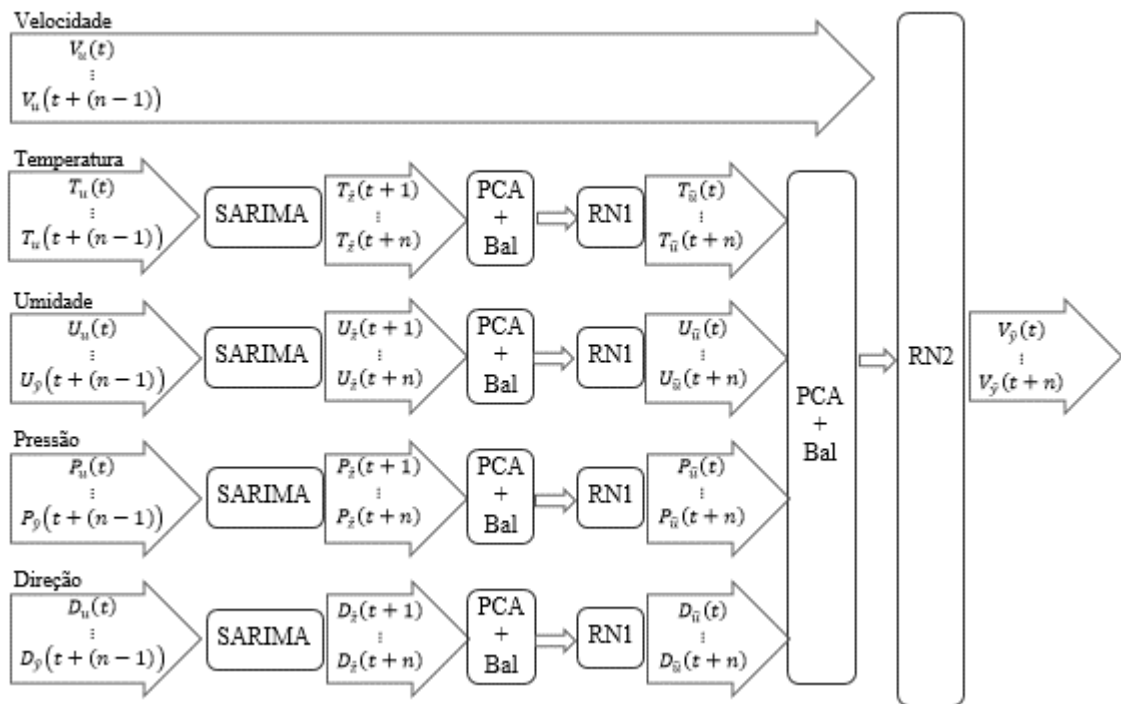


Figura 4.3: Diagrama de blocos do modelo híbrido proposto
Fonte: O Autor

Etapa 01 (Banco de dados) – A primeira etapa da predição segue a partir do processo descrito no item 4.2, onde descreve a obtenção do banco de dados, considera-se a variável velocidade do vento V_t é função das variáveis componentes $Tu_t^i, Uu_t^i, Pu_t^i, Du_t^i$. Cada variável componente é composta por uma estrutura linear e não linear $Cu_t^i = f(CL_t, CN_t)$, onde $CL_t =$ Componente linear e $CN_t =$ Componente não linear.

Etapa 02 (SARIMA) é $U_{\hat{z}}(t + 1) = CL[U_u(t)]$; , $U_{\hat{z}}(t + 2) = CL[U_u(t + 1)]$, ..., $U_{\hat{z}}(t + n) = CL[U_u(t + (n - 1))]$, onde CL = componente linear = SARIMA. Nesta segunda etapa de predição, as relações lineares das 5 variáveis são modeladas através do filtro SARIMA com N passos a frente (5, 10 e 20) ($C\hat{z}_{t+n}^i$), as saídas são componentes individuais de cada uma das variáveis, sendo as resultantes para Temperatura ($T\hat{z}_{t+n}^i$), Umidade ($U\hat{z}_{t+n}^i$), Pressão ($P\hat{z}_{t+n}^i$), e Direção ($D\hat{z}_{t+n}^i$).

Etapa 03 (PCA) – A finalidade desta etapa é otimizar os dados com redução dos mesmos eliminando sobreposições através das combinações lineares das variáveis originais. Essa etapa visa melhorar a configuração de aprendizagem antes de treinar a rede. A análise de componentes principais – ACP ou PCA também conhecida como Transformada discreta de Karhunen-Loève (KLT), é um método estatístico de múltiplas variáveis mais simples.

Etapa 04 (RN1) é: $U_{\hat{u}}(t + 1) = CN1[U_{\hat{z}}(t + 1)]$, $U_{\hat{u}}(t + 2) = CN1[U_{\hat{z}}(t + 2)]$, ..., $U_{\hat{u}}(t + n) = CN1[U_{\hat{z}}(t + n)]$, onde CN1 = componente não-linear 1 = RN1. Os valores das variáveis entram na primeira Rede Neural (RN1), que é utilizada para mapear as relações não-lineares das séries de variáveis explanatórias. Esta etapa resulta na predição com N passos em frente ($C\hat{u}_{t+n}^i$), as saídas são componentes individuais de cada uma das cinco variáveis, sendo as resultantes para Temperatura ($T\hat{u}_{t+n}^i$), Umidade ($U\hat{u}_{t+n}^i$), Pressão ($P\hat{u}_{t+n}^i$), e Direção ($D\hat{u}_{t+n}^i$).

Etapa 05 (RN2) é: $V_{\hat{y}}(t + 1) = CN2\{U_{\hat{u}}^1(t + 1), U_{\hat{u}}^2(t + 1), U_{\hat{u}}^3(t + 1), U_{\hat{u}}^4(t + 1), V_u(t)\}$

$$V_{\hat{y}}(t + 2) = CN2\{U_{\hat{u}}^1(t + 2), U_{\hat{u}}^2(t + 2), U_{\hat{u}}^3(t + 2), U_{\hat{u}}^4(t + 2), V_{\hat{y}}(t + 1)\}$$

.....

$$V_{\hat{y}}(t + n) = CN2\{U_{\hat{u}}^1(t + n), U_{\hat{u}}^2(t + n), U_{\hat{u}}^3(t + n), U_{\hat{u}}^4(t + n), V_{\hat{y}}(t + (n - 1))\}$$

Onde:

- CN2 = componente não-linear 2 = RN2.

Faz-se a predição da velocidade do vento n passos à frente $V_{\hat{y}}(t + n)$, utilizando uma segunda Rede Neural (RN2) precedido do processo de preparação de dados novamente.

A entrada $V_u(t)$ serve para prever $V_{\hat{y}}(t + 1)$.

Para prever $V_{\hat{y}}(t + 2)$, a entrada deve ser $V_{\hat{y}}(t + 1)$.

Para prever $V_{\hat{y}}(t + 3)$, a entrada deve ser $V_{\hat{y}}(t + 2)$.

Para prever $V_{\hat{y}}(t + 4)$, a entrada deve ser $V_{\hat{y}}(t + 3)$.

.....

Para prever $V_{\hat{y}}(t + n)$, a entrada deve ser $V_{\hat{y}}(t + (n - 1))$.

As entradas desta Rede Neural são as variáveis explanatórias preditas n passos à frente. A RN2 tem apenas um neurônio de saída e prevê os n passos à frente.

4.5 Considerações finais

No presente Capítulo foi proposta a metodologia a seguir para o desenvolvimento da pesquisa, foram mostradas as etapas do trabalho e foi descrito o modelo de previsão proposto que é um modelo híbrido de SARIMA com duas Redes Neurais.

A partir da descrição da metodologia empregada para a previsão do vento, o próximo capítulo apresentará os resultados obtidos com o uso desta metodologia na aplicação no banco de dados.

CAPÍTULO 5

5. RESULTADOS OBTIDOS, VALIDAÇÃO EXPERIMENTAL E ANÁLISE

5.1 Introdução

Neste capítulo são apresentados os resultados da predição da velocidade do vento para a localidade de Petrolina em Pernambuco, Brasil. Tal previsão viabilizou conhecer as possibilidades de geração eólica nesse lugar e possibilitou prever a geração de energia elétrica. Foram usados quatro tipos de previsões, considerando-se prazos ultra curto, curto, médio prazo e longo prazo.

Esses resultados foram obtidos com o auxílio do *software* IBM SPSS MODELER PROFESSIONAL versão 18.0, o qual já foi descrito em detalhes no capítulo anterior. Esta ferramenta propiciou a descoberta rápida de padrões e tendências em dados numéricos estruturados de maneira facilitada, usando uma única interface visual.

A configuração do computador portátil utilizado para realizar os experimentos teve as seguintes características: processador Intel i7 Core™ i7-3632QM, 2.20 GHz, 4 Gb de RAM e 1 Tb de HD. O sistema operacional foi o Windows 10 de 64 bits em língua portuguesa.

5.2. Apresentação dos modelos propostos e comparativos

Baseado nos objetivos deste trabalho, são apresentados os resultados obtidos para previsão de velocidade do vento, utilizando quatro modelos, SARIMA, Redes Neurais, SARIMA + Redes Neurais 1, o modelo híbrido proposto, constituído da seguinte combinação: SARIMA + Redes Neurais 1 + Redes Neurais 2. Será apresentado ainda o modelo comparativo SARIMA+*Wavelet*, com o intuito de verificar o comportamento do modelo proposto.

Para possibilitar a comparação dos diversos horizontes de previsão, a aplicação dos modelos seguem uma configuração igual para todos os horizontes, assim foi possível fazer a verificação de qual horizonte obteve a melhor resposta para os modelos propostos, as configurações foram aplicadas na primeira etapa do modelo SARIMA o qual pode ser verificado no $(p, d, q)(P, D, Q)$ s explicado a seguir.

As aplicações das redes neurais tanto no modelo híbrido proposto quanto no comparativo somente Redes Neurais seguiram padronização como demonstrado após o modelo SARIMA.

As previsões seguiram o padrão apresentado na tabela 5.1. onde apresenta os padrões dos horizontes de previsão, a previsão ultra curto prazo utiliza o intervalo de grandeza para cada minuto, para previsão de curto prazo, foi utilizado a grandeza de horas, cujo intervalo foi de uma em uma hora, para previsão em médio prazo utilizou-se duas grandezas de dias com intervalos de um dia e grandeza semana, com intervalos de uma em uma semana, a previsão de longo prazo também utilizou duas grandezas, mês e ano, com intervalo de um em um mês e intervalo de um ano.

Tabela 5.1: Padrão dos horizontes de previsão.

Sigla	Previsão	Grandeza	Quantidade de Dados	Base
UCP	Ultracurto Prazo	Minutos	7200	5 dias
CP	Curto Prazo	Horas	8760	1 ano
MP	Médio Prazo	Dias	4745	13 anos
		Semanas	1248	13 anos
LP	Longo Prazo	Meses	156	13 anos
		Ano	13*	13 anos

Fonte: O Autor.

Na previsão do horizonte ano, devido à pequena quantidade de dados disponibilizada, foi necessário utilizar a base de horizonte em meses, na qual foi aplicada a técnica de interpolação dos resultados de base em meses, transformando os mesmos para anos, e também no horizonte em anos, foi utilizada a técnica de extrapolação de média móvel de dados 5 anos para frente para propiciar a comparação dos resultados previstos com o real.

Os valores inicialmente obtidos da base de dados foram em minutos, e a partir deste, para obter os dados em hora, foi feita a média simples de 60 minutos. Para obter os dados em dias, foi calculada a média simples de 24 horas. Para obter os dados em semanas, foi calculado a média simples de 7 dias. Para obter os dados em meses, foi calculado a média simples de 30 dias. E para obter os dados em anos, foi calculado a média simples de 365 dias.

Para previsão de ultra curto prazo e curto prazo, foi utilizado base de dados para 5 dias e um ano respectivamente.

5.2.1 Modelo SARIMA

A primeira etapa do algoritmo híbrido proposto ilustrada na figura 5.1 é constituída pelo modelo SARIMA (Auto Regressivo Integrado de Média Móvel Sazonal) o qual resulta da combinação de três filtros: o componente Auto-regressivo (AR), o filtro de Integração (I) e o componente de Médias Móveis (MA), considerando a sazonalidade das variáveis. A representação deste modelo é feita através da notação SARIMA de ordem (p,d,q)(P,D,Q).

Uma representação SARIMA (1,2,0)(1,0,1), indica um modelo de ordem 1 para o componente AR (Auto-Regressivo), ordem 2 para o componente I (Integração ou diferenciação) e o último ordem 0 para o componente MA (Média Móvel).

Onde:

P = número de termos auto-regressivos sazonais;

D = Número de diferenças sazonais;

Q = Número de médias móveis sazonais.

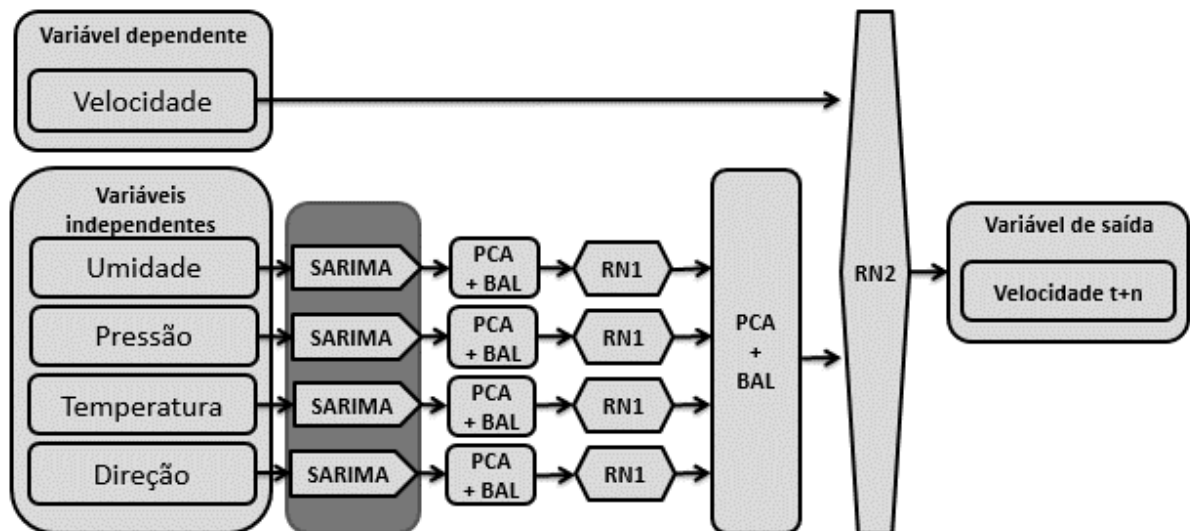


Figura 5.1: Diagrama de blocos do modelo primeira etapa – SARIMA

Fonte: O Autor

A velocidade foi classificada como dependente, pois seu valor previsto no modelo híbrido proposto dependeu dos valores das variáveis umidade, pressão, temperatura e direção.

Os modelos SARIMA (p, d, q)(P,D,Q)s obtidos para cada uma das séries temporais são apresentados respectivamente em cada etapa de aplicação conforme tabela 5.2.

Tabela 5.2: Modelo SARIMA para cada horizonte.

Previsão	Grandeza	Modelo SARIMA (p, d, q)(P.D.Q.)s
Ultracurto Prazo	Minutos	(0,1,1) (0,0,0)12
Curto Prazo	Horas	(2,0,0) (2,0,1)12
Médio Prazo	Dias	(2,0,2) (1,0,1)12
	Semanas	(0,1,1) (1,0,2)12
Longo Prazo	Meses	(1,01) (1,0,0)12
	Ano	(0,2,1) (0,1,2)12

Fonte: Gerado pelo SPSS Modeler, (2018)

Nesta etapa a variável dependente Velocidade e as variáveis independentes descritas anteriormente, as quais são a Umidade, Pressão, Temperatura e Direção, geraram resultados independentes umas das outras. A confiança utilizada foi de 95%. A independência foi processada através do filtro de entrada do programa, o intervalo de tempo e toda base de dados utilizada foi de 01 de janeiro de 2004 até 31 de maio de 2017, a estimação baseou-se desde o início dos dados, a previsão seguiu a proposta multipassos.

Os valores iniciais encontrados com o modelo SARIMA representados foram o Erro mínimo, Erro máximo, Erro médio, Desvio padrão e Correlação linear.

Para avaliação da precisão da previsão da variável velocidade foram utilizados velocidade média do vento (VMED), Erro Médio Absoluto (MAE), Raiz do Erro Médio Quadrático (RMSE), e Erro Médio Percentual Absoluto (MAPE) (WU e SHAHIDEHPOUR, 2010) detalham esses itens.

VMED é o cálculo da média da velocidade do vento, Onde, N é o número de amostras, V_i^{real} é o valor real da Velocidade, equação 5.1.

$$VMED = \frac{1}{N} \sum_{i=1}^N V_i^{real} \quad (5.1)$$

MAE expressa precisão nas mesmas unidades dos dados, o que ajuda a conceituar a magnitude do erro. A equação 5.2.

$$MAE = \frac{1}{N} \sum_{i=1}^N |V_i^{real} - V_i^{prev}| \quad (5.2)$$

Onde, N é o número de amostras, V_i^{real} é o valor real da Velocidade e V_i^{prev} é a velocidade predita.

RMSE é uma medida comumente usada da exatidão dos valores de séries temporais ajustados, como na equação 5.3.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (V_i^{real} - V_i^{prev})^2} \quad (5.3)$$

MAPE expressa precisão como porcentagem do erro. Como esse número é uma porcentagem, ele pode ser mais fácil de compreender do que outras estatísticas. Por exemplo, se o MAPE é 7, em média, a previsão está incorreta em 7%. A equação 5.4:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|V_i^{real} - V_i^{prev}|}{V_{med}} \times 100\% \quad (5.4)$$

Os valores por si não podem demonstrar resultados positivos ou negativos, esses valores são base para comparativos de modelos.

5.2.2 Modelo SARIMA+RN1

A segunda etapa do modelo ilustrado com o diagrama de blocos na figura 5.2 foi realizada na primeira Rede Neural - RN1, esta etapa foi executada para prever variáveis explanatórias, utilizando os resultados previstos pelo modelo SARIMA como variáveis de entrada, as quais foram reduzidas através do (PCA) Análise de Componentes Principais, este encontrou combinações lineares dos campos de entrada reduzindo os componentes para utilização das variáveis principais.

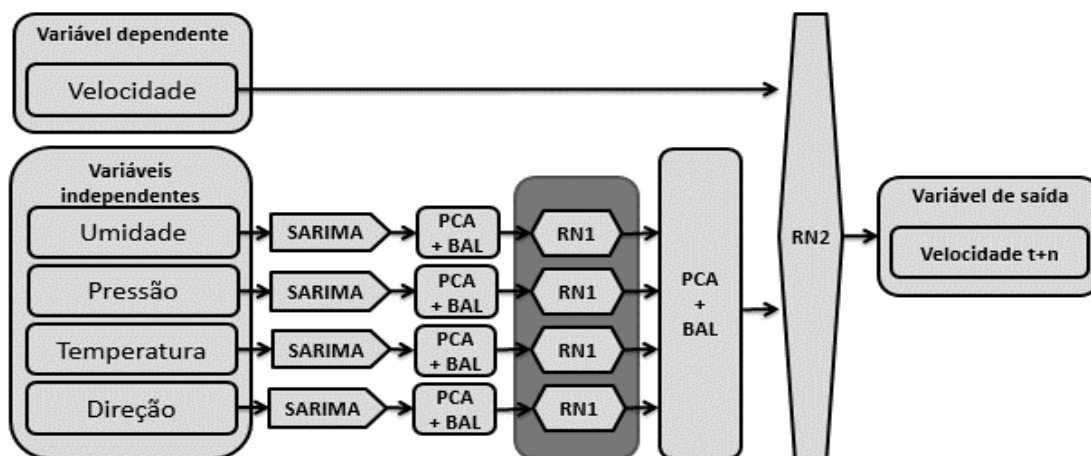


Figura 5.2: Diagrama de blocos do modelo segunda etapa – SARIMA+RN1.

Fonte: O Autor

A RN1 apresenta 8 neurônios nas camadas de entrada, 2 neurônios na camada oculta ou intermediárias e 1 neurônio na camada de saída, configuração utilizada para todas as variáveis, foi utilizado o algoritmo de treinamento de retropropagação do erro, o qual ajusta os pesos da rede com objetivo de minimizar o erro entre os valores reais e as saídas previstas. O particionamento de dados foi de 80% para treino e 20% para teste. (HERTZ, 2018).

O critério de parada utilizado foi o erro mínimo encontrado. A rede foi treinada com função de ativação do tipo tangente sigmoideal para todos os neurônios.

A rede segue uma programação padronizada com MLP com a topologia 8-2-1, função de ativação logística e algoritmo *backpropagation*.

A rede utilizou os dados para cada horizonte respectivo, ou seja 180 para minutos, 72 para horas, 21 para dias, 12 para semanas, 38 para meses, 38 para anos através da aplicação da extrapolação nos dados; esses atrasos representam o ciclos de cada representação, e projetou um passo para frente, a rede recursiva re-inseriu cada projeção na entrada da MLP e fez essa repetição automaticamente 20 vezes.

Nesta etapa foi feita a predição da velocidade SARIMA+RN1 e analisado todos os valores com base nos Erros, Desvio padrão e Correlação linear.

5.2.3 Modelo híbrido proposto (SARIMA+RN1+RN2)

A etapa final do algoritmo é representada pelo diagrama de blocos na figura 5.3. Nesta etapa foi feito a predição final da velocidade.

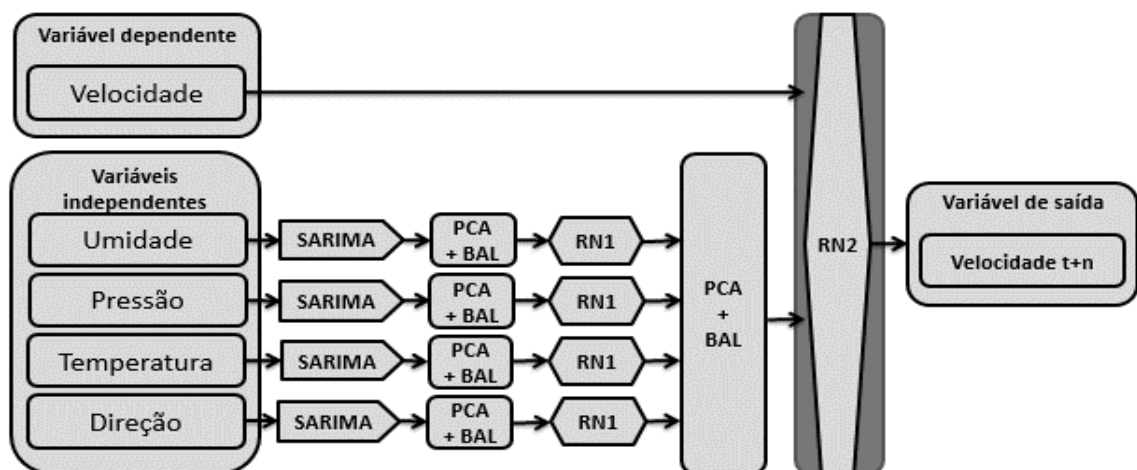


Figura 5.3: Diagrama de blocos do modelo híbrido proposto etapa final (SARIMA+RN1+RN2).

Fonte: O Autor

A RN2 utilizou as saídas do modelo SARIMA+RN1 como entrada, com intuito de otimizar os resultados, o qual ajustou os pesos da rede neural com objetivo de minimizar o erro entre os valores reais e saídas previstas. O particionamento de dados foi de 80% para treino e 20% para teste.

A rede seguiu uma programação padronizada com MLP com a topologia 11 neurônios na camada de entrada, 8 neurônios na primeira camada oculta, 8 neurônios na segunda camada oculta, 8 neurônios na terceira camada oculta e 1 neurônio na camada de saída, função de ativação logística e algoritmo *backpropagation*.

A rede utilizou valores para cada horizonte respectivo, ou seja, 180 para minutos, 72 para horas, 21 para dias, 12 para semanas, 38 para meses, 38 para anos através da aplicação da extrapolação nos dados, esses atrasos representaram os ciclos de cada representação, e projetaram um passo para frente, a rede recursiva re-inseriu cada projeção na entrada da MLP e faz essa repetição automaticamente 20 vezes.

O critério de parada é o erro mínimo encontrado por modelo. A rede foi treinada com função de ativação do tipo tangente sigmoideal para todos os neurônios.

5.2.4 Modelo Redes Neurais Artificiais

Foi utilizado o modelo de redes neurais com o objetivo de fazer o comparativo entre os resultados obtidos como o modelo híbrido proposto, a configuração do modelo teve como entrada os dados ambientais de valores reais descritos como variáveis de entradas.

A rede seguiu uma programação padronizada com MLP com a topologia formada com 9 neurônios na camada de entrada, 7 neurônios na camada oculta e 1 neurônio na camada de saída, a função de ativação logística e algoritmo *backpropagation*.

A rede utilizou valores para cada horizonte respectivo, ou seja, 180 para minutos, 72 para horas, 21 para dias, 12 para semanas, 38 para meses, 38 para anos através da aplicação da extrapolação nos dados, esses atrasos representaram o ciclos de cada representação, e projetaram um passo para frente, a rede recursiva re-inseriu cada projeção na entrada da MLP e fez essa repetição automaticamente 20 vezes.

5.3. Previsão da Velocidade e da Potência

Para uma velocidade do vento dada, a potência gerada depende do tipo de gerador a usar. O aerogerador escolhido para o estudo foi o modelo WES100 tem 100 kW de potência, com capacidade para gerar 100 kWh por mês a uma velocidade média do vento de (5.4 m/s), a figura 5.4 mostra a curva de potência do aerogerador.

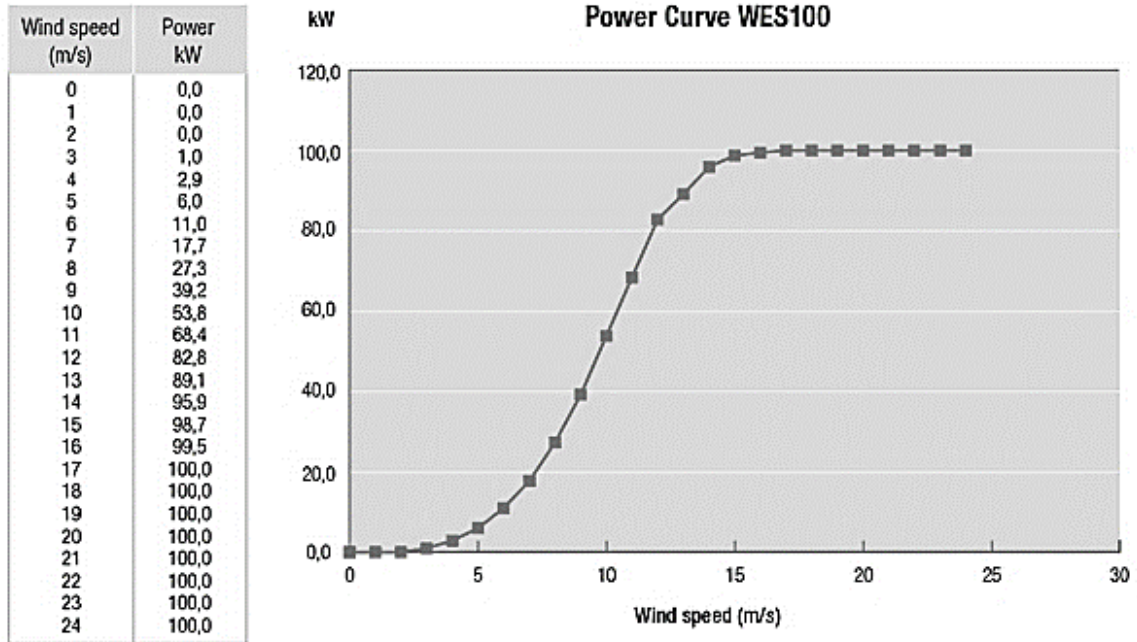


Figura 5.4: Curva de potência do aerogerador WES100
 Fonte: <http://www.energiapura.com/aerogerador-wes-100>, (2017).

Para obter a equação da curva de potência do gerador foi utilizado o *software Curve Expert* a partir dos dados de Potência e Velocidade. A equação que representa a curva da geração é dada por:

$$P = a + bx + cx^2 + dx^3 + ex^4 \tag{5.5}$$

Onde:

P = potência gerada

X = Velocidade do vento

a = 1.515151515153736E-02

b = -6.414141414141929E-02

c = -9.734848484848370E-02

d = 8.005050505050480E-02

e = -1.893939393939385E-03

A figura 5.5 mostra o gráfico e tabela da geração de energia anual do aerogerador WES 100 em Kwh.

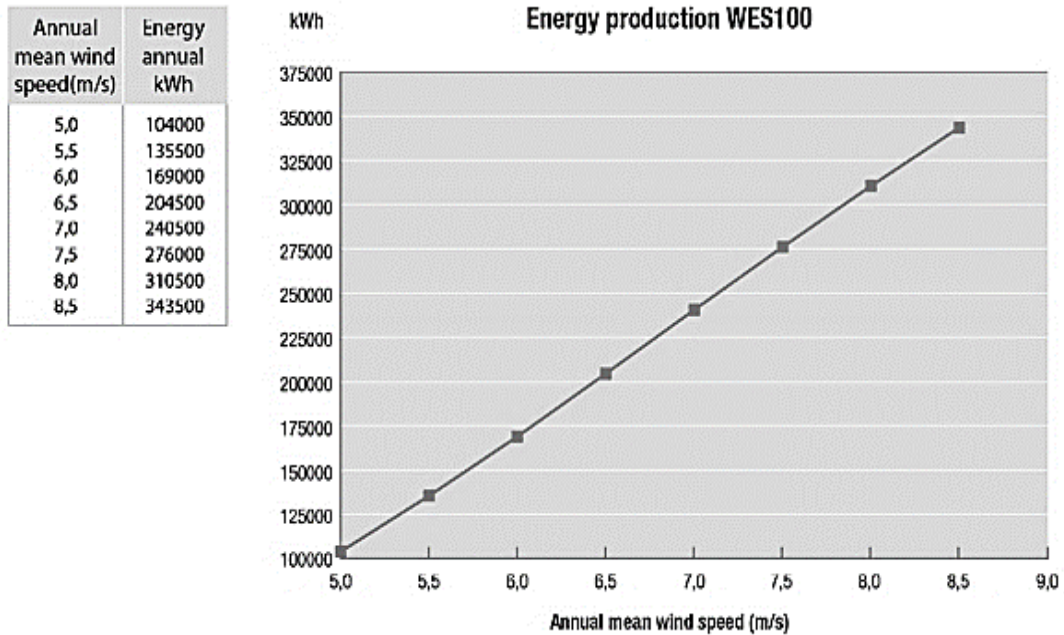


Figura 5.5: Geração de energia anual em kWh
 Fonte: <http://www.energiapura.com/aerogerador-wes-100>, (2017).

Também para obter a equação da curva de energia fornecida pelo gerador foi utilizado o *software Curve Expert* (<https://www.curveexpert.net/download/>) a partir dos dados de energia e velocidade. A equação de energia anual gerada conforme a velocidade do vento para esta turbina é:

$$E = a + b * v + c * v^2 + d + e \quad (5.6)$$

Em que:

v = velocidade do vento

a = 5.738920454544906E+05

b = -3.862506313128678E+05

c = 9.348295454540566E+04

d = -8.406565656562561E+03

e = 2.803030303030391E+02

Estas equações Foram aplicadas após cada horizonte de previsão e foi feita a análise comparativa dos resultados no final.

5.4. ANÁLISE DOS RESULTADOS

Nesta tese, os resultados obtidos para a previsão da velocidade do vento foram geradas utilizando cinco modelos: SARIMA, SARIMA + *Wavelet*, SARIMA + Redes Neurais 1, Redes Neurais e o Modelo Híbrido Proposto (SARIMA + Redes Neurais + Redes Neurais 2).

Para permitir a comparação dos diferentes horizontes de previsão, a aplicação dos modelos seguiu a mesma configuração para todos os horizontes, desta forma foi possível verificar qual horizonte teria a melhor resposta para cada modelo proposto.

Para cada horizonte, o comportamento estatístico dos dados varia em função dos valores das variáveis, a variação do comportamento da velocidade do vento, por exemplo, foi diferente se comparado um intervalo de um minuto, com um intervalo de um dia, um mês ou um ano.

Os resultados foram mostrados para cada universo e horizonte de previsão, conforme descrito acima. No caso da velocidade do vento, utilizaram-se *Wavelets* simétricas de variação combinadas (SHOAIB *et al.*, 2018) com o modelo SARIMA para a previsão.

Os resultados obtidos foram mostrados para cada universo de previsão conforme descrito anteriormente.

5.4.1 Previsão a ultra curto prazo - UCP (minutos)

A primeira aplicação foi realizada na previsão de ultra curto prazo que abrange a grandeza de tempo com intervalos de minuto em minuto.

Os dados utilizados tiveram uma base contendo 7200 linhas de entrada, sendo cinco variáveis um total de 36000 dados, tal quantidade equivaleu a um universo de 5 dias, uma quantidade de dados significativamente relevante para aplicação do estudo.

Inicialmente para previsão de UCP, foi analisado o comportamento dos resultados do modelo com os passos à frente, foi realizada a análise do Erro Médio Absoluto (**MAE**), Erro Médio Quadrático (**RMSE**), Erro Médio Percentual (**MAPE**), Desvio Padrão, representado na equação 5.7 e Correlação Linear do modelo representado pela equação 5.8.

$$DP = \sqrt{\frac{\sum_{i=1}^n (x_i - MA)^2}{n}} \quad (5.7)$$

Onde:

DP = Desvio Padrão.

x_i : valor na posição i no conjunto de dados

MA: média aritmética dos dados

n : quantidade de dados

$$r_{xy} = \frac{Cov(X, Y)}{S_x S_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (5.8)$$

Onde:

r_{xy} é a Correlação dos elementos x e y .

A seguir na tabela 5.3 são apresentados os resultados dos Erros para ultra curto prazo para 5 minutos, 10 minutos e 20 minutos para os modelos SARIMA, SARIMA+WAVELET, Redes Neurais, SARIMA+RN1 e o modelo híbrido proposto. Para este horizonte foi utilizado o modelo SARIMA+WAVELET, para fins de estudo da aplicabilidade do modelo.

O modelo SARIMA já mostrou um bom resultado em todos os passos, o Erro Médio Absoluto (MAE) para 5 passos (minutos) é de 0,795 o qual obteve um aumento de 0,337 para 10 passos (minutos), ficando com erro de 1,132 obtendo ainda um erro de 1,182 para 10 passos (minutos).

Ainda para o modelo SARIMA o erro Médio Percentual (MAPE) para 5 passos (minutos), foi de 15,024% de erro, uma média boa em relação a outros trabalhos, obtendo ainda um crescimento de 2,583% no horizonte de 10 passos (minutos), e 5,567% para o horizonte de 20 passos (minutos), ficando com 20,591% de Erro Médio Percentual. A correlação para 5 passos de 0,663 foi considerada moderada de acordo com o coeficiente de correlação de Pearson, a qual mantem-se na mesma classificação em 10 passos, onde apresenta coeficiente de 0,647 e 20 passos, com coeficiente de correlação de 0,624.

Tabela 5.3: Resultados dos Erros para Previsão Multipassos Ultra Curto Prazo (Minutos).

Modelo		SARIMA	SARIMA + WAVELET	REDES NEURAIAS	SARIMA+ RN1	Modelo híbrido proposto
Previsão 5 minutos	VMED	5,290	5,556	5,290	5,555	5,456
	MAE	0,795	0,790	0,377	0,265	0,153
	RMSE	1,777	1,766	0,889	0,592	0,342
	MAPE (%)	15,024	14,290	7,412	4,769	2,806
	Desvio padrão	1,587	1,609	0,422	0,083	0,078
	Correlação	0,663	0,637	0,915	0,959	0,980
Previsão 10 minutos	VMED	6,428	5,946	6,428	6,317	6,326
	MAE	1,132	1,010	0,566	0,377	0,249
	RMSE	3,579	3,194	1,790	1,193	0,797
	MAPE (%)	17,607	16,986	8,804	5,972	3,969
	Desvio padrão	1,615	1,637	0,426	0,085	0,080
	Correlação	0,647	0,622	0,905	0,939	0,960
Previsão 20 minutos	VMED	5,739	6,016	5,689	5,843	5,769
	MAE	1,182	1,089	0,616	0,411	0,286
	RMSE	5,285	4,870	2,754	1,836	1,281
	MAPE (%)	20,591	18,102	10,825	7,027	4,987
	Desvio padrão	1,656	1,665	0,433	0,086	0,082
	Correlação	0,624	0,608	0,886	0,929	0,954

Fonte: O Autor

O modelo SARIMA+Wavelet mostrou uma melhora sutil, porém significativa, que comprovou a teoria da literatura que descreve melhora em relação ao modelo SARIMA.

Houve uma melhora de 0,734% no Erro Médio Quadrático, que ficou com 14,290% de erro no horizonte de 5 passos. O Erro Médio Quadrático ficou em 1,766. No horizonte de 10 passos, a melhoria no Erro Médio Percentual foi de 0,621%, onde ficou com 16,986%. Comparando o horizonte de 5 e 20 passos, o modelo SARIMA+Wavelet teve um aumento de 3,812% de Erro Médio Percentual.

Para os resultados referentes ao modelo Redes Neurais em relação ao SARIMA, considerando o erro máximo obtido no modelo SARIMA, foi obtida uma melhora média, em termos de Erro Médio Absoluto de 52,57%, onde ficou com 0,377. O desvio padrão ficou 0,422 um resultado 76,65% melhor que o resultado do modelo SARIMA. A correlação linear ficou em 0,915 o que caracterizou uma correlação muito forte.

Com relação ao horizonte de previsão, para o modelo redes neurais o erro médio percentual teve uma queda de rendimento de 1,29%, passando para 8,804% de Erro Médio Percentual do horizonte de 5 para 10 passos, e 3,31% de perda de 5 para 20 passos, ficando com 10,825% de Erro Médio Percentual.

O modelo SARIMA+RN1 nesta tese foi considerado um modelo intermediário, o qual faz parte da composição do modelo híbrido proposto, os resultados obtidos com esse modelo foram excelentes, resultado superior ao modelo de Redes Neurais.

Considerando o erro máximo obtido pelo modelo SARIMA, o resultado do Erro Médio Absoluto (MAE) para o horizonte de 5 passos obtido foi de 0,265 o que correspondeu a uma evolução de 66,65% na melhora dos resultados.

O Erro Médio Quadrático (RMSE) para 5 passos obteve melhora proporcional, acompanhando a melhoria para 0,592. O Erro Médio Percentual obtido para 5 passos obtido foi de 4,77% o que corresponde a melhora de 68,25% com relação ao modelo SARIMA.

O desvio padrão para 5 passos melhorou 94,77% resultando em 0,083. A correlação linear obtida para 5 passos foi de 0,959 índice considerado muito forte na escala de Pearson. Aos resultados para os horizontes de previsão para 10 passos, houve uma perda, já que o Erro Médio Absoluto (MAE) obteve um aumento de 0,112 pontos o que resultou 0,377 de erro e, para 20 passos, o MAE foi de 0,411.

O Erro Médio Percentual (MAPE) teve aumento de 1,21% em relação ao horizonte de 5 passos, o que resultou em um MAPE de 5,972% de erro. Para 20 passos, o MAPE obtido foi de 7,027%. O desvio padrão no horizonte de 10 passos aumentou para 0,085 e para 20 passos aumentou para 0,086. A correlação aumentou para 0,939 para 10 passos e 0,929 para 20 passos, mesmo com o aumento dos passos, a correlação manteve-se muito forte de acordo com a escala de Pearson.

O modelo híbrido proposto é composto de SARIMA+RN1+RN2, obteve resultados excelentes, o Erro Médio Absoluto (MAE) no horizonte de 5 passos foi 0,153 e para 20 passos mesmo com perdas, obteve um resultado de 0,286 valor ainda considerado muito bom, o Erro Médio Percentual (MAPE) para 5 passos obteve resultado de 2,806%, com uma confiança de 97,194% e para 20 passos erro de 4,987%, com uma garantia de 95,013% de confiança mesmo no passo de maior horizonte previsto.

A correlação para esse modelo em todos os horizontes previstos foi considerada muito forte, mesmo no maior horizonte de previsão, mostrando que o modelo proposto foi superior aos demais modelos.

Os resultados multipassos à frente mostraram que os modelos previstos seguiram a conformidade da literatura, a qual trata sobre a perda de precisão relativa ao passo de previsão, quanto maior o passo de previsão, menor é a precisão do modelo.

Mesmo o modelo SARIMA+Wavelet tendo uma melhora sutil com a aplicação do modelo, a utilização do modelo SARIMA + Redes Neurais e até mesmo somente o modelo de Redes Neurais obteve um resultado muito superior.

Para todos os horizontes, o modelo híbrido proposto obteve os melhores resultados quando comparado com os demais modelos, mesmo para o horizonte de 20 passos, os resultados foram satisfatórios e mostram a eficiência e efetividade do modelo.

5.4.1.1 Velocidade prevista a ultra curto prazo – UCP (minutos)

A figura 5.6 mostra os resultados dos valores da velocidade em m/s prevista para ultra curto prazo em minutos. Na mesma pode-se apreciar que não houve grande diferença entre o modelo SARIMA e o modelo SARIMA + *Wavelets*, e o último não será incluído na previsão de potência e de energia.

Os valores reais consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir do minuto 00 do dia 01 de junho de 2017 estendendo-se até o minuto 20 da mesma data, uma previsão de 20 passo (minutos) para frente.




Figura 5.6: Velocidade prevista ultra curto prazo minutos em m/s.
Fonte: O Autor

As curvas apresentadas na Figura 5.6 mostram os resultados para cada modelo, os resultados do SARIMA e SARIMA + *Wavelets* tenderam para média prevista. As curvas que usaram modelos com rede neural, baseados em características não lineares, apresentaram melhor desempenho, destacando-se o Modelo Híbrido Proposto (SARIMA+RN1+RN2) como o melhor, visto que segue muito bem a curva da velocidade real.

A seguir são representados os valores de geração prevista para esta previsão.

5.4.1.2 Potência prevista a ultra curto prazo – UCP (minutos)

A figura 5.7 mostra a potência gerada prevista para ultra curto prazo em minutos, com os resultados sendo dados em kW.

A previsão da geração foi realizada a partir do minuto 00 do dia 01 de junho de 2017 estendendo-se até o minuto 20 da mesma data, uma previsão de 20 passos (minutos) para frente.

A previsão para este horizonte levou em consideração um intervalo de tempo ultra curto, o que faz a variação da velocidade algumas mudanças bruscas, do intervalo de 5 minutos para 7 minutos houve um aumento de aproximadamente 15 kW para previsão do modelo híbrido proposto, e uma queda de aproximadamente 20kW do intervalo de 9 minutos para 11 minutos,

após esses picos, a previsão tendeu para uma média de aproximadamente 10 kW e do modelo SARIMA tendeu para 12kW, houve picos na previsão de até 26 kW.

A previsão de geração de potência para este horizonte é importante para compensação do mercado de eletricidade, operações de rede em tempo real e ações de regulação.

As curvas apresentadas na Figura 5.7 mostram os resultados para cada modelo, igual que no caso anterior, os resultados do SARIMA e SARIMA + *Wavelets* tendem para média prevista. As curvas que usam modelos com rede neural, baseados em características não lineares, apresentaram melhor desempenho, destacando-se o Modelo Híbrido Proposto (SARIMA+RN1+RN2) como o melhor, visto que segue muito bem a curva da potência real.




Figura 5.7: Potência gerada prevista ultra curto prazo minutos kW.

Fonte: O Autor

Para as apresentações dos próximos horizontes não foram mostrados os modelos SARIMA+*Wavelet* pois os mesmos obtiveram resultados muito próximo aos do modelo SARIMA, e o modelo intermediário SARIMA+RN1 não teve aqui apresentado seus resultados, pois o mesmo fez parte da composição do modelo híbrido proposto.

5.4.2 Previsão à Curto Prazo - CP (horas)

Foi realizada na previsão de curto prazo que abrange a grandeza de tempo em horas. Os dados utilizados para este horizonte, tiveram uma base de dados contendo 8760 linhas, foram os dados de horas durante um ano, sendo cinco variáveis utilizadas, compreendendo um total de 43800 dados, que equivaleram à um universo de 1 ano.

Na tabela 5.4 são apresentados os resultados dos erros para curto prazo em 5 horas, 10 horas e 20 horas para os modelos SARIMA, Redes Neurais e modelo híbrido proposto.

Os resultados da velocidade média – VMED para os diversos passos de previsão foram muito próximos devido ao comportamento do vento que embora tenha variação ao longo do dia, a média leva em consideração todos os valores anteriores.

Para exemplificar, a velocidade para 5 passos ou 5 horas no modelo SARIMA é de 7,562 m/s. Essa média é a somatória dos valores dividido pela quantidade de amostras, na previsão de 20 passos ou horas a velocidade média foi de 7,306, embora a velocidade apresente valores muito próximos.

O modelo SARIMA tem uma característica que acompanha a evolução da média móvel dos dados, mesmo com essa característica do comportamento da velocidade média e da característica do modelo, o Erro Médio Percentual (MAPE) obtido para 5 horas de previsão foi de 9,543% de erro um valor considerado bom para previsão neste modelo, tendo ainda uma perda suave de precisão, onde o erro para 20 passos foi de 10,325% de erro, quanto maior o horizonte de previsão, maior o erro do MAPE.

Tabela 5.4: Resultados dos Erros para Previsão Multipassos Curto Prazo (Horas).

Modelo		SARIMA	REDES NEURAIIS	Modelo híbrido proposto
Previsão 5 Horas	VMED	7,562	7,562	7,583
	MAE	0,722	0,381	0,139
	RMSE	1,614	0,817	0,310
	MAPE (%)	9,543	4,772	1,833
Previsão 10 Horas	VMED	7,489	7,489	7,436
	MAE	0,748	0,324	0,165
	RMSE	2,366	1,483	0,526
	MAPE (%)	9,989	4,994	2,231
Previsão 20 Horas	VMED	7,306	7,256	7,291
	MAE	0,754	0,427	0,176
	RMSE	3,374	1,787	0,784
	MAPE (%)	10,325	5,198	2,417

Fonte: O Autor

O Erro Médio Absoluto (MAE) para 5 horas de previsão do modelo SARIMA, foi de 0,722 e para o modelo de redes neurais, foi de 0,381 uma melhora relativa ao modelo anterior de 47,22%, e o modelo híbrido proposto obteve uma resposta de erro MAE 0,139. Se comparado ao modelo SARIMA, houve uma evolução na melhora da resposta de 80,75% um resultado excelente.

Os resultados para 10 e 20 passos obtiveram uma resposta equivalente e muito próxima a essa evolução de melhoria.

Neste horizonte de previsão para curto prazo (horas) multipassos a frente mostraram que os resultados de erro do modelo híbrido proposto tanto para o Erro Médio Absoluto, Erro Médio Quadrático, quanto para o Erro Médio Percentual, obteve um resultado muito superior aos demais modelos.

5.4.2.1 Velocidade prevista a curto prazo - CP (horas)

A figura 5.8 mostra os resultados dos valores da velocidade em m/s prevista para curto prazo em horas.

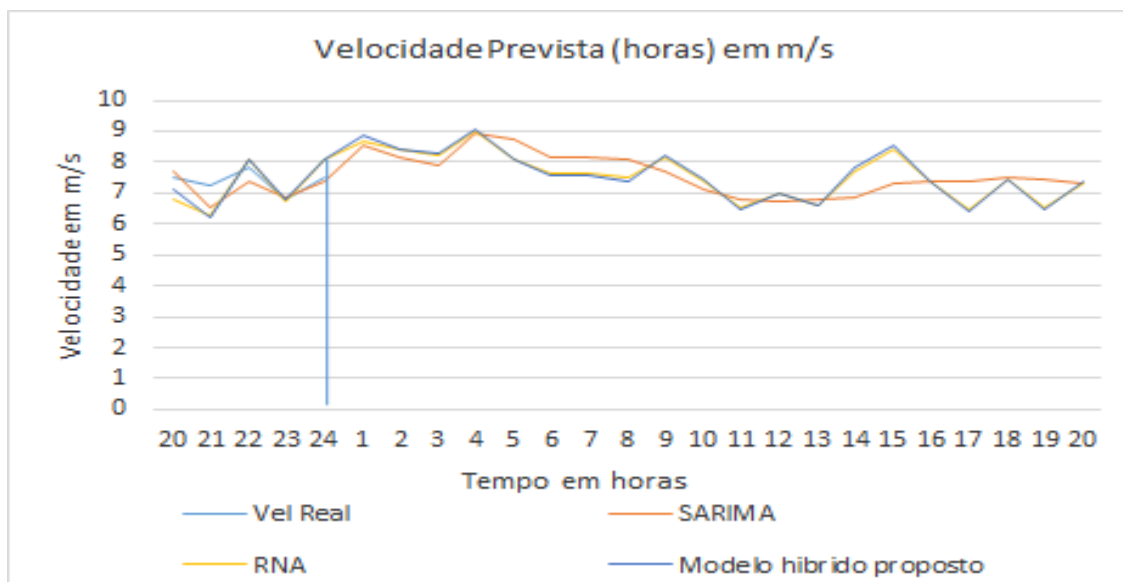


Figura 5.8: Velocidade prevista curto prazo horas em m/s.

Fonte: O Autor

Da Figura 5.8, pode-se apreciar que o comportamento do modelo SARIMA tendeu para uma média dos resultados, enquanto os modelos com Redes neurais mostraram um comportamento próximo à variação real. Dentre os dois modelos que usaram redes neurais, o Modelo Híbrido Proposto apresentou melhores resultados.

Os valores reais consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir da hora 01 do dia 01 de junho de 2017 estendendo-se até 20 horas da mesma data, uma previsão de 20 passo (horas) para frente.

A seguir são representados os valores de geração prevista para esta previsão.

5.4.2.2 Potência prevista a curto prazo - CP (horas)

A figura 5.9 mostra a potência gerada prevista para curto prazo Horas. Os resultados são dados em dados em kW.




Figura 5.9: Potência gerada prevista Curto Prazo horas em kW
Fonte: O Autor

Os Valores mostrados na figura acima são os valores reais calculado são até o dia 31 de maio de 2017, a previsão da geração foi realizada a partir da hora 01 do dia 01 de junho de 2017 estendendo-se até a hora 20 da mesma data, uma previsão de 20 passos (horas) para frente.

A potência gerada prevista varia conforme a velocidade do vento prevista. Para o gerador selecionado pode-se gerar uma potência de até 40 kW, essa potência pode aumentar levando-se em consideração a velocidade e também adotando um gerador eólico de mais capacidade de geração de potência.

A variação do comportamento da previsão da geração de potência mostrou-se mais suave que a ultra curta previsão, porém ainda houve uma variação de aproximadamente 15 kW do intervalo de 8 horas para 10 horas e uma queda na mesma proporção no intervalo das 10 horas para 12 horas.

Esse horizonte de previsão é importante para o planejamento do despacho econômico de carga, decisões razoáveis de carga e segurança operacional no mercado da eletricidade.

5.4.3 Previsão a Médio Prazo - MP (dias)

A terceira previsão realizada foi realizada no horizonte de curto prazo que abrange a grandeza de tempo em Dias.

Os dados utilizados para o presente horizonte, teve uma base contendo 4745 linhas de dados por variável, sendo 5 variáveis em um total de 23725 dados, estes dados equivaleram à um universo de 13 ano.

Na tabela 5.5 são apresentados os resultados dos erros para médio prazo para 5 dias, 10 dias e 20 dias para os modelos SARIMA, Redes Neurais e modelo híbrido proposto.

Tabela 5.5: Resultados dos Erros para Previsão Multipassos Médio Prazo (Dias).

Modelo		SARIMA	REDES NEURAIS	Modelo híbrido proposto
Previsão 5 Dias	VMED	7,054	7,254	7,279
	MAE	0,923	0,362	0,139
	RMSE	2,065	0,809	0,311
	MAPE (%)	13,091	4,987	1,914
Previsão 10 Dias	VMED	7,223	7,323	7,341
	MAE	1,135	0,518	0,228
	RMSE	3,590	1,637	0,729
	MAPE (%)	15,718	7,069	3,128
Previsão 20 Dias	VMED	7,674	8,324	8,065
	MAE	1,640	0,735	0,342
	RMSE	7,333	3,289	1,530
	MAPE (%)	21,366	8,835	4,260

Fonte: O Autor

O resultado da previsão de médio prazo em dias mostrou a evolução de melhora nos resultados dos modelos no Erro Médio Absoluto (MAE), para o horizonte de 5 passos, o qual obteve 0,923 no modelo SARIMA, e 0,362 para o modelo redes neurais, onde já houve uma melhora de 60,78% na comparação dos dois modelos. O modelo híbrido proposto obteve 0,139 de Erro Médio Absoluto, o que corresponde a uma melhora de 84,94% em relação ao primeiro modelo.

Os resultados mostraram que mesmo a maior previsão de 20 horas para o modelo híbrido proposto é superior a menor previsão tanto do SARIMA quanto Redes neurais, mostrando a eficiência do modelo proposto.

5.4.3.1 Velocidade Prevista a Médio Prazo – MP (dias)

A figura 5.10 mostra os resultados do valores da velocidade em m/s prevista para médio prazo em dias.




Figura 5.10: Velocidade prevista médio prazo dias em m/s.

Fonte: O Autor

Os valores reais consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir do dia 01 de junho de 2017 estendendo-se até o dia 20 de junho de 2017 com 20 passo (Dias) para frente.

Da Figura 5.10 se pode apreciar que as curvas que usaram modelos com rede neural, baseados em características não lineares, apresentaram melhor desempenho, destacando-se o modelo híbrido proposto (SARIMA+RN1+RN2) como o melhor, visto que segue muito bem a curva da velocidade real.

A seguir são representados os valores de geração prevista para esta previsão.

5.4.3.2 Potência Prevista a médio prazo – MP (dias)

A figura 5.11 mostra a potência gerada prevista para médio prazo. Os resultados são dados em dados em KW.




Figura 5.11: Potência Gerada Prevista Médio Prazo Dias em kW.
Fonte: O autor

Os valores reais calculados consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir do dia 01 de junho de 2017 estendendo-se até o dia 20 de junho de 2017 com 20 passo (Dias) para frente.

A variação da capacidade de geração do horizonte dias foi maior em relação ao horizonte de horas, isso foi devido ao comportamento dos ventos, que mesmo não sendo parte da análise deste trabalho, mas merece uma observação, pois o vento repete seu comportamento durante o ciclo de um dia, um mês e um ano, em escalas proporcionais.

É possível perceber que houveram picos de geração de mais de 50kW, valor próximo de 60% da capacidade máxima do aerogerador, esse valor de geração pode aumentar se for adotado outro gerador eólico de maior capacidade.

O horizonte de previsão a médio prazo é importante para decisões de compromisso das unidades, decisões de compromisso de reserva e Gerador on-line / off-line decisões.

5.4.4 Previsão a Médio Prazo - MP (semanas)

O quarto horizonte de previsão foi realizada a médio prazo que abrange a grandeza de tempo em Semanas.

Os dados utilizados considerou uma base contendo 676 linhas equivalentes a quantidade de cada variável, sendo utilizadas cinco variáveis, um total de 3380 dados, tal quantidade equivale à um universo de 13 anos.

A seguir na tabela 5.6 são apresentados os resultados dos Erros para médio prazo para 5 semanas, 10 semanas e 20 semanas para os modelos SARIMA, Redes Neurais e o modelo híbrido proposto.

Tabela 5.6: Resultados dos Erros para Previsão Multipassos Médio Prazo (Semanas).

Modelo		SARIMA	REDES NEURALS	Modelo híbrido proposto
Previsão 5 Semanas	VMED	7,112	7,112	7,360
	MAE	1,169	0,585	0,225
	RMSE	2,615	1,307	0,504
	MAPE (%)	16,443	8,221	3,060
Previsão 10 Semanas	VMED	6,686	6,686	7,064
	MAE	1,595	0,798	0,351
	RMSE	5,045	2,523	1,122
	MAPE (%)	23,862	11,931	5,011
Previsão 20 Semanas	VMED	6,598	6,748	7,088
	MAE	1,683	0,827	0,384
	RMSE	7,528	3,697	1,719
	MAPE (%)	25,514	12,250	5,448

Fonte: O Autor.

A previsão multipassos para este horizonte, obteve uma perda de precisão em relação à previsão de horizonte de médio prazo (dias), o erro médio percentual (MAPE) do modelo SARIMA para cinco passos de previsão obteve um acréscimo de 3,35% em relação ao horizonte de previsão de médio prazo em dias.

O modelo redes neurais para o mesmo passo obteve uma perda de 3,23% de confiabilidade na comparação dos modelos, e o modelo híbrido proposto obteve perda de 1,15%

de precisão, se comparado ao horizonte anterior. As variações dos erros refletem também nos MAE e RMSE, essas variações são relativas ao comportamento estatístico dos dados.

Os modelos mostraram resultados diferentes para cada horizonte, e para bases de dados distintas.

5.4.4.1 Velocidade Prevista a Médio Prazo – (semanas)

A figura 5.12 mostra os resultados dos valores da velocidade em m/s prevista para médio prazo em semanas.




Figura 5.12: Velocidade prevista médio prazo semanas em m/s.
Fonte: O Autor.

Os valores reais consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir do dia 01 de junho de 2017 estendendo-se por 20 semanas, o que corresponde a data de 12 de outubro de 2017, um horizonte de 20 passo (semanas) para frente.

Da Figura 5.12 se pode apreciar que igual ao caso de curto passo que as curvas que usaram modelos com rede neural, baseados em características não lineares, apresentaram melhor desempenho, destacando-se o modelo híbrido proposto (SARIMA+RN1+RN2) como o melhor, visto que seguiram muito bem a curva da velocidade real.

5.4.4.2 Potência Prevista a Médio Prazo - MP (semanas)

A figura 5.13 mostra a potência gerada prevista para médio prazo semanas os resultados são dados em dados em KW.

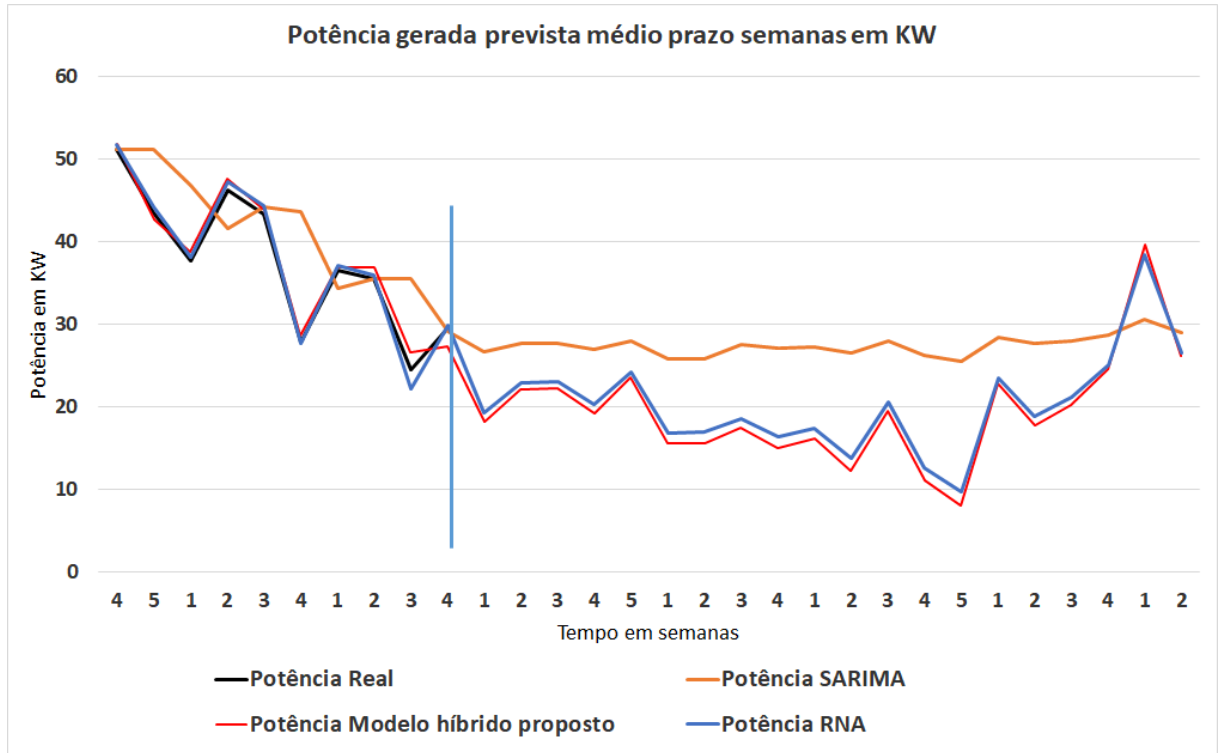


Figura 5.13: Potência Gerada Prevista médio Prazo em semanas em kW.
Fonte: O Autor.

Os valores reais calculados consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir do dia 01 de junho de 2017 estendendo-se 20 semanas para frente.

Comparando os resultados de geração com os outros horizontes foi possível perceber que o comportamento varia de acordo com o comportamento dos ventos, mesmo tendo resultados abaixo de 10kW, a previsão de geração de potência manteve-se em uma média próximo a 20kW e com picos de 40kW previstos.

Estes valores podem ser maior com a variação do vento ou adotando gerador eólico de maior capacidade de geração.

O horizonte de previsão a médio prazo para semanas também é importante para decisões de compromisso das unidades, decisões de compromisso de reserva e Gerador on-line / off-line decisões.

5.4.5 Previsão a Longo Prazo - LP (meses)

O quinto horizonte de previsão foi realizado a longo prazo, foi utilizado a grandeza de tempo em Meses.

Os dados utilizados teve uma base contendo 156 linhas, das cinco variáveis um total de 780 dados, tal quantidade equivaleu à um universo de 13 Anos.

A tabela 5.7 apresenta os resultados dos Erros para longo prazo para 5 meses, 10 meses e 20 meses para os modelos SARIMA, Redes Neurais e o modelo híbrido proposto.

Tabela 5.7: Resultados dos Erros para Previsão Multipassos Longo Prazo (Meses).

Modelo		SARIMA	REDES NEURAIAS	Modelo híbrido proposto
Previsão 5 Meses	VMED	9,202	9,202	8,939
	MAE	0,838	0,519	0,207
	RMSE	1,853	0,989	0,383
	MAPE (%)	9,104	4,652	1,813
Previsão 10 Meses	VMED	9,271	9,271	8,944
	MAE	1,202	0,681	0,282
	RMSE	3,800	1,990	0,819
	MAPE (%)	12,963	6,521	2,981
Previsão 20 Meses	VMED	9,387	9,387	9,044
	MAE	1,455	0,567	0,305
	RMSE	6,506	2,937	1,458
	MAPE (%)	15,498	6,996	3,392

Fonte: O Autor.

Na previsão multipassos de longo prazo em meses, obteve um resultado superior todos os resultados de previsão das grandezas apresentadas de minutos, horas, dias e semanas.

A previsão de longo prazo em meses, se comparado a previsão médio prazo semanas, para o horizonte de cinco passos obteve melhora de 7,34% no modelo SARIMA, 3,57% no modelo Redes Neurais, e 1,25% de melhora no modelo híbrido proposto.

5.4.5.1 Velocidade Prevista a Longo Prazo - LP (meses)

A figura 5.14 mostra os resultados dos valores da velocidade em m/s prevista para Longo Prazo em Meses.




Figura 5.14: Velocidade prevista longo prazo meses em m/s.
Fonte: O Autor.

Os valores reais consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir do dia 01 de junho de 2017 estendendo-se por 20 meses, abrangendo até o mês de janeiro de 2019, um horizonte de 20 passos (meses) para frente.

A seguir são representados os valores de geração prevista para esta previsão.

5.4.5.2 Potência Prevista a Longo Prazo – LP (meses)

A figura 5.15 mostra a potência gerada prevista para longo prazo meses os resultados são dados em dados em kW.




Figura 5.15: Potência Gerada Prevista longo Prazo em meses em kW.
Fonte: O Autor.

Os valores reais calculados consideraram até o dia 31 de maio de 2017, a previsão foi realizada a partir do dia 01 de junho de 2017 estendendo-se 20 meses para frente.

Neste horizonte a amplitude de previsão dos dados da potência gerada foi maior, devido ao comportamento do vento o qual varia o ciclo completo, nos meses de abril, maio e junho obtiveram picos de mais de 60kW de potência prevista, quase 70% da capacidade total do gerador eólico, se o gerador for substituído por um de maior capacidade, a geração de potência também será maior.

O horizonte de previsão de longo prazo é importante para planejamento da manutenção, gestão da operação, custo de funcionamento ótimo e estudo de viabilidade para projetos de parques eólico.

5.4.6 Previsão a Longo Prazo - LP (anos)

O sexto horizonte de previsão foi realizado a longo prazo, foi utilizado a grandeza de tempo em Anos.

Para o horizonte de longo prazo de grandeza em anos, devido a base de dados dispor de apenas 13 linhas o qual é considerado insuficiente para realizar uma previsão com os modelos e técnicas propostas, foi utilizado a base de meses a qual contém 156 linhas, um total de 780 dados, tal quantidade equivale à um universo de 13 anos.

Após a aplicação dos modelos foi feito a interpolação dos dados transformando os resultados de meses para anos, e para comparação dos resultados também foi utilizado a extrapolação através da média móvel dos dados em anos para possibilitar a realização dos testes comparativos.

A tabela 5.8 apresenta os resultados dos Erros para longo prazo para 5 Anos para os modelos SARIMA, Redes Neurais e Modelo híbrido proposto.

Para este horizonte só foi possível fazer previsão para 5 passos (Anos) devido a base de dados limitada 13 anos.

Tabela 5.8: Resultados dos Erros para Previsão Multipassos Longo Prazo (Anos).

Modelo		SARIMA	REDES NEURAI	Modelo híbrido proposto
Previsão 5 Anos	VMED	8,802	7,874	8,166
	MAE	1,226	0,421	0,170
	RMSE	2,741	0,941	0,380
	MAPE (%)	13,927	6,378	2,083

Fonte: O Autor.

Os resultados obtidos, exporam uma melhora média de 85,77% comparando o modelo híbrido proposto com o modelo SARIMA. Os resultados para o horizonte de longo prazo anos obteve um ótimo desempenho mesmo tendo uma base de dados muito pequena, o resultado foi possível pela utilização das técnicas estatísticas e matemáticas de extrapolação e interpolação e devido a constância dos modelos aplicados.

5.4.6.1 Velocidade Prevista a Longo Prazo – LP (anos)

A figura 5.16 mostra os resultados dos valores da velocidade em m/s prevista para Longo Prazo em Anos.




Figura 5.16: Velocidade prevista longo prazo anos em m/s
Fonte: O Autor

Os valores reais consideraram até o dia 31 de dezembro de 2016, a previsão foi realizada a partir do dia 01 de janeiro de 2017 estendendo-se por 5 anos, abrangendo até o ano de 2021, um horizonte de 20 passo (anos) para frente.

A velocidade anual teve uma variação menor que as velocidades dos outros horizontes, pois o vento teve uma variação de acordo com as estações do ano.

A seguir são representados os valores de geração prevista para esta previsão.

5.4.6.2 Potência prevista a longo prazo - LP (anos)

A figura 5.17 mostra a potência gerada prevista para longo prazo anos os resultados são dados em dados em kW.




Figura 5.17: Potência Gerada Prevista médio Prazo em anos em kW.
Fonte: O Autor.

Os valores reais calculados consideraram até o dia 31 de dezembro de 2016, a previsão foi realizada a partir do dia 01 de janeiro de 2017 estendendo-se 5 anos para frente.

Este horizonte de previsão estendeu-se por 5 passos ou 5 anos, uma previsão menor que os horizontes anteriores devido a quantidade de dados históricos, porém é possível perceber que a amplitude de previsão de geração foi maior, devido ao comportamento do vento o qual varia o ciclo completo, nos meses de abril, maio e junho obtiveram picos de mais de 60kW de potência prevista, quase 70% da capacidade total do gerador eólico, se o gerador for substituído por um de maior capacidade, a geração de potência também será maior.

O horizonte de previsão de longo prazo para passos em anos, é importante para planejamento da manutenção, gestão da operação, custo de funcionamento ótimo e estudo de viabilidade para projetos de parques eólico.

5.4.6.3 Energia Média Anual Prevista a Longo Prazo - LP (anos)

A figura 5.18 mostra a previsão da energia média anual prevista para horizonte de longo prazo (anos), os resultados são dados em dados em kWh.




Figura 5.18: Energia média anual Prevista Longo Prazo em anos em kWh.
Fonte: O Autor.

A previsão da energia para o horizonte mostrou um pico de aproximadamente 365000 kWh para o modelo ARIMA e 362000 kWh para o modelo híbrido proposto (SARIMA+RN1+RN2), a amplitude da previsão não foi muito grande, não tendo variações muito bruscas de previsão.

5.4.7 Comportamento do modelo em diferentes estações do ano.

Uma das características da base de dados utilizada nesta pesquisa é que diferente da maioria das outras bases, a divisão das estações do ano é considerada como sendo apenas duas, o verão que abrange o primeiro semestre do ano e o inverno que abrange o segundo semestre do ano.

Na tabela 5.9 se oferece uma comparação da velocidade média do vento e dos erros obtidos na velocidade do vento pelos diferentes modelos para as duas estações do ano e para os diferentes cenários de previsão. A tabela 5.9, mostra que os resultados encontrados no teste de

previsão teve uma diferença significativa para o valor da velocidade média nas diferentes estações do ano, sendo elas muito maiores em inverno que no verão. Pode-se observar também que não existiu uma diferença significativa para os diferentes valores dos erros, sendo ligeiramente superiores na época de inverno. Foi usada a previsão em horas porque é o passo que menos erros induz na previsão.

Tabela 5.9: Resultados dos Erros para previsão nas diferentes estações do ano.

Modelo		Verão (jan à Jun)			Inverno (Jul à dez)		
		SARIMA	REDES NEURAIS	Modelo híbrido proposto	SARIMA	REDES NEURAIS	Modelo híbrido proposto
Previsão 5 Horas	VMED	7,562	7,562	7,588	9,14	9,16	9,277
	MAE	0,722	0,381	0,139	0,731	0,384	0,142
	RMSE	1,614	0,817	0,311	1,638	0,922	0,395
	MAPE (%)	9,543	4,772	1,834	10,322	4,927	1,943
Previsão 10 Horas	VMED	7,489	7,489	7,438	9,14	9,17	9,23
	MAE	0,748	0,324	0,166	0,751	0,389	0,17
	RMSE	2,366	1,483	0,526	2,589	1,684	0,635
	MAPE (%)	9,989	4,994	2,237	11,956	5,971	2,645
Previsão 20 Horas	VMED	7,306	7,256	7,324	8,931	8,931	9,12
	MAE	0,754	0,427	0,178	0,759	0,411	0,184
	RMSE	3,374	1,787	0,797	4,102	1,893	0,843
	MAPE (%)	10,325	5,198	2,434	12,435	7,336	3,976

Fonte: O Autor.

5.4.8 Comportamento do modelo sem considerar a temperatura e a pressão.

Para esse teste, foi realizado a exclusão das variáveis temperatura e pressão, foi aplicado o modelo com 5 variáveis e 3 variáveis (sem considerar a temperatura e a pressão) e feito a comparação dos resultados. Na tabela 5.10 mostram-se estes resultados. Neste caso não houve separação das estações de verão e inverno.

Os resultados obtidos mostraram que com a exclusão das variáveis temperatura e pressão, não houve melhora no modelo, e nem houve aumento de tempo na iteração do modelo, conforme (MA *et al.*, 2018), a eliminação das variáveis que têm relações mais fracas, porém não cita sobre melhora do modelo, quanto menor a quantidade de variáveis, menor é a complexidade do modelo, porém essa afirmativa vem sendo desconsiderada devido a evolução da configuração dos computadores que tem maior capacidade de processamento de informações. Não houve diferença significativa no tempo de processamento dos resultados.

A aplicação do modelo eliminando as variáveis temperatura e pressão, não melhoraram e nem aumentaram o tempo de iteração dos resultados de forma significativa.

Tabela 5.10: Resultados dos Erros para previsão da velocidade do vento com três e cinco variáveis.

Modelo		5 variáveis			3 variáveis		
		ARIMA	REDES NEURAIAS	Modelo híbrido proposto	ARIMA	REDES NEURAIAS	Modelo híbrido proposto
Previsão 5 Horas	VMED	7,562	7,562	7,588	7,562	7,562	7,588
	MAE	0,722	0,381	0,139	0,946	0,483	0,216
	RMSE	1,614	0,817	0,311	2,115	1,062	0,483
	MAPE (%)	9,543	4,772	1,834	12,993	6,497	2,891
Previsão 10 Horas	VMED	7,489	7,489	7,438	7,489	7,489	7,438
	MAE	0,748	0,324	0,166	1,172	0,561	0,283
	RMSE	2,366	1,483	0,526	3,706	2,003	0,894
	MAPE (%)	9,989	4,994	2,237	16,926	8,463	3,934
Previsão 20 Horas	VMED	7,306	7,256	7,324	7,306	7,256	7,324
	MAE	0,754	0,427	0,178	1,219	0,627	0,296
	RMSE	3,374	1,787	0,797	5,451	2,742	1,323
	MAPE (%)	10,325	5,198	2,434	17,920	8,724	4,115

Fonte: O Autor.

5.4.9 Comportamento dos modelos em diferentes bases de dados

Para esta aplicação, a série histórica das variáveis meteorológicas utilizadas foi obtida do Banco de dados meteorológicos para ensino e pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET), Estação MACAU / RN (OMM: 82594), Latitude (graus): -5,15 e Longitude (graus): -36,57, Altitude (metros): 32,00. Foram utilizadas as variáveis: Temperatura do ar, Umidade do ar, Pressão atmosférica, Velocidade média do vento, Direção do vento.

A base de dados disponibilizado pelo Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) pode ser acessado no URL <http://inmet.gov.br>. A escolha foi tomada baseada no atlas eólico do Brasil, e pela análise das velocidades médias apresentadas no banco de dados.

Foi considerado um intervalo de 6, 12, 18 e 24 horas, e mostrado os resultados para os modelos SARIMA, SARIMA + *Wavelet*, Redes Neurais e Modelo Híbrido Proposto (ver tabela 5.11).

Tabela 5.11: Resultados dos Erros entre diferentes bases de dados -Petrolina/PE e Macau/RN.

Modelo		Resultados dos Erros para Previsão Multipassos (Horas) - MACAU – RN				Resultados dos Erros para Previsão Multipassos (Horas) - PETROLINA – PE			
		SARIMA	SARIMA + WAVELET	REDES NEURAIIS	Modelo híbrido proposto	SARIMA	SARIMA + WAVELET	REDES NEURAIIS	Modelo híbrido proposto
Previsão 6 Horas	VMED	5,162	5,524	5,538	5,158	7,562	7,722	7,562	7,629
	MAE	1,122	1,032	0,576	0,202	0,733	0,674	0,387	0,141
	RMSE	5,836	5,428	2,811	1,74	1,638	1,474	0,829	0,316
	MAPE (%)	14,391	13,096	7,791	2,815	9,686	8,814	4,844	1,862
Previsão 12 Horas	VMED	5,140	5,232	5,33	5,253	7,489	7,643	7,489	7,458
	MAE	1,294	1,190	0,784	0,428	0,77	0,709	0,334	0,171
	RMSE	7,08	6,585	2,922	2,283	2,437	2,193	1,527	0,542
	MAPE (%)	17,744	16,147	9,769	4,445	10,289	9,363	5,144	2,304
Previsão 18 Horas	VMED	5,135	5,427	5,451	5,386	7,489	7,643	7,489	7,458
	MAE	1,399	1,287	0,854	0,400	0,789	0,725	0,387	0,181
	RMSE	8,613	8,01	4,439	3,146	3,014	2,712	1,707	0,695
	MAPE (%)	21,796	19,834	12,043	6,188	10,665	9,705	5,320	2,452
Previsão 24 Horas	VMED	5,130	5,622	5,572	5,518	7,306	7,384	7,256	7,335
	MAE	1,508	1,387	0,93	0,374	0,814	0,749	0,446	0,192
	RMSE	10,198	9,485	6,031	4,049	3,644	3,28	1,909	0,861
	MAPE (%)	25,987	23,648	14,451	8,023	11,151	10,147	5,551	2,629

Fonte: O Autor.

A aplicação dos modelos com as mesmas configurações na base de dados de Macau/RN, retornaram resultados muito bons, comparando o mesmo horizonte de previsão, foi possível verificar que os resultados da base de Petrolina formam melhores, isso comprova a teoria que diferentes bases de dados retornam resultados diferentes.

Para previsão de 6 horas de previsão no modelo SARIMA na base de dados Macau/RN, o Erro Médio Absoluto obteve um resultado de 1,122 para previsão de 12 horas, o MAE foi de 1,294, para 18 horas foi de 1,399 e para 24 horas, o MAE foi de 1,508 resultados muito bom, e mostrando que quanto maior o passo de previsão, maior é o erro obtido.

Ainda na base de dados de Macau/RN, os melhores resultados foram obtidos com o modelo híbrido proposto, onde o Erro Médio Absoluto no passo de 6 horas foi de 0,202 e o RMSE foi de 1,74 e Erro Médio Percentual – MAPE foi de 2,815% de erro, para o passo de 12 horas os erros obtidos para o MAE 0,435 e o Erro Médio Quadrático foi de 2,268 e o Erro Médio Percentual foi de 4,577% resultado esse que ainda é muito bom com uma confiança de 95,55% um valor muito bom se comparado com outros estudos e com a aplicação do mesmo modelo na base de Petrolina.

Para previsão com 24 passos os resultados foram inferiores aos com menor passo, porém ainda muito satisfatórios, o MAE obtido foi de 0,374 o RMSE para o modelo híbrido proposto foi de 4,049 e o MAPE foi de 8,023% resultados bastante relevantes para confirma que o modelo mesmo em diferentes bases de dados tem melhor resultados que os demais modelos testados.

5.4.9.1 Gráficos do comportamento dos modelos em diferentes bases de dados

São apresentados a seguir os gráficos de velocidade e potência prevista das bases de dados de Macau/RN e Petrolina/PE.




Figura 5.19: Velociade Prevista (horas) em m/s - Macau/RN.
Fonte: O Autor.

Os resultados de velocidade modelo SARIMA mostrou uma proximidade com o resultado SARIMA+ *Wavelet*, o que mostra que mesmo em bases diferentes os dois modelos têm comportamento similar.




Figura 5.20: Potência Prevista (horas) em KW - Macau/RN.
 Fonte: O Autor.

A potência prevista obteve um resultado menor que a da base de Petrolina, devido a velocidade do vento prevista.




Figura 5.21: Velocidade Prevista (horas) em m/s - Petrolina/PE.
 Fonte: O Autor.

O comportamento da velocidade prevista para o horizonte com passo de 6, 12, 18 e 24 horas, na base de Petrolina, obteve um resultado proporcionalmente equivalente aos resultados previsto para horizontes de 5, 10 e 20 horas para frente, isso mostra que os modelos podem ser aplicados em diversos outros horizontes de previsão.




Figura 5.22: Potência Prevista (horas) em kW - Petrolina/PE.
 Fonte: O Autor.

A figura 5.22, mostra a potência prevista em kW para base de Petrolina. Da Figura pode-se apreciar igual as curvas que usam modelos com Redes Neurais, baseados em características não lineares, apresentam melhor desempenho, destacando-se o modelo híbrido proposto (SARIMA+RN1+RN2) como o melhor, visto que segue muito bem a curva da velocidade real.

CAPÍTULO 6

6. CONCLUSÕES

Para fazer a previsão da velocidade do vento e da potência possível a ser gerada foram utilizados cinco modelos de previsão: SARIMA, SARIMA + *Wavelet*, Redes Neurais, SARIMA + Redes Neurais, Modelo Híbrido Proposto (SARIMA + Redes Neurais 1 + Redes Neurais 2).

Foram feitos os seis tipos de previsões conforme a literatura revisada, isto é: previsão a ultra curto prazo em minutos, previsão a curto prazo em horas, previsão a médio prazo em dias, previsão a médio prazo em semanas, previsão a longo prazo em meses, previsão a longo prazo em anos. Um total de trinta combinações de análises, onde foram apresentados dezoito dos melhores resultados de combinações.

Dos modelos usados, o modelo híbrido proposto foi o que apresentou os melhores resultados com os menores erros na previsão da velocidade do vento em todos os horizontes de previsão, como pode ser observado nas tabelas e nos gráficos apresentados neste trabalho.

Para a previsão para um passo à frente, a melhor resposta para o erro médio absoluto (MAE) foi obtida para o horizonte de horas com resultado de 0,139 de erro, e a pior resposta obtida foi para o horizonte de semanas com resposta de 0,225 de erro. A melhor resposta para o erro médio quadrático (RMSE) foi obtido para o horizonte de horas com 0,310 de erro, e a pior resposta obtida foi para o horizonte de semanas com resposta de 0,504 de erro.

Para as respostas do erro médio percentual (MAPE), a melhor resposta foi obtida para o horizonte de meses com 1,813% de erro, e pior resposta para o horizonte de semanas com 3,060% de erro.

Para previsão de 20 passos à frente, a melhor resposta para o erro médio absoluto (MAE) foi obtida para o horizonte de horas com resultado de 0,176 de erro, e a pior resposta obtida foi para o horizonte de semanas com resposta de 0,384 de erro. A melhor resposta para a raiz do erro médio quadrático (RMSE) foi obtido para o horizonte de horas com 0,784 de erro, e a pior resposta obtida foi para o horizonte de semanas com resposta de 1,719 de erro.

Para as respostas do erro médio percentual absoluto (MAPE), a melhor resposta foi obtida para o horizonte de horas com 2,417% de erro, e pior resposta para o horizonte de semanas com 5,448% de erro. As melhores respostas obtidas para 5, 10 e 20 passos foram para horas, enquanto os piores resultados para esses horizontes foram obtidos nas previsões de semanas.

A utilização do modelo híbrido mostrou-se mais eficiente pela consideração das características lineares e não lineares dos sinais modelados.

Quanto maior o passo de previsão menor é a garantia de resultado, porém o mercado necessita de respostas rápidas e a tendência desta característica de velocidade de resposta é crescente no cenário mundial. Um dos fatores que impactam nessa rápida resposta, além de um modelo eficiente para a necessidade da demanda, a base de dados tem crucial importância para resultados com ótima precisão.

Com a previsão da velocidade do vento é possível prever a geração eólica da região analisada, em função dos geradores que se deseja instalar. Estes resultados da previsão da velocidade do vento e por tanto do potencial de geração de energia eólica não tem precedentes na literatura, mais ainda com a combinação de modelos, o que sem dúvida constitui uma novidade.

O uso de *Wavelets* não melhora significativamente a previsão da velocidade do vento quando comparados com o modelo SARIMA; os resultados de previsão SARIMA + *Wavelets* estão muito perto das previsões SARIMA.

O modelo híbrido proposto mostrou-se eficiente nos diversos horizontes e nas diferentes bases de dados e que a aplicação do modelo proposto tem uma importância significativa para previsão da velocidade do vento e da potência.

6.1 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestão para trabalhos futuros tem-se a aplicação do modelo híbrido proposto para previsão da energia eólica utilizando outra base de dados do exterior, e a aplicação do modelo proposto para previsão da energia fotovoltaica.

REFERÊNCIAS

- ADEBIYI, A. A.; ADEWUMI, A. O.; AYO, C. K. Comparison of ARIMA and artificial neural networks models for stock price prediction. **Journal of Applied Mathematics**, v. 2014, 2014. ISSN 1110-757X.
- ADHIKARI, R.; AGRAWAL, R. An introductory study on time series modeling and forecasting. **arXiv preprint arXiv:1302.6613**, 2013.
- AMARANTE, O. A. C. B., M.; ZACK, J & SÁ, A.L.; A.L.: Atlas do Potencial Eólico Brasileiro. **Ministério de Minas e Energia**, Brasília, Brasil, 2001. Disponível em: <
http://www.cresesb.cepel.br/index.php?link=/atlas_eolico_brasil/atlas.htm >.
- ANVARI, M. et al. Short term fluctuations of wind and solar power systems. **New Journal of Physics**, v. 18, n. 6, p. 063027, 2016. ISSN 1367-2630.
- AZAD, H. B.; MEKHILEF, S.; GANAPATHY, V. G. Long-term wind speed forecasting and general pattern recognition using neural networks. **IEEE Transactions on Sustainable Energy**, v. 5, n. 2, p. 546-553, 2014. ISSN 1949-3029.
- BABU, C. N.; REDDY, B. E. A moving-average filter based hybrid ARIMA–ANN model for forecasting time series data. **Applied Soft Computing**, v. 23, p. 27-38, 2014. ISSN 1568-4946.
- BABY, C. M.; VERMA, K.; KUMAR, R. Short term wind speed forecasting and wind energy estimation: A case study of Rajasthan. **Computer, Communications and Electronics (Comptelix)**, 2017 International Conference on, 2017, IEEE. p.275-280.
- BARBOSA, V. Geração de energia eólica cresce 25% no Brasil em 2017. 2017. Disponível em: <
<https://exame.abril.com.br/economia/geracao-de-energia-eolica-cresce-25-no-brasil-em-2017/> >. Acesso em: 05/02/2018.
- BAROUDI, J. A.; DINAHAHI, V.; KNIGHT, A. M. A review of power converter topologies for wind generators. **Renewable energy**, v. 32, n. 14, p. 2369-2385, 2007. ISSN 0960-1481.
- BERNSTEIN, J. Wind Resource Analysis Program 2002. **Saint Paul, MN: Minnesota Department of Commerce**, 2002.
- BIGOVIĆ, M. Demand forecasting within Montenegrin tourism using Box-Jenkins methodology for seasonal ARIMA models. **Tourism and Hospitality Management**, v. 18, n. 1, p. 1-18, 2012. ISSN 1330-7533.
- BIZRAH, A.; AL-MUHAINI, M. The impact of seasonal ARMA wind speed modeling on the reliability of power distribution systems. **Power & Energy Society General Meeting**, 2017 IEEE, 2017, IEEE. p.1-5.
- BONANNO, F. et al. Wavelet recurrent neural network with semi-parametric input data preprocessing for micro-wind power forecasting in integrated generation Systems. **Clean Electrical Power (ICCEP)**, 2015 International Conference on, 2015, IEEE. p.602-609.
- BOX, G. E. et al. **Time series analysis: forecasting and control**. John Wiley & Sons, 2015. ISBN 1118675029.

BRAGA, A. D. P.; CARVALHO, A.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Livros Técnicos e Científicos, 2000. ISBN 8521612184.

BROCKWELL, P. J.; DAVIS, R. A. **Time series: theory and methods**. Springer Science & Business Media, 2013. ISBN 1489900047.

CADENAS, E.; RIVERA, W. Short term wind speed forecasting in La Venta, Oaxaca, México, using artificial neural networks. **Renewable Energy**, v. 34, n. 1, p. 274-278, 2009. ISSN 0960-1481.

_____. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA-ANN model. **Renewable Energy**, v. 35, n. 12, p. 2732-2738, 2010. ISSN 0960-1481.

CADENAS, E. et al. Wind speed prediction using a univariate ARIMA model and a multivariate NARX model. **Energies**, v. 9, n. 2, p. 109, 2016.

CASTRO, R. M. Energias renováveis e produção descentralizada-introdução à energia eólica. **Lisboa, Universidade Técnica de Lisboa, 86p**, 2007.

CBEE. Centro Brasileiro de Energia Eólica. **CBEE - Centro Brasileiro de Energia Eólica**. , Brasil, 2014. Acesso em: 24/05/2017.

CCEE. Câmara de Comercialização de Energia Elétrica. 2018. Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/noticias-opiniao/noticias/noticia leitura?contentid=CCEE_392436&_afLoop=1366565701358569#!%40%40%3Fcontentid%3DCCEE_392436%26_afLoop%3D1366565701358569%26_adf.ctrl-state%3D9vqr7qt75_150>. Acesso em: 05/02/2018.

CHANG, T.-P. et al. Oscillation characteristic study of wind speed, global solar radiation and air temperature using wavelet analysis. **Applied energy**, v. 190, p. 650-657, 2017. ISSN 0306-2619.

CHANG, W.-Y. A literature review of wind forecasting methods. **Journal of Power and Energy Engineering**, v. 2, n. 04, p. 161, 2014.

CHENG, M.; ZHU, Y. The state of the art of wind energy conversion systems and technologies: A review. **Energy Conversion and Management**, v. 88, p. 332-347, 2014. ISSN 0196-8904.

CHENG, William YY et al. Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation. **Renewable Energy**, v. 107, p. 340-351, 2017.

DE PÁDUA BRAGA, A.; DE LEON FERREIRA, A. C. P.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. LTC Editora, 2007. ISBN 8521615647.

DE SALLES, A. C. N. **Metodologias de análise de risco para avaliação financeira de projetos de geração eólica**. 2004. UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

DEMUTH, H. B. et al. **Neural network design**. Martin Hagan, 2014. ISBN 0971732116.

DONG, Q.; SUN, Y.; LI, P. A novel forecasting model based on a hybrid processing strategy and an optimized local linear fuzzy neural network to make wind power forecasting: A case study of wind farms in China. **Renewable Energy**, v. 102, p. 241-257, 2017. ISSN 0960-1481.

DONGMEI, Z.; YUCHEN, Z.; XU, Z. Research on wind power forecasting in wind farms. **Power Engineering and Automation Conference (PEAM)**, 2011 IEEE, 2011, IEEE. p.175-178.

DONOVAN, S. Wind farm optimization. **Proceedings of the 40th annual ORSNZ conference**, 2005. p.196-205.

DUMITRU, C.-D.; GLIGOR, A. Daily Average Wind Energy Forecasting Using Artificial Neural Networks. **Procedia Engineering**, v. 181, p. 829-836, 2017. ISSN 1877-7058.

DUTRA, R. Energia Eólica—Princípios e Tecnologia. **Rio de Janeiro: Centro de Referência para Energia Solar e Eólica Sérgio de Salvo Britto**, 2011.

EHLERS, R. S. Análise de séries temporais. **Universidade Federal do Paraná**, 2007.

EÓLICA, A. B. E. Associação Brasileira de Energia Eólica. **Energia eólica**, 2018.

ESPINOSA, M. M.; PRADO, S. M.; GHELLERE, M. Uso do modelo SARIMA na previsão do número de focos de calor para os meses de junho a outubro no Estado de Mato Grosso. **Ciência e Natura**, v. 32, n. 2, p. 7, 2010. ISSN 0100-8307.

EYMEN, A.; KÖYLÜ, Ü. Seasonal trend analysis and ARIMA modeling of relative humidity and wind speed time series around Yamula Dam. **Meteorology and Atmospheric Physics**, p. 1-12, 2018. ISSN 0177-7971.

FEAM, F. E. D. M. A. Utilização da Energia Eólica no Estado de Minas Gerais: aspectos técnicos e o meio ambiente. **FEAM - Fundação Estadual do Meio Ambiente. Utilização da Energia Eólica no Estado de Minas Gerais: aspectos técnicos e o meio ambiente.** , N.2, Fevereiro, 2013. 2013.

FIGUEREDO, C. J. **Previsão de Séries Temporais Utilizando a Metodologia Box & Jenkins e Redes Neurais para Inicialização de Planejamento e Controle de Produção**. 2008. Universidade Federal do Paraná

FILHO, J. C. R.; AFFONSO, C. D. M.; DE OLIVEIRA, R. C. L. Energy price prediction multi-step ahead using hybrid model in the Brazilian market. **Electric Power Systems Research**, v. 117, p. 115-122, 2014.

FLEMING, P.; PROBERT, S. The evolution of wind-turbines: an historical review. **Applied energy**, v. 18, n. 3, p. 163-177, 1984. ISSN 0306-2619.

FOLEY, A. M. et al. Current methods and advances in forecasting of wind power generation. **Renewable Energy**, v. 37, n. 1, p. 1-8, 2012. ISSN 0960-1481.

GASCH, R.; TWELE, J. **Wind power plants: fundamentals, design, construction and operation**. Springer Science & Business Media, 2011. ISBN 3642229387.

GOMIDE, F. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático**: SciELO Brasil 2012.

GONZÁLEZ, J. S. et al. Overall design optimization of wind farms. **Renewable Energy**, v. 36, n. 7, p. 1973-1982, 2011. ISSN 0960-1481.

GRANGER, C. W. J.; NEWBOLD, P. **Forecasting economic time series**. Academic Press, 2014. ISBN 1483273245.

GUJARATI, D. N.; PORTER, D. C. **Econometria Básica-5**. AMGH Editora, 2011. ISBN 8580550513.

HAN, Q. et al. Non-parametric hybrid models for wind speed forecasting. **Energy Conversion and Management**, v. 148, p. 554-568, 2017. ISSN 0196-8904.

HAYKIN, S. Network, Neural : A comprehensive foundation. **Neural Networks**, v. 2, n. 2004, p. 41, 2004.

HAYKIN, S. S. et al. **Neural networks and learning machines**. Pearson Upper Saddle River, NJ, USA:, 2009.

HECKMAN, J. J.; SERLETIS, A. Introduction to Econometrics with Theory: A Special Issue Honoring William A. Barnett. **Econometric Reviews**, v. 34, n. 1-2, p. 1-5, 2015. ISSN 0747-4938.

HERTZ, J. A. **Introduction to the theory of neural computation**. CRC Press, 2018. ISBN 0429968213.

HIPEL, K. W.; MCLEOD, A. I. **Time series modelling of water resources and environmental systems**. Elsevier, 1994. ISBN 0080870368.

IBM. IBM SPSS Modeler. United States, 2017. Disponível em: <
<https://www.ibm.com/products/spss-modeler> >. Acesso em: 27/02/2018.

JIANG, P.; WANG, Y.; WANG, J. Short-term wind speed forecasting using a hybrid model. **Energy**, v. 119, p. 561-577, 2017. ISSN 0360-5442.

JONCAS, S. **Thermoplastic Composite Wind Turbine Blades: An Integrated Design Approach**. 2010. TU Delft, Delft University of Technology

JUNFENG, L. et al. A study on the pricing policy of wind power in China. In: GWEC, B., 2006, **Brussels: GWEC**.

KAACK, L. H. et al. Empirical prediction intervals improve energy forecasting. **Proceedings of the National Academy of Sciences**, v. 114, n. 33, p. 8752-8757, 2017. ISSN 0027-8424.

KAENSAR, C. Analysis on the parameter of back propagation algorithm with three weight adjustment structure for hand written digit recognition. **Service Systems and Service Management (ICSSSM)**, 2013 10th International Conference on, 2013, IEEE. p.18-22.

KALDELLIS, J. K.; ZAFIRAKIS, D. The wind energy (r) evolution: A short review of a long history. **Renewable Energy**, v. 36, n. 7, p. 1887-1901, 2011. ISSN 0960-1481.

KAPLAN, Orhan; TEMIZ, Murat. A novel method based on Weibull distribution for short-term wind speed prediction. **International Journal of Hydrogen Energy**, v. 42, n. 28, p. 17793-17800, 2017.

KARTHIKEYAN, L.; KUMAR, D. N. Predictability of nonstationary time series using wavelet and EMD based ARMA models. **Journal of hydrology**, v. 502, p. 103-119, 2013. ISSN 0022-1694.

KINGMA, D.; BA, J. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.

KOVAČIĆ, Z. J. **Analiza vremenskih serija**. Ekonomski fakultet Beograd, Beograd. 1995.: Ekonomski fakultet, 1995. ISBN 8640302529.

LAW WOZNIAK, S. et al. Review of Advances in Neural Networks: Neural Design Technology Stack. **Proceedings of ELM-2014 Volume**, p. 367, 2014.

LEI, M. et al. A review on the forecasting of wind speed and generated power. **Renewable and Sustainable Energy Reviews**, v. 13, n. 4, p. 915-920, 2009. ISSN 1364-0321.

LEITE, A. P.; FALCÃO, D. M.; BORGES, C. L. Modelagem de usinas eólicas para estudos de confiabilidade. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 17, n. 2, p. 177-188, 2006. ISSN 0103-1759.

LI, Chaoshun et al. A hybrid model based on synchronous optimisation for multi-step short-term wind speed forecasting. **Applied Energy**, v. 215, p. 131-144, 2018.

LI, G.; SHI, J. On comparing three artificial neural networks for wind speed forecasting. **Applied Energy**, v. 87, n. 7, p. 2313-2320, 2010. ISSN 0306-2619.

LI, Hongmin et al. Research and application of a combined model based on variable weight for short term wind speed forecasting. **Renewable Energy**, v. 116, p. 669-684, 2018.

LIU, D. et al. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm. **Renewable Energy**, v. 62, p. 592-597, 2014. ISSN 0960-1481.

LIU, H. et al. Forecasting models for wind speed using wavelet, wavelet packet, time series and Artificial Neural Networks. **Applied Energy**, v. 107, p. 191-208, 2013. ISSN 0306-2619.

LIU, J.; WANG, X.; LU, Y. A novel hybrid methodology for short-term wind power forecasting based on adaptive neuro-fuzzy inference system. **Renewable energy**, v. 103, p. 620-629, 2017. ISSN 0960-1481.

LIU, Y. et al. A hybrid forecasting method for wind power ramp based on Orthogonal Test and Support Vector Machine (OT-SVM). **IEEE Transactions on Sustainable Energy**, v. 8, n. 2, p. 451-457, 2017. ISSN 1949-3029.

MA, J. et al. Ultra-short-term wind generation forecast based on multivariate empirical dynamic modeling. **IEEE Transactions on Industry Applications**, v. 54, n. 2, p. 1029-1038, 2018. ISSN 0093-9994.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting methods and applications**. John Wiley & Sons, 2008. ISBN 8126518529.

MAKWANA, A. M.; GANDHI, P. Day-Ahead Wind Energy Forecasting Using Feed Forward Neural Network. **Proceedings of the International Conference on Intelligent Systems and Signal Processing**, 2018, **Springer**. p.221-233.

MANWELL, J. F.; MCGOWAN, J. G.; ROGERS, A. L. **Wind energy explained: theory, design and application**. John Wiley & Sons, 2010. ISBN 0470686286.

MAO, Q. et al. Forecasting the incidence of tuberculosis in China using the seasonal auto-regressive integrated moving average (SARIMA) model. **Journal of infection and public health**, 2018. ISSN 1876-0341.

MARELLI, D.; YOU, K.; FU, M. Identification of ARMA models using intermittent and quantized output observations. **Automatica**, v. 49, n. 2, p. 360-369, 2013. ISSN 0005-1098.

MARTINS, F.; GUARNIERI, R.; PEREIRA, E. O aproveitamento da energia eólica. **Revista Brasileira de Ensino de Física**, v. 30, n. 1, p. 1304, 2008.

MONFARED, M.; RASTEGAR, H.; KOJABADI, H. M. A new strategy for wind speed forecasting using artificial intelligent methods. **Renewable energy**, v. 34, n. 3, p. 845-848, 2009. ISSN 0960-1481.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. John Wiley & Sons, 2015. ISBN 1118745116.

MOREIRA, L. C. Um novo mercado de energia elétrica para o Brasil. 2017.

MORETTIN, P. A.; TOLOI, C. **Análise de séries temporais**. Blucher, 2006. ISBN 8521203896.

MUSGROVE, P. et al. **Wind power**. Cambridge University Press Cambridge, 2010. ISBN 0521747635.

NIU, D.; PU, D.; DAI, S. Ultra-Short-Term Wind-Power Forecasting Based on the Weighted Random Forest Optimized by the Niche Immune Lion Algorithm. **Energies**, v. 11, n. 5, p. 1-21, 2018.

NOBRE, F. F. et al. Dynamic linear model and SARIMA: a comparison of their forecasting performance in epidemiology. **Statistics in medicine**, v. 20, n. 20, p. 3051-3069, 2001. ISSN 1097-0258.

NUNES, G. D. A.; MANHÃES, A. A. Energia eólica no Brasil: uma alternativa inteligente frente às demandas elétricas atuais. **Revista de divulgação do Projeto Universidade Petrobras e IF Fluminense v. 1, p. 163-167, 2010.**, v. 1, p. 163-167, 2010.

NURY, A. H.; HASAN, K.; ALAM, M. J. B. Comparative study of wavelet-ARIMA and wavelet-ANN models for temperature time series data in northeastern Bangladesh. **Journal of King Saud University-Science**, v. 29, n. 1, p. 47-61, 2017. ISSN 1018-3647.

OLAOFE, Z.; FOLLY, K. Wind power estimation using recurrent neural network technique. **Power Engineering Society Conference and Exposition in Africa (PowerAfrica)**, 2012 IEEE, 2012, IEEE. p.1-7.

OLIVEIRA, J. B. D. **Sistemas inteligentes e wavelets para previsão de vento e geração eólica**. 2008. Dissertação Mestrado. Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Pernambuco. , Recife, 2008.

PAN, D.-F.; LIU, H.; LI, Y.-F. A wind speed forecasting optimization model for wind farms based on time series analysis and Kalman filter algorithm. **Power System Technology**, v. 32, n. 7, p. 82-86, 2008.

PATEL, M. R. **Wind and solar power systems: design, analysis, and operation**. CRC press, 2005. ISBN 142003992X.

PAVINATTO, E. F. Ferramenta para auxílio à análise de viabilidade técnica da conexão de parques eólicos à rede elétrica. **Electrical Engineering Master Thesis. COPPE/UFRJ**, 2005.

PICOLO, A. P.; BÜHLER, A. J.; RAMPINELLI, G. A. Uma abordagem sobre a energia eólica como alternativa de ensino de tópicos de física clássica. **Revista Brasileira de Ensino de Física**, v. 36, n. 4, p. 4306, 2014.

POKORNY, M. **An introduction to econometrics**. Blackwell, 1987. ISBN 063115003X.

RAICHAROEN, T.; LURSINSAP, C.; SANGUANBHOKAI, P. Application of critical support vector machine to time series prediction. *Circuits and Systems*, 2003. ISCAS'03. **Proceedings of the 2003 International Symposium on**, 2003, IEEE. p.V-V.

REN, C. et al. Optimal parameters selection for BP neural network based on particle swarm optimization: A case study of wind speed forecasting. **Knowledge-Based Systems**, v. 56, p. 226-239, 2014. ISSN 0950-7051.

SANTOS, R. C. D. Energia eólica para produção de energia elétrica. **Rio de Janeiro: Eletrobrás**, 2009.

SCHICKER, Irene et al. Short-range wind speed predictions for complex terrain using an interval-artificial neural network. **Energy Procedia**, v. 125, p. 199-206, 2017.

SCHLÜTER, S.; DEUSCHLE, C. **Using wavelets for time series forecasting: Does it pay off?** IWQW discussion paper series. 2010

SHAFAEI, M.; KISI, O. Lake level forecasting using wavelet-SVR, wavelet-ANFIS and wavelet-ARMA conjunction models. **Water resources management**, v. 30, n. 1, p. 79-97, 2016. ISSN 0920-4741.

SHARIFIAN, Amir et al. A new method based on Type-2 fuzzy neural network for accurate wind power forecasting under uncertain data. **Renewable Energy**, v. 120, p. 220-230, 2018.

SHEPHERD, D. G. Historical development of the windmill. **Wind Turbine Technology–Fundamental Concepts of Wind Turbine Engineering**, v. 1, p. 1-46, 1994.

SHOAIB, M. et al. A wavelet based approach for combining the outputs of different rainfall–runoff models. **Stochastic Environmental Research and Risk Assessment**, v. 32, n. 1, p. 155-168, 2018. ISSN 1436-3240.

SILVA, I. N. D.; SPATTI, H.; FLAUZINO, R. Redes Neurais Artificiais, **Curso prático para engenharia e ciências aplicadas/Ivan Nunes da Silva**, 2010.

SLOUGHTER, J. M.; GNEITING, T.; RAFTERY, A. E. Probabilistic wind speed forecasting using ensembles and Bayesian model averaging. **Journal of the american statistical association**, v. 105, n. 489, p. 25-35, 2010. ISSN 0162-1459.

SOMAN, S. S. et al. A review of wind power and wind speed forecasting methods with different time horizons. **North American Power Symposium (NAPS)**, 2010, 2010, IEEE. p.1-8.

SONDA, S. D. O. N. D. D. A. ESTAÇÕES SONDA. 2018. Disponível em: <
<http://sonda.ccst.inpe.br/infos/index.html> >.

SONG, J.; WANG, J.; LU, H. A novel combined model based on advanced optimization algorithm for short-term wind speed forecasting. **Applied Energy**, v. 215, p. 643-658, 2018. ISSN 0306-2619.

SOUZA, F. M. Modelos Box & Jenkins aplicados a previsão de demanda de leitos hospitalares. **Programa de Pós-Graduação em Estatística e Modelagem Quantitativa, Universidade Federal de Santa Maria (UFSM), RS**, 2006.

SUN, Gaiping et al. Short-term wind power forecasts by a synthetical similar time series data mining method. **Renewable Energy**, v. 115, p. 575-584, 2018.

SUN, Shaolong et al. A new dynamic integrated approach for wind speed forecasting. **Applied Energy**, v. 197, p. 151-162, 2017.

TERCIOTE, R. A energia eólica e o meio ambiente. **Proceedings of the 4th Encontro de Energia no Meio Rural**, 2002.

THOMAS, T.; CHERIYAN, E. P. Wind energy system for a laboratory scale micro-grid. **Electrical, Electronics and Computer Science (SCEECS)**, 2012 IEEE Students' Conference on, 2012, IEEE. p.1-5.

TONG, W. **Wind power generation and wind turbine design**. WIT press, 2010. ISBN 1845642058.

VALIPOUR, M.; BANIHABIB, M. E.; BEHBAHANI, S. M. R. Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. **Journal of hydrology**, v. 476, p. 433-441, 2013. ISSN 0022-1694.

WAN, C. et al. Optimal micro-siting of wind farms by particle swarm optimization. **Advances in swarm intelligence**, p. 198-205, 2010.

WANG, Deyun et al. Multi-step ahead wind speed forecasting using an improved wavelet neural network combining variational mode decomposition and phase space reconstruction. **Renewable Energy**, v. 113, p. 1345-1358, 2017.

WANG, J. et al. Medium-term wind speeds forecasting utilizing hybrid models for three different sites in Xinjiang, China. **Renewable Energy**, v. 76, p. 91-101, 2015. ISSN 0960-1481.

WANG, X.; GUO, P.; HUANG, X. A review of wind power forecasting models. **Energy procedia**, v. 12, p. 770-778, 2011. ISSN 1876-6102.

WU, L.; SHAHIDEHPOUR, M. A hybrid model for day-ahead price forecasting. **IEEE Transactions on Power Systems**, v. 25, n. 3, p. 1519-1530, 2010. ISSN 0885-8950.

WU, Y.-K.; HONG, J.-S. A literature review of wind forecasting technology in the world. **Power Tech, 2007 IEEE Lausanne**, 2007, IEEE. p.504-509.

- XIAO, Liye; QIAN, Feng; SHAO, Wei. Multi-step wind speed forecasting based on a hybrid forecasting architecture and an improved bat algorithm. **Energy Conversion and Management**, v. 143, p. 410-430, 2017.
- YADAV, A.; SAHU, K. WIND FORECASTING USING ARTIFICIAL NEURAL NETWORKS: A SURVEY AND TAXONOMY. **International Journal of Research In Science & Engineering**, v. 3, 2017.
- YOUNG, P. C. Refined instrumental variable estimation: maximum likelihood optimization of a unified Box–Jenkins model. **Automatica**, v. 52, p. 35-46, 2015. ISSN 0005-1098.
- YOUSSEFBEIGI, S.; AKMANDOR, I. S. Wind Farm Optimization. **International Symposium on Innovative Technologies in Engineering and Science**. ISITES, 2015. p.3-5.
- ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, v. 50, p. 159-175, 2003. ISSN 0925-2312.
- ZHANG, K.; GENÇAY, R.; YAZGAN, M. E. Application of wavelet decomposition in time-series forecasting. **Economics Letters**, v. 158, p. 41-46, 2017. ISSN 0165-1765.
- ZHANG, L.; ZHANG, B. A geometrical representation of McCulloch-Pitts neural model and its applications. **IEEE Transactions on Neural Networks**, v. 10, n. 4, p. 925-929, 1999. ISSN 1045-9227.
- ZHANG, Y.; WANG, J.; WANG, X. Review on probabilistic forecasting of wind power generation. **Renewable and Sustainable Energy Reviews**, v. 32, p. 255-270, 2014. ISSN 1364-0321.
- ZHAO, X.; WANG, S.; LI, T. Review of evaluation criteria and main methods of wind power forecasting. **Energy Procedia**, v. 12, p. 761-769, 2011. ISSN 1876-6102.