

INSTITUTO FEDERAL DE EDUCAÇÃO,
CIÊNCIA E TECNOLOGIA DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENERGIAS RENOVÁVEIS

Samuel Luz Gomes

Estimativa de produção de energia eólica em aerogeradores utilizando
métodos de regressão sobre a curva de potência e redes neurais recursivas
para prever a velocidade do vento

Maracanaú, Ceará

2017

Samuel Luz Gomes

Estimativa de produção de energia eólica em aerogeradores utilizando métodos de regressão sobre a curva de potência e redes neurais recursivas para prever a velocidade do vento

Dissertação apresentada ao Programa de Pós-graduação em Energias Renováveis do Instituto Federal de Educação, Ciência e Tecnologia do Ceará como requisito parcial para a obtenção do título de mestre em energias renováveis. Área de concentração: Energias Renováveis.

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho
Coorientador: Prof. Dr. Cláudio Marques de Sá Medeiros

Maracanaú, Ceará

2017

Dados Internacionais de Catalogação na Publicação (CIP)
Ficha catalográfica elaborada pelo Bibliotecário
Gláucio Barreto de Lima - CRB-3/995

G633 Gomes, Samuel Luz.

Estimativa de produção de energia eólica em aerogeradores utilizando métodos de regressão sobre a curva de potência e redes neurais recursivas para prever a velocidade do vento / Samuel Luz Gomes -- 2017.
86 f.

Dissertação (Mestrado em Energias Renováveis) -
- Instituto Federal de Educação Ciência e Tecnologia do Ceará, *campus* Maracanaú, 2017.
Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho.

1. ENERGIA EÓLICA. 2. AEROGERADOR. 3. REDES NEURAIIS. I. Título.

333.92


SAMUEL LUZ GOMES

ESTIMATIVA DE PRODUÇÃO DE ENERGIA EÓLICA EM AEROGERADORES
UTILIZANDO MÉTODOS DE REGRESSÃO SOBRE A CURVA DE POTÊNCIA E
REDES NEURAIS RECURSIVAS PARA PREVER A VELOCIDADE DO VENTO


Dissertação submetida à Coordenação do Curso de Pós-graduação em Energias Renováveis do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para a obtenção do título de Mestre em Energias Renováveis, área de concentração Energias Renováveis.

Aprovada em 28 / 12 / 2017


BANCA EXAMINADORA




Prof. Dr. Pedro Pedrosa Rebouças Filho (Orientador)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Cláudio Marques de Sá Medeiros
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Antônio Carlos da Silva Barros
Universidade de Fortaleza - UNIFOR



Prof. Dr. José Daniel de Alencar Santos
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Agradecimentos

Agradeço a Deus que, com seu grande amor e misericórdia, me deu vida em abundância em seu filho, Jesus Cristo.

Ao meu pai, José Valdo, por se meu grande exemplo de superação e por me apoiar em todos os meus sonhos.

A minha mãe, Maria José, por seu grande amor e por interceder por mim em todos os momentos com suas orações.

A minha esposa, Suzana Marques, que me aguentou nos momentos mais estressantes com amor e paciência. Que me deu todo o suporte necessário para a conclusão deste trabalho e que me dá confiança para enfrentar os desafios que virão.

Ao meu orientador e amigo, Prof. Pedro Pedrosa, por ter acreditado em minha capacidade quando eu mesmo não acreditava. Por não ter permitido que eu desistisse me ajudando a superar meus limites e a ser um profissional melhor.

Ao meu coorientador Prof. Cláudio Sá, por suas críticas e sugestões que contribuiu bastante para esse trabalho.

Ao meus colegas e amigos do LAPISCO (Laboratório de Processamento de Imagens, Sinais e Computação Aplicada), que estão sempre à disposição para ajudar. Em especial aos grandes amigos, Navar Nascimento, Shara Shame e Leandro Marinho, que me ajudaram muito em várias etapas desse trabalho.

Ao Instituto Federal do Ceará (IFCE), por me propiciar toda a estrutura necessária para o meu desenvolvimento profissional.

“Não te surpreendas pelo fato de Eu te haver dito: ‘deveis nascer de novo.’ O vento sopra onde quer, e ouves a sua voz; mas não sabes donde vem, nem para onde vai; assim é todo aquele que é nascido do Espírito.”
(Jesus Cristo, João 3:8)

Resumo

A energia eólica se mostra como uma interessante fonte de energia alternativa para complementar a matriz energética brasileira. O grande desafio desta tecnologia encontra-se, hoje, em gerenciar o recurso eólico devido ao seu comportamento sazonal e intermitente, o que prejudica o mercado de energia eólica. Tendo em vista esta problemática, nesta dissertação é abordado o problema da estimação da produção de energia elétrica de um aerogerador de velocidade variável. A estimação do recurso eólico auxilia no gerenciamento de parques eólicos possibilitando um aproveitamento mais eficiente do recurso eólico, além de possibilitar calcular o potencial de geração energética de uma região onde ainda não existe aerogeradores instalados. A estimativa da produção de energia de um aerogerador é realizada através da curva de potência do aerogerador e da previsão da velocidade do vento. A curva de potência do aerogerador é fornecida pelo fabricante, entretanto este trabalho visa obter esta curva de potência utilizando métodos de regressão paramétricos e não paramétricos em dados reais de vento e potência gerados em aerogeradores instalados no estado ceará. Em conjunto com a aproximação da curva de potência, este trabalho utiliza uma Rede Neural recursiva (NAR) e um método de regressão baseado em Vetores de Suporte (SVR) na predição de velocidade de vento. Concluímos que realizar a predição de produção de energia é possível e eficaz, visto que as duas etapas intermediárias (predição da curva de potência e estimativa da velocidade do vento) foram realizadas de forma satisfatória, em que a melhor abordagem apresentada é utilizando o método NAR para estimar a velocidade do vento e o MQ para predição da curva de potência quando é necessário uma predição de energia de até 5 dias à frente, enquanto a melhor abordagem para períodos mais curtos é obtida pelo método SVR na estimativa da velocidade do vento e o MQ para predição da curva de potência. Sendo assim, ao fim dos resultados apresentados e análises realizadas, este trabalho conclui que estimar a curva por métodos de regressão torna a análise da produção de aerogeradores mais adequada e realista, além de abrir espaço para outras análises comerciais, como por exemplo, a estimativa de produção de máquinas paradas, ou quanto se deixa de produzir em máquinas paradas para manutenção, ou até mesmo para planejar paradas em períodos de vento com menos intensidade. Por fim, pode-se concluir que abordagem proposta neste estudo possui potencial para ser utilizados em parques eólicos de forma eficaz e satisfatória. **Palavras-chaves:** Energia eólica, Modelagem, Curva de potência, Séries Temporais, Rede Neural Recorrente.

Abstract

Wind energy is an interesting source of alternative energy to complement the Brazilian energy matrix. The great challenge of this technology lies today in managing the wind resource due to its seasonal and intermittent behavior, which harms the wind energy market. Considering this problem, this study addresses the problem of the estimation of the electric power production of a variable speed wind turbine. The estimation of the wind resource assists in the management of wind farms, allowing a more efficient use of the wind resource, besides making it possible to calculate the power generation potential of a region where there are still no wind turbines installed. The estimation of the energy production of a wind turbine is performed through the power curve of the wind turbine and wind speed prediction. The power curve of the aerogenerator is provided by the manufacturer, however this work aims to obtain this power curve using parametric and non-parametric regression methods in real wind and power data generated in aerogenerators installed in the state of Ceará. Integrated with the power curve approximation, this work uses a recursive neural network (NAR) and a regression method based on support vectors (SVR) in wind speed prediction. We conclude that prediction of energy production is possible and effective, since the two intermediate stages (power curve prediction and wind speed estimation) were performed in a satisfactory approach, where the best is using the NAR method to estimate the wind speed and the MQ to predict the power curve when an energy prediction until 5 days ahead is required, while the best approach for shorter periods is obtained by the SVR method in estimating wind speed and MQ to predict the power curve. Thus, at the end of the results presented and analyzes carried out, this work concludes that estimating the curve by regression methods makes the analysis of the production of aerogenerators more adequate and realistic, as well as making room for other commercial analyzes, such as estimation of production of stationary machines, or how much is left to be produced in machines stopped for maintenance, or even to plan stops in periods of wind with less intensity. Finally, it can be concluded that the approach proposed in this study has the potential to be used effectively and satisfactorily in wind farms. **Key-words:** Wind Power, Modeling, Power Curve, Time Series, Recurrent Neural Network.

Lista de ilustrações

Figura 1 – Matriz elétrica brasileira	14
Figura 2 – Geração de energia por fontes hidrelétricas e eólicas no Brasil em 2016 (MW médio)	16
Figura 3 – Evolução da capacidade instalada de geração eólica	17
Figura 4 – Comportamento dos ventos de circulação global que cobrem todo o planeta.	30
Figura 5 – Componentes de um aerogerador de eixo horizontal	31
Figura 6 – Sistema de Conversão de Energia Eólica.	32
Figura 7 – Curvas de C_p x λ para diversos valores de β	33
Figura 8 – Exemplo da curva de potência de uma aerogerador de velocidade variável real.	35
Figura 9 – Fluxograma do sistema de controle um aerogerador.	35
Figura 10 – Regiões da curva de potência de um aerogerador de velocidade variável.	36
Figura 11 – Processo de modelagem baseado em equações fundamentais.	37
Figura 12 – Perceptron Simples	39
Figura 13 – Função de perda ε -insensível	42
Figura 14 – Preditor recursivo com realimentação.	46
Figura 15 – Exemplo de topologia NAR.	47
Figura 16 – Exemplo de resultado da rede NAR estimando série temporal.	48
Figura 17 – Exemplo de <i>underfitting</i>	48
Figura 18 – Exemplo de <i>overfitting</i>	49
Figura 19 – Etapas para estimação da produção energética de um aerogerador	50
Figura 20 – Exemplo da relação de velocidade do vento, produção de energia e disponibilidade do aerogerador.	51
Figura 21 – Curva de potência do aerogerador utilizado dada pelo fabricante.	52
Figura 22 – Filtragem dos dados	53
Figura 23 – Modelo com combinações de funções lineares.	55
Figura 24 – Divisão dos dados para avaliação dos métodos não paramétrica na predição da curva de potência de um aerogerador.	57
Figura 25 – Topologia do modelo NAR para predição da velocidade do vento.	58
Figura 26 – Etapas para estimativa do potencial eólico na abordagem proposta.	59
Figura 27 – Análise de similaridade da regressão exponencial variando K_p e β	61
Figura 28 – Análise de similaridade da regressão logística variando b e c do vetor θ_3	62
Figura 29 – Curvas de aproximação da curva de potência obtidas por modelos paramétricos, juntamente com a curva dada pelo fabricante.	63
Figura 30 – Análise da regressão polinomial com MQ	64

Figura 31 – Análise do número de neurônios ocultos da ELM	65
Figura 32 – Análise do número de neurônios ocultos da RBF	66
Figura 33 – Curvas de aproximação da curva de potência obtidas por modelos paramétricos durante o período de treino, juntamente com a curva dada pelo fabricante.	67
Figura 34 – Curvas de aproximação da curva de potência obtidas por modelos paramétricos durante o período de teste, juntamente com a curva dada pelo fabricante.	68
Figura 35 – Dados utilizados na análise dos métodos de previsão da velocidade do vento: a) dados de treino; b) dados de teste.	69
Figura 36 – Resultado da previsão de velocidade do vento no período avaliado, através dos métodos a) NAR em simulação livre; e b) SVR com horizonte de previsão de três passos a frente.	71
Figura 37 – Resultados obtidos na estimativa de potência produzida utilizando o método NAR na estimativa do vento, e a curva de potência pelo método Logístico em (a) e MQ em (b), em relação aos dados reais do período avaliado.	74
Figura 38 – Resultados obtidos na estimativa de potência produzida utilizando o método SVR na estimativa do vento, e a curva de potência pelo método Logístico em (a) e MQ em (b), em relação aos dados reais do período avaliado.	75
Figura 39 – Curvas de potência obtidas pelos métodos propostos em contraste com a curva de potência informada pelo fabricante.	76
Figura 40 – Aplicação do modelo MQ na análise da produção de um período real em que a máquina estava parada.	78
Figura 41 – Análise sazonal das curvas de produção, considerando os meses: a) Janeiro, Fevereiro e Março; b) Abril, Maio, Junho; c) Julho, Agosto e Setembro; d) Outubro, Novembro e Dezembro.	79

Lista de tabelas

Tabela 1 – Geração de energia por fontes hidrelétricas e eólicas no Brasil em 2016 (MW médio)	15
Tabela 2 – Constante de Aproximação.	33
Tabela 3 – Função de Kernel	45
Tabela 4 – Características do Aerogerador.	52
Tabela 5 – Resultados obtidos	62
Tabela 6 – Análise da regressão polinomial com MQ.	62
Tabela 7 – Análise da regressão polinomial com MQ	64
Tabela 8 – Análise do número de neurônios ocultos da ELM	65
Tabela 9 – Análise do número de neurônios ocultos da RBF	67
Tabela 10 – Resultados obtidos durante o período de treino dos modelos não paramétricos.	67
Tabela 11 – Resultados dos modelos não paramétricos aplicados às amostras de teste.	68
Tabela 12 – Resultados das estimativas de produção de energia, obtida pela combinação da curva de potência (considerando os métodos mínimos quadrados (MQ), logístico e a curva do fabricante) e pela velocidade do vento (considerando os métodos NAR, SVR e a velocidade do vento real (VVR)).	72
Tabela 13 – Análise dos modelos Sigmoides ³ e MQ em cada trimestre do ano.	78

Lista de abreviaturas e siglas

ELM	Extreme Learning Machine
MISO	Multi-Input, Single-Output
MME	Ministério Minas e Energias
MQ	Mínimos quadrados
NAR	Nonlinear AutoRegressive model
NARX	Nonlinear AutoRegressive model with eXogenous inputs
PCH	Pequenas Centrias Hidrelétricas
PROINFA	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
PS	Perceptron Simples
SCEE	Sistema de Conversão de Energia Eólica
SIN	Sistema Elétrico Interligado Nacional
SOM	Self Organizing Maps
SLFN	Single-hidden Layer Feedforward Network
RBF	Radial Basis Function
RMSE	Root Mean Square Error
RNA	Rede Neural Artificial
VSWT	Variable Speed Wind Turbine

Sumário

1	INTRODUÇÃO	14
1.1	Justificativa	16
1.2	Objetivos	18
1.2.1	Objetivos específicos	18
1.3	Produção	18
1.4	Organização do texto	19
2	ESTADO DA ARTE	20
2.1	Previsão da velocidade do vento	22
2.2	Regressão da curva de potência de um aerogerador	24
2.3	Impactos na produção de energia	26
2.4	Contribuições da pesquisa	28
3	FUNDAMENTAÇÃO TEÓRICA	29
3.1	Energia Eólica	29
3.2	Sistema de conversão de energia eólica - Aerogeradores	30
3.2.1	Coefficiente de potência C_p	32
3.3	Curva de Potência	34
3.4	Controle de Aerogeradores	34
3.5	Métodos de Regressão	37
3.6	Reconhecimento de Padrões	38
3.6.1	Perceptron Simples	38
3.6.2	Mínimos Quadrados	39
3.6.3	Máquina de Aprendizagem Extrema (ELM)	40
3.6.4	Função de Base Radial	41
3.7	Regressão baseada em Vetores-Suporte	42
3.7.1	SVR para Regressão Linear	43
3.7.2	SVR para Regressão Não-Linear	44
3.7.3	RNAs Recursivas	45
3.7.4	Rede NAR	46
3.8	Métricas de avaliação dos resultados	47
4	METODOLOGIA	50
4.1	Bancos de dados	51


4.1.1	Filtragem de dados	52
4.2	Regressão da curva de potência	53
4.2.1	Obtenção da curva de potência por modelos paramétricos	54
4.2.1.1	Curva de potência cúbico aproximado	54
4.2.1.2	Curva de potência exponencial	54
4.2.1.3	Curva de potência polinomial	54
4.2.1.4	Função logística	55
4.2.2	Obtenção da curva de potência por modelos não paramétricos	56
4.3	Predição da velocidade do vento	56
4.4	Estimação do potencial energético	58
5	RESULTADOS E DISCUSSÕES	60
5.1	Modelagem da curva de potência	60
5.1.1	Modelagem da curva de potência por modelos paramétricos	60
5.1.1.1	Aproximação Cúbica	60
5.1.1.2	Curva de potência exponencial	60
5.1.1.3	Modelo polinomial	61
5.1.1.4	Aproximação por função logística	61
5.1.1.5	Comparação dos resultados dos modelos paramétricos	62
5.1.2	Modelagem da curva de potência por modelos não paramétricos	63
5.1.2.1	Mínimos Quadrados	63
5.1.2.2	<i>Extreme Learning Machine</i> (ELM)	64
5.1.2.3	<i>Radial Basis Function</i> (RBF)	66
5.1.2.4	Comparação dos resultados dos modelos não paramétricos	66
5.2	Predição da velocidade do vento	68
5.3	Estimação da produção energética do aerogerador	70
5.4	Ferramentas de análise geradas pela abordagem proposta	73
5.4.1	Análise da curva de produção de energia	74
5.4.2	Análise da produção do período em que a máquina não estava 100% disponível	77
5.4.3	Análise da sazonalidade dos ventos	78
6	CONCLUSÕES	81
6.1	Trabalhos futuros	82
	REFERÊNCIAS	83

1 Introdução

Energia é um dos insumos essenciais para o desenvolvimento sócio-econômico de um país, de tal forma que a quantidade de energia consumida por uma nação muitas vezes reflete o seu nível de desenvolvimento ([SATHYAJITH, 2014](#)). Infelizmente, o uso de energia proveniente de combustíveis fósseis ainda é predominante na matriz energética mundial e isto tem ocasionado problemas ambientais e econômicos. As preocupações com mudanças climáticas e os preços altamente voláteis do petróleo têm atraído o interesse e o apoio dos governos para sustentar investimentos em aproveitamento das fontes de energia renovável (FER). Dessa forma, várias políticas de apoio foram implementadas em muitos países ao redor do mundo, já que a introdução de fontes de energia renováveis na matriz energética tem o potencial de reduzir as emissões de carbono para a atmosfera, assim como amenizar a dependência econômica dos países que importam petróleo ([FAGIANI; BARQUIN; HAKVOORT, 2013](#)).

No Brasil, a matriz elétrica é abastecida principalmente pelas hidrelétricas, como pode ser visto na Figura 1. Apesar da hidrelétrica ser uma fonte de energia considerada limpa e bastante confiável não é ideal ter a matriz elétrica baseada em apenas uma fonte

Figura 1 – Matriz elétrica brasileira



Fonte: ([ABEEÓLICA, 2016](#))

de energia. Em épocas em que a efluência hidrológica nos reservatórios hidrelétricos reduz, o país passa por momentos com baixa capacidade de geração de energia. Isso faz com que seja necessário o acionamento das usinas termoeletricas que, além de emitir CO_2 , tem um custo de produção mais elevado que as hidrelétricas e eólicas. No ano de 2016, por exemplo, a queda no nível de água dos reservatórios baixou ao ponto do reservatório de Sobradinho iniciar o ano de 2017 com apenas 12% da sua capacidade (ABEEÓLICA, 2016).

Nota-se, dessa forma, a necessidade de diversificar a matriz energética do país investindo em outras fontes de energia, de preferência, fontes limpas e com características complementares. A energia eólica, por exemplo, apresenta características sazonais complementares às hidrelétricas. Na Figura 2 são apresentados gráficos de análises mensais da produção energética das fontes eólicas e hidrelétricas no Brasil no ano de 2016, onde é possível notar que, entre os meses de junho e novembro, enquanto a produção das hidrelétricas reduziu, a produção eólica aumentou. Além disto, a utilização de energia eólica no ano de 2016 evitou a emissões de 17,81 milhões toneladas de CO_2 substituindo outras fontes de geração de energia elétrica com emissão (ABEEÓLICA, 2016).

Outro ponto importante a ser observado é que o aumento da oferta de energia eólica tem descentralizado a produção de energia do país, tornando os estados do Nordeste mais independentes da importação de energia proveniente de outros estados. Segundo estudo feito pelo consultor Thaymos para a ABEEólica, o risco de déficit de energia para a região Nordeste do Brasil no ano de 2016 foi de 6,1%, sem as eólicas esse número teria sido de 43,1% (ABEEÓLICA, 2016). Assim, a energia eólica se mostra como uma interessante fonte de energia alternativa para complementar a matriz energética brasileira.


Tabela 1 – Geração de energia por fontes hidrelétricas e eólicas no Brasil em 2016 (MW médio)

Mês	Fonte hidrelétrica	Fonte eólica	hidrelétricas + eólicas
Jan	47615,05	1734,52	49349,57
Fev	52013,85	2557,91	54571,76
Mar	51963,29	2601,83	54565,12
Abr	50151,29	3165,71	53317
Mai	46190,49	3041,12	49231,61
Jun	44841	3541,43	48382,43
Jul	44244,9	4171,94	48416,84
Ago	43790,64	4272,28	48062,92
Set	42982,31	4621,82	47604,13
Out	43337,25	4521,11	47858,36
Nov	44560,99	4238,01	48799
Dez	48935,43	3615,66	52551,09

Fonte: (ONS, 2017)

Com o objetivo de diversificar a matriz energética brasileira e aumentar a partici-

Figura 2 – Geração de energia por fontes hidrelétricas e eólicas no Brasil em 2016 (MW médio)



Fonte: (ONS, 2017)


pação da energia elétrica produzida por empreendimentos concebidos com base em fonte eólica, biomassa e Pequenas Centrais Hidrelétricas (PCH) no Sistema Elétrico Interligado Nacional (SIN) o Ministério de Minas e Energias(MME) do Brasil criou o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA) que foi grande incentivador da produção de energia eólica no país. Pouco mais de uma década após a criação do PROINFA, iniciado em 2004, a capacidade eólica instalada ultrapassou a marca dos 9 GW em agosto de 2016 (ABEEÓLICA, 2016). A Figura 3 ilustra o crescimento da fonte eólica instalada no decorrer dos anos com estimativa até 2020, onde há a expectativa de 18,42 GW instalados em território brasileiro.

O desafio destas tecnologias encontra-se, hoje, em estimar o recurso eólico devido ao seu aspecto sazonal e intermitente. Estas características prejudicam o mercado de energia eólica. Tendo em vista esta problemática, este trabalho propõe analisar métodos de estimativa de produção baseados na modelagem da curva de potência de um aerogerador e da previsão de velocidade do vento aplicando métodos de inteligência computacional para auxiliar na gestão em um parque eólico.

1.1 Justificativa

Para um aproveitamento eficiente do recurso eólica de uma região é necessário estimar o seu potencial de geração eólico. Utilizando a análise da curva de potência de

Figura 3 – Evolução da capacidade instalada de geração eólica



Fonte: (ABEEÓLICA, 2016)

um aerogerador juntamente com dados da velocidade do vento de uma região podemos estimar o seu potencial de geração de energia eólica, além disto, é possível utilizar os mesmos métodos para verificar se em um parque eólico já instalado as turbinas estão funcionando corretamente (THAPAR; AGNIHOTRI; SETHI, 2011; LYDIA et al., 2015; KHALFALLAH; KOLIUB, 2007).

A curva de potência é a característica energética fundamental dos aerogeradores. Ela consiste na relação entre a potência elétrica fornecida em função da velocidade de vento incidente (VILLANUEVA; FEIJÓO, 2016). A curva de potência é utilizada para estimação do recurso eólico de determinado local (LYDIA et al., 2015), o que ajuda na identificação de potenciais locais para o estabelecimento de um parque eólico, assim como determinar o modelo de turbina mais adequado para um específico local. A curva de potência também auxilia no cálculo da energia anual produzida (KUSIAK; ZHENG; SONG, 2009a; VILLANUEVA; FEIJÓO, 2016), o que pode aumentar a penetração de energia eólica na rede elétrica e no mercado de eletricidade, podendo também ser utilizada como perfis on-line da curva de potência para detecção de defeitos no processo de geração de energia de turbinas eólicas (KUSIAK; ZHENG; SONG, 2009b). O modelo da curva de potência possibilita melhorias no controle, monitoramento e otimização de desempenho de parques eólicos (KUSIAK; ZHENG; SONG, 2009a).

É comum em cada gerador ter instalado um sensor anemômetro de medição de velocidade do vento e também de sua direção o que, agregado com as informações

de produção de energia, abre diversas possibilidades de análise de cada aerogerador, e até mesmo em parques eólicos. Sendo assim, este trabalho visa utilizar os dados de disponibilidade de vento e de produção de energia para prever a produção de energia eólica destes aerogeradores, sendo isto realizado através da obtenção do modelo matemático da curva de potência por métodos de regressão matemática utilizando dados reais de um aerogerador, bem como pela estimativa de disponibilidade de vento na região em que o aerogerador está instalado.

1.2 Objetivos

O objetivo deste trabalho é estimar a produção de energia elétrica de um aerogerador a partir da obtenção da curva de potência do aerogerador por métodos de regressão e da previsão da disponibilidade de vento que incide na turbina do aerogerador. Ambos utilizando dados reais locais de um aerogerador.

1.2.1 Objetivos específicos

Essa dissertação tem os seguintes objetivos específicos:

- Modelar a curva de potência através de métodos de regressão utilizando dados locais do aerogerador, e avaliar o método que obtém o melhor desempenho;
- Realizar a previsão da velocidade de vento do local onde está instalado o aerogerador;
- Prever a produção de energia utilizando a curva de potência encontrada e a velocidade do vento predita.

1.3 Produção

Dentre os artigos aprovados junto ao PPGER até o presente momento utilizando métodos de Inteligência Artificial Aplicada e na área de Processamento Digital de Sinais, podem ser listados:

- GOMES, S. L. ; REBOUÇAS, E. S. ; Cavalcanti Neto, E. ; Papa, J. P. ; ALBUQUERQUE, V. H. C. ; Rebouças Filho, Pedro Pedrosa ; TAVARES, J. M. R. S. . Embedded real-time speed limit sign recognition using image processing and machine learning techniques. Neural Computing and Applications (Print), p. 1-12, 2016.
- Cavalcanti Neto, E. ; REBOUÇAS, E. S. ; MORAES, J. L. ; GOMES, S. L. ; REBOUÇAS FILHO, P. P. . Development control parking access using techniques Digital Image Processing and Applied Computational Intelligence. Revista IEEE América Latina, v. 13, p. 272-276, 2015.

- Cavalcanti Neto, E. ; GOMES, S. L. ; Rebouças Filho, Pedro Pedrosa ; DE ALBUQUERQUE, VICTOR HUGO C. . Brazilian vehicle identification using a new embedded plate recognition system. Measurement (London. Print), p. 36-46, 2015.
- REBOUÇAS, E. S. ; GOMES, S. L. ; Rebouças Filho, Pedro Pedrosa . Computer Vision System to Aid Drivers of Vehicles through Vertical Signaling Traffic. International Journal of Computer Applications, v. 115, p. 1-7, 2015.
- Rebouças Filho, Pedro Pedrosa; MOREIRA, F. D. L. ; XAVIER, F. G. L. ; GOMES, S. L. ; SANTOS, J. C. ; FREITAS, F. N. C. ; FREITAS, R. G. . New Analysis Method Application in Metallographic Images through the Construction of Mosaics Via Speeded Up Robust Features and Scale Invariant Feature Transform. Materials (Basel), v. 8, p. 3864-3882, 2015.

Além disto, encontra-se em processo de submissão o artigo do tema deste trabalho, seguindo os dados abaixo:

- GOMES, S. L.; Rebouças Filho, P. P.; Medeiros, C. S. M . A new approach to estimate wind power production in wind turbines using regression to estimate the power curve and Recursive Neural Networks to predict wind speed. Energy Conversion and Management, submissão prevista para Outubro/2017.

1.4 Organização do texto

O restante desta dissertação está organizada segundo os capítulos abaixo.

O **Capítulo 2** apresenta o estado da arte das pesquisas em cada uma das etapas deste trabalho, bem como na linha de pesquisa final do mesmo.

O **Capítulo 3** apresenta a fundamentação que envolve a produção de energia eólica, bem como apresenta a formulação dos métodos computacionais utilizados para modelar a curva de potência dos aerogeradores e prever a disponibilidade de vento na região.

O **Capítulo 4** explica as etapas empregadas na abordagem adotada, como foi realizado a modelagem da curva de potência e como foi realizada a predição da velocidade do vento, o que juntos possibilitam predição da produção de energia.

O **Capítulo 5** apresenta os resultados e as discussões dos experimentos isolados para modelagem da curva de potência e da predição da velocidade dos ventos, e também integrados para predição da produção de energia.

No **Capítulo 6** estão as conclusões do estudo realizado nesta dissertação e as propostas para trabalhos futuros.

2 Estado da arte

Sabe-se que o crescimento econômico de uma nação é diretamente regulado por sua produção industrial, cujo seu desenvolvimento promove melhorias na economia (e.g. aumento do Produto Interno Bruto, PIB). Além disso, a energia elétrica serve como insumo para diversos setores de bens e serviços, tornando o mercado energético um forte influenciador em fatores econômicos nacionais (YUAN; PENG, 2017). Em países com altos índices de produção, como a China, a dependência é latente. A pesquisa realizada por Yuan e Peng (2017) exhibe uma correlação positiva entre as produções de energia e da indústria alimentícia, que é considerada crucial, especialmente em países densamente povoados. Em meio a necessidade por energia, as fontes renováveis de energia emergiram para: (i) mitigar problemas relacionados a queima de combustíveis fósseis, como redução da emissão dos gases de efeito estufa (RAHIMI et al., 2013) e (ii) reduzir os custos da energia, por meio da diversificação da matriz energética (SANTOS; HADDAD; HEWINGS, 2013).

Países que possuem fontes de energia renováveis fortemente presentes em suas matrizes energéticas demonstraram ter vantagens econômicas, como exibido por Valodka e Valodkien (2015), houve circulação monetária na economia, redução dos custos de importação de combustíveis fósseis e crescimento do PIB. Porém, dentre as fontes de energias renováveis, o GWEC (2017a) indica a energia eólica como a fonte mais promissora e tecnologicamente estabilizada. E o seu crescimento expressivo ao longo dos últimos anos possibilitou alcançar 486,8 GW de capacidade instalada no mundo, ao final de 2016 (GWEC, 2017a), e as projeções indicam que em 2030 a energia eólica será capaz de suprir até 19% da eletricidade mundial (GWEC, 2017b). No Brasil, a realidade é promissora, visto que é o líder na América Latina e está em 9º lugar dentre os países com maiores capacidades instaladas no mundo, contando com 10.74 GW (GWEC, 2017a).

Entretanto, empresários buscam investimentos factíveis, e a decisão para implantação de um parque eólico é bastante complexa, pois é baseada em uma solução de compromisso entre necessidades produtivas, interesses econômicos, políticas governamentais e impactos sócioambientais. Sovacool (2009) apresentou um estudo feito em diversos órgãos atuantes no mercado energético dos Estados Unidos, sobre as principais barreiras para inserção de energias renováveis na matriz energética. O principal argumento residia na natureza intermitente das fontes alternativas, como a eólica. Contudo, Sovacool (2009) exhibe evidências de que as fontes convencionais de energia também sofrem de variabilidade de produção e que a energia eólica quando utilizada em larga escala e de maneira descentralizada é extremamente benéfica para a matriz energética. O autor conclui que há uma barreira sócio-operacional para o crescimento da aerogeração, e que pode ser mitigada com políticas sustentáveis à difusão da energia eólica.

Para facilitar a comercialização da energia elétrica, garantir competição justa e diminuir as barreiras políticas para os empresários, a regulação econômica vem como uma ferramenta importante. No Brasil, a venda da energia elétrica é intermediada pelo governo, que estabelece leilões de compra e venda, garantindo os direitos das centrais geradoras e das concessionárias de distribuição (CCEE, 2017). Para empresas de energia eólica, a inserção em um mercado regulado é vantajosa, pois parte dos riscos relacionados a intermitência de geração são sobrepostos por vantagens, como: (i) a garantia de compra de energia elétrica por 20 anos; (ii) prazo de até 5 anos para entrega da energia contratada, podendo o empresário vender energia para o mercado livre neste período, há também (iii) carência de multas para empresários que não finalizarem parque eólicos nesse mesmo período (DALBEM; BRANDÃO; GOMES, 2014). A análise realizada por Dalbem, Brandão e Gomes (2014) demonstra que o cenário brasileiro traz garantias a longo prazo para as empresas de energia eólica, tanto que Bradshaw (2016) aponta a regulação exercida no Brasil como referência para uma relação mútua de benefícios entre órgãos de fomento, regulação, fiscalização e empresários.

Levando em conta os riscos intrínsecos a um projeto para uma usina de geração eólica, Afanasyeva et al. (2016) realiza um estudo, cujo objetivo é propor métodos para avaliar a viabilidade do investimento, a partir de estudos de sensibilidade econômica das variáveis presentes no processo de geração. Além de fatores mensuráveis, como custos de instalação, operação e manutenção e taxas de juros, são também avaliadas variáveis de natureza incertas, como velocidade média do vento, distribuição de Weibull da região e curvas de potências de cada aerogerador. Afanasyeva et al. (2016) conclui que dentre as incertezas, a (i) velocidade média do vento e a (ii) curva de potência do aerogerador são as mais importantes e possuem um alto impacto no projeto. Baseado em análises de riscos para investimentos, Rolik (2017) também enfatiza que é necessário conhecer o comportamento dos ventos da região de interesse do parque eólico, com pelo menos 1 ano de monitoramento. Mediante tal importância, o autor sugere que a escolha da turbina eólica deve ser feita de maneira inteligente e harmonizada com o parque eólico.

Visto que a natureza incerta do vento promove variabilidade de potência na rede elétrica de um parque eólico (KATZENSTEIN; APT, 2012), esse tem sido objeto de estudos que favorecem a energia eólica. Katzenstein e Apt (2012) analisam os impactos no custo final da energia elétrica, à luz da variabilidade na potência de parques eólicos. Os autores compilaram dados de produção de 20 parques eólicos e dados do preço da energia e constataram variabilidade nos preços de até 14 \$/MWh, que podem ser reduzidos para 3,16 \$/MWh mediante o aumento do fator de capacidade de um parque eólico. Kiviluoma et al. (2015) atualizam o comportamento da variação de potência em diferentes regiões e demonstram que mudanças rápidas nas condições locais do vento causam flutuações de potência na ordem de 10% a 30%. Por essas características, as preocupações de viabilidade econômica de uma usina eólica são complexas e particulares de cada região, dessa forma

os estudos visam promover métodos para maximizar a potência extraída de um parque eólico.

As pesquisas realizadas na literatura exibiram que há diferentes técnicas para maximizar a potência de um parque eólico. Há métodos que buscam otimizações de *layout*, como os estudados por [Patel et al. \(2017\)](#), [Parada et al. \(2017\)](#), [Feng e Shen \(2017\)](#), porém são restritos a parques ainda em projetos, não podendo ser aplicados a parques já operantes. Entretanto, [Serrano González et al. \(2015\)](#) exhibe uma abordagem diferente, pois reconhece que para atingir máxima potência em um parque não significa que todas as turbinas eólica devam operar em regime nominal, pois as interações aerodinâmicas entre as turbinas influenciam na produção total do parque eólico. O autor sugere um algoritmo para otimização, que opere individualmente em cada turbina eólica. Contudo, ainda há poucas estratégias como a de [Serrano González et al. \(2015\)](#), que visem otimizar a energia elétrica produzida de um parque em operação.

A revisão bibliográfica evidenciou que todos os trabalhos que visam estimar, mensurar ou otimizar a potência elétrica produzida por um parque eólico, dependem de valores ou medições das velocidades do vento na região de interesse e ainda, das curvas de potências dos aerogeradores instalados. Desta forma, na Seção 2.1 são apresentados os métodos encontrados na literatura para previsão da velocidade do vento, discutindo suas aplicabilidades. Na Seção 2.2 exibem-se os métodos que têm sido utilizados para a regressão da curva de potência de aerogeradores. Na Seção 2.3 discutem-se as implicações em termos produtivos. E, por fim, as contribuições desta pesquisa são descritas na Seção 2.4.

2.1 Previsão da velocidade do vento

Ao longo dos anos, pesquisadores esforçam-se para avaliar impactos da geração eólica nas operações e custos dos sistemas elétricos. [Holttinen \(2005\)](#), por exemplo, exhibe em sua pesquisa uma estimativa do aumento da quantidade de recursos auxiliares (e.g. ativação de usinas termo-elétricas) que são disponibilizados mediante variações na produção da usinas eólicas nos países Nórdicos. [Ummels et al. \(2006\)](#) apresenta o desajuste no balanço energético geração/carga e as implicações nos sistemas elétricos interligados à usinas eólicas na Holanda. Baseada nessas variações, órgãos como a [GE \(2008\)](#), criaram manuais para modelar quantidade de serviços adicionais. Nestas pesquisas fica claro a importância da predição das condições de vento, pois todas utilizam dados temporais para modelar e prever variações no regime de ventos e correlacionar com variações das cargas elétricas adicionadas a rede.

Dessa forma, o primeiro passo para se determinar a potência de um parque eólico é modelar o comportamento (i.e. velocidade) do vento ([ZOLFAGHARI; RIAHY; ABEDI,](#)

2015). Há dois métodos clássicos e consolidados para a modelagem das condições de vento, os que assumem o comportamento do vento de acordo com distribuições estatísticas, como a de Weibull (CONRADSEN; NIELSEN; PRAHM, 1984) e métodos baseados em séries temporais (BROWN; KATZ; MURPHY, 1984). Contudo, há destaques para os novos métodos, principalmente baseados em técnicas de inteligência artificial (LEI et al., 2009), e autores acreditam que se sobrepõem ao métodos estatísticos clássicos (LAHOUAR; Ben Hadj Slama, 2017).

Yesilbudak, Sagioglu e Colak (2013) utilizam o clássico algoritmo do k-vizinhos mais próximos (k-NN) para realizar previsões de curto prazo (e.g. 10 minutos) da velocidade do vento. Os autores convencionam as diferentes velocidades de ventos como classes distintas e utilizam as métricas de distância Euclidiana, Manhattan e Minkowski como medidas de dissimilaridades para o método k-NN. As desvantagens na utilização deste método está no elevado custo computacional, pois um elevado número de amostras no banco de dado, pode tornar seu uso impraticável para estimativas em tempo real. Os autores destacam também a sensibilidade a ruídos nos dados, tornando-o impreciso para previsões acima de 10 minutos. Encontrou-se, também, na literatura a utilização das florestas aleatórias, porém demonstraram-se eficazes para previsões de apenas 1 hora adiante (LAHOUAR; Ben Hadj Slama, 2017).

Há um destaque para as redes neurais, que tem-se mostrado promissoras e já afirma-se que são capazes de fornecer informações de vento sem conhecimentos de detalhes topográficos ou meteorológicos (LEI et al., 2009). Velo, López e Maseda (2014) utilizam uma rede Perceptron Multi-camadas (do inglês *Multi-layer Perceptron* - MLP) para estimar a velocidade média anual do vento em um local onde não há estação meteorológica disponível para medir a velocidade do vento. Foram utilizado, como entrada para a rede neural, dados de velocidade e direção do vento de estações meteorológicas próximas ao local de interesse. A metodologia utilizada pelos autores exibiu que para obter uma aceitável capacidade de generalização foi necessário utilizar dados de 60 dias de observações, e os resultados encontrados obtiveram erros menores que 6%.

Apesar disto, arquiteturas diferentes de redes neurais padrões também tem sido expostas para análises de séries temporais e ganharam espaço na comunidade científica nos últimos anos. O destaque são as redes do tipo NAR (do inglês *Nonlinear Autoregressive*) e suas aplicações em sinais temporais demonstraram-se efetivas e vantajosas, perante as redes neurais recursivas tradicionais (MENEZES; BARRETO, 2008). Baseada na necessidade de previsão de vento para aplicações eólicas e na imprecisão de previsões a longo prazo, Azad, Mekhilef e Ganapathy (2014) propuseram a utilização da rede NAR para previsões de vento na região da Malásia e obtiveram resultados promissores: erros absolutos nas previsões de velocidade do vento de 0.17 m/s para previsões de médias mensais, 0.64 m/s para previsões de 30 dias adiante e 0.8 m/s para previsões de 1 ano adiante. Com isso, o

autor demonstra que a rede NAR é uma ferramenta adequada para previsão da velocidade do vento.

Baseado nas pesquisas na literatura, o presente trabalho escolheu a rede NAR como a ferramenta para predição da velocidade dos ventos, nos entornos da turbina eólica, situada no litoral do estado do Ceará.

2.2 Regressão da curva de potência de um aerogerador

Estimar a produção anual de energia é uma das mais importantes aplicações da curva de potência do aerogerador (TRIVELLATO; BATTISTI; MIORI, 2012). A importância de possuir modelos representativos das curvas de potência é destacada por Lydia et al. (2013b), pois esses refletem a performance do equipamento e até indicam anomalias no funcionamento. Desde que haja uma predição da velocidade do vento é possível, também, trabalhar de maneira preditiva, provendo informações futuras de disponibilidade energética (LYDIA et al., 2013b). Dessa forma, o passo seguinte para estimação da potência produzida por um parque eólico é conhecer a curva de potência dos aerogeradores instalados naquele sítio.

Em sua pesquisa, Trivellato, Battisti e Miori (2012) objetivam validar a potência anual de um parque eólico em uma região da Itália, para tal realizou medições de potência em uma turbina de 12 kW e de velocidades do vento em torno da mesma, por um período de um ano. Os autores propõem um método analítico para estimar o modelo da curva de potência a partir dos dados e comparam com a curva disponibilizada pelo fabricante da turbina. Os resultados indicaram que o modelo real, estimado por Trivellato, Battisti e Miori (2012), possui um *déficit* de produção de 10.2%, levando a conclusão de que a curva estipulada pelo fabricante é uma representação otimista do processo. Mais tarde, Zolfaghari, Riahy e Abedi (2015) indicaram em seu estudo que a potência real de saída do aerogerador nem sempre acompanha o comportamento da curva teórica, proposta pelo fabricante. Segundo Zolfaghari, Riahy e Abedi (2015) o motivo da imprecisão da curva teórica é o fato de ter sido estimada em ensaio laboratoriais, que controlam a direção e velocidade do vento, e umidade relativa do ar.

Portanto, é relevante estimar a curva de potência de um aerogerador a partir de dados, visto que o resultado proverá indicativos reais de potência instantânea gerada pela máquina. De encontro à esta necessidade estão os métodos de regressão. Lydia et al. (2014) exibiram em sua revisão bibliográfica os mais comuns métodos utilizados para modelagem de curvas de potência. Os autores classificam os métodos em basicamente dois tipos: (i) os métodos paramétricos, que baseiam-se em resolver modelos matemáticos que expliquem o comportamento do sistema. Como exemplos, Lydia et al. (2014) reportaram o uso de técnicas de regressão linear e polinomial, modelos probabilísticos e regressão logística. Os

segundo tipo de métodos, chamados de (ii) não paramétricos, visam encontrar relações entre entradas e saídas de um conjunto de dados, não atentando a um modelo matemático específico. Dentre estas, há aplicações dos modelos de cópula, redes neurais e lógicas fuzzy (LYDIA et al., 2014).

Em seu trabalho, Lydia et al. (2013b) compararam os métodos de regressão linear por Mínimos Quadrados (MQ) e regressão logística para estimar a curva de potência. Contudo a regressão linear aplicada por partes obteve melhores resultados que a regressão logística. Shokrzadeh, Jafari Jozani e Bibeau (2014) destacam que a regressão polinomial simples é suscetível a ruídos e propõe a utilização de modelos polinomiais interpolados e obtém resultados satisfatórios. Taslimi-Renani et al. (2016) utiliza uma variação a regressão logística em sua pesquisa e obtém resultados superiores a regressão linear por mínimos quadrados. Mediante as revisões bibliográficas, o presente trabalho escolheu utilizar o método paramétrico de regressão linear e polinomial, devido à sua simplicidade, e a regressão logística devido à sua característica não linear.

Em sua pesquisa Panahi, Deilami e Masoum (2015) comparam a performance, por meio da análise da Raiz Quadrada do Erro Quadrático Médio (RMSE) e do erro médio absoluto, de métodos paramétricos e não paramétricos para modelagem da curva de potência. A regressão polinomial robusta obteve menor erro médio, sobrepondo os resultados das regressões linear e polinomial. Contudo, Panahi, Deilami e Masoum (2015) propuseram uma rede do tipo MLP, de duas camadas, e obtiveram resultados similares à regressão robusta. Os autores indicam as redes neurais artificiais como uma ferramenta promissora para suas análises, porém, deve-se haver uma preocupação em buscar a estrutura ótima para cada problema específico. Entretanto, Panahi, Deilami e Masoum (2015) não justificam a escolha da arquitetura ou sequer comparam com outros métodos de mesma categoria.

Pelletier, Masson e Tahan (2016) propuseram o uso de uma rede MLP, porém além de realizar uma regressão simples entre velocidade do vento e potência, os autores acreditam que utilizar outras informações (e.g. densidade do ar e intensidade de turbulência) como entrada da rede ajudará tornar o modelo mais representativo. Os resultados obtidos foram melhores que os de outros modelos paramétricos e não paramétricos, provando a capacidade das redes neurais funcionarem como aproximadores universais de funções.

Contudo, é sabido que a principal desvantagem da rede MLP reside no árduo e demorado treinamento. Portanto, pesquisadores propuseram alternativas estruturais ao processo de retropropagação do erro para o treinamento da MLP, com o intuito de torná-lo mais eficaz. Miller, Glanz e Kraft (1990) expõem a ineficiência do algoritmo da retropropagação em aplicações que exigem aprendizado em tempo real, e com isso propuseram uma abordagem diferente. Anos posteriores, Huang, Zhu e Siew (2006) propuseram o modelo atual da rede neural chamada de Máquina de Aprendizado Extremo (do inglês *Extreme*

Learning Machine - ELM), baseada em projeção aleatória, para parte dos parâmetros da rede, e na técnica dos mínimos quadrados para estimar a outra parte. Huang, Zhu e Siew (2006) demonstraram a vantagem da ELM sobre algoritmos clássicos como a MLP e as Máquinas de Vetores Suporte (SVM): rápido treinamento sem perdas na capacidade de generalização do modelo, podendo ser utilizado também para problemas de regressão.

A utilização da ELM tem sido reportada na literatura como solução para o problemas de regressão, inclusive previsão de séries temporais com aprendizado em tempo real (HUANG et al., 2012; WANG; HU, 2015). Portanto, o presente trabalho escolheu a ELM como o método não paramétrico a ser utilizado para regressão da curva de potência do aerogerador. Havendo agora a estimativa da velocidade de vento local e da curva de potência real de um aerogerador a informação da produção futura de energia torna-se um fator crucial para proporcionar um gerenciamento eficiente do parque eólico.

2.3 Impactos na produção de energia

A expansão do setor eólico deve estar alinhado com as necessidade expansivas e produtivas da rede elétrica, é isso que Shi, Fan e He (2017) destacam em sua pesquisa. O estudo foi realizado na China, e exibiu que mesmo o país possuindo a maior capacidade eólica instalada do mundo (168.7 GW), a participação da energia eólica na matriz energética sofreu reduções consecutivas nos últimos anos, chegando a um total de energia perdida de aproximadamente 70 bilhões de kWh (SHI; FAN; HE, 2017). A realidade na China é crítica, pois é um país desamente povoado, montanhoso e não possui condições propícias para o desenvolvimento da tecnologia. Shi, Fan e He (2017) relatam que não há um gerenciamento adequado entre os locais aonde está havendo geração, linhas de transmissão e localização da demanda. E estes fatores ainda são agravados pela intermitência dos ventos, cujo autor afirma ter característica voláteis que contribuem para a imprecisão no cálculo quantidade de energia disponível. Com o intuito de avaliar a eficiência na utilização do parque eólico Shi, Fan e He (2017) propõe um índice multivariável, dentre essas, o autor enfatiza a velocidade local do vento, a disponibilidade e a geração efetiva da turbina eólica como variáveis importantes.

Os estudos realizados por Shi, Fan e He (2017) evidenciaram que o conhecimento das (i) condições locais do vento e (ii) produção real do parque eólico podem auxiliar o gerenciamento da programação da quantidade de energia elétrica fornecida à rede, mitigando os problemas da intermitência de geração. Além disso, se esta informação for fidedigna servirá para solidificar a presença da energia eólica na matriz energética.

Zolfaghari, Riahy e Abedi (2015) propõe uma metodologia para validação da quantidade de potência produzida em um parque eólico, baseado em dados individuais de cada aerogerador. Os autores analisam 31 turbinas situadas em um parque eólico e

estimam curvas de potência individuais, porém assumem uma distribuição média de vento a cada ponto do parque. A compilação de um ano de dados revelou que o real fator de capacidade do parque eólico é aproximadamente 10% menor que o fator de capacidade estimado com as curvas de potência fornecidas pelos fabricantes, ratificando a hipótese da curva de potência do aerogerador ser única para cada região. É baseado em constatações como essas que [Serrano González et al. \(2015\)](#) hipotetiza que a produção total do parque eólico pode ser maximizada se cada aerogerador tiver seu sistema de controle individual e baseado nos dados de vento e potência coletados em tempo real pelo equipamento.

No estudo de caso teórico apresentado por [Serrano González et al. \(2015\)](#) há ganhos em produção de energia de 27,3 GWh em um período de ano, se for utilizado um controle otimizado e individual por turbinas. Contudo, a pesquisa exibida pelo autor utiliza como referência a velocidade do vento proveniente da distribuição da Weibull. Tal distribuição utiliza médias mensais de velocidade, então acredita-se que utilizar valores instantâneos da velocidade de vento promoverá resultados acima do previsto por [Serrano González et al. \(2015\)](#).

De olho para na produção energética brasileira, onde aproximadamente 65% da geração é proveniente de usinas hidroelétricas ([ANEEL, 2017](#)), há preocupações em promover diversificação na matriz energética ([OLIVEIRA; ZULANAS; KASHIWAGI, 2016](#)). As constantes secas causaram problemas no sistema de energia brasileiro, e o estudo feito por [Oliveira, Zulas e Kashiwagi \(2016\)](#) exhibe que o Brasil tem experienciado um aumento anual no consumo de energia de 3.3%, enquanto que a representatividade das hidroelétricas caíram de 71%, em 2011, para 65%, em 2017. Isso obriga os operadores dos sistema elétrico a comprarem energia das termoeletricas, que em geral são 23.7% mais caras que plantas hidroelétricas, e isso implica no aumento dos preços da energia ([OLIVEIRA; ZULANAS; KASHIWAGI, 2016](#)).

A região do Nordeste brasileiro é extremamente promissora para a aerogeração, tanto que é detentora de 81,7% da capacidade instalada no país ([GWEC, 2017b](#)). Visando analisar a viabilidade de integrações, em grande escala, de parque eólicos a rede elétrica nordestina, [Jong et al. \(2016\)](#) exhibe que o custo nivelado da energia poderá reduzir de 46 à 52% até 2020, desde que 100% da demanda do sistema elétrico nordestino seja atendida. Os benefícios seriam uma redução de 3.3 bilhões de dólares nos custos com energia e redução na emissão de 34 milhões toneladas de carbono.

Em suma, as necessidades por fontes alternativas de energia possibilitou a difusão da energia eólica, porém suas peculiaridades, como intermitência na geração, devem ser contornadas. Há mobilizações acadêmicas em torno de soluções que contribuam para construir um sistema elétrico sólido, sustentável e diversificado, e que possa provê energia elétrica ao menor custo possível.

2.4 Contribuições da pesquisa

A revisão bibliográfica realizada possibilitou identificar o espaço no qual a presente pesquisa está inserida, pois contribui com embasamentos teóricos e tendências de estudos atuais. Mediante isso, os objetivos foram traçados de modo que as contribuições desse trabalho são:

- O trabalho consiste em uma análise local para a região do Ceará. E a predição dos ventos é feita com dados reais, assim como a estimação da curva de potência do aerogerador. Ambas características tornam o trabalho inédito para a região;
- A escolha de utilizar métodos paramétricos e não paramétricos para realizar a regressão da curva de potência garante robustez nas análises realizadas. Combinado a predição da velocidade do vento, o resultado é a proposição de um método consistente para avaliação de produtividade em usinas eólicas locais;
- A análise dos dados proposta possibilita o melhor gerenciamento de parques eólicos que já instalados da seguinte forma: (i) efetividade na programação do calendário de manutenção; (ii) possibilita estimativa, a curto e médio prazo, da quantidade de energia que estará disponível para a concessionária e (iii) viabiliza a análise real do impacto na produção referente aos dias que o equipamento esteve parado, ou por motivos de manutenções ou por solicitações da concessionária;
- Por fim, a solução proposta será disponibilizada para empresários locais trabalharem e gerenciarem seus parques eólicos com maior efetividade.

3 Fundamentação Teórica

Neste capítulo são introduzidos conceitos sobre a energia eólica, bem como apresentados os métodos computacionais utilizados para alcançar os objetivos geral e específicos desta dissertação.

3.1 Energia Eólica

A energia eólica entrou na matriz energética brasileira em 1992, com a instalação de uma turbina de 75 kW na Ilha de Fernando de Noronha (PE). Resultado da parceria entre o grupo de energia eólica da Universidade Federal de Pernambuco (UFPE) e a Companhia Energética de Pernambuco (CELPE), através de financiamento do Instituto de Pesquisas Dinamarquês Folkecenter ([REIS, 2013](#)).


A energia eólica é uma das formas em que a energia solar se manifesta. O vento é o movimento das massas de ar na atmosfera devido a incidência desigual de radiação solar, aos movimentos da Terra e à influência dos efeitos térmicos. As diferenças de temperatura do ar, devido o aquecimento desigual da Terra por meio da radiação solar, criam zonas com pressões atmosféricas diferentes, movendo as massas de ar das zonas de alta pressão para as zonas de baixa pressão atmosférica, resultando nos ventos de circulação global.

As regiões tropicais são mais aquecidas que as regiões polares devido ao raios solares incidirem nas regiões tropicais quase que perpendicularmente. Por este motivo, o ar quente, de maior pressão, das regiões tropicais tende a se deslocar para as regiões polares, de menor pressão. Isso faz com que os ventos frios dos polos circulem para o Equador, substituindo o ar quente que subiu dos trópicos.

O movimento de rotação e translação da Terra também afetam esses ventos planetários. Devido ao eixo da Terra estar a uma inclinação de $23,5^\circ$ em relação ao plano de sua órbita em torno do Sol a distribuição de radiação na superfície da Terra apresenta variações durante o ano. Por consequência, o recurso eólico apresenta características sazonais como variações na velocidade, direção e duração dos ventos. Na Figura 4 é ilustrado o comportamento dos ventos de circulação global que cobrem todo o planeta.

Além dos ventos de circulação global, há também os modelos de vento locais. Nos litorais existe a circulação das brisas marítimas e terrestres. Elas são resultado das diferentes capacidades da terra e do mar em absorver calor. A terra tem maior capacidade que o mar de refletir os raios solares, por este motivo, durante o dia, a temperatura do ar sobre o continente é maior que a do mar. Isso faz com que uma corrente de ar movimenta-se do mar para o continente, formando a brisa marítima. À noite esse cenário se inverte. A

Figura 4 – Comportamento dos ventos de circulação global que cobrem todo o planeta.



Fonte: [CEPEL \(2001\)](#).

terra perde calor mais rápido que o mar, assim, a corrente de ar sopra da terra para o mar, formando a brisa terrestre. Estes fenômenos são de grande importância para a geração de energia eólica. Por este motivo, grande parte dos parques eólicos estão instalados em regiões litorâneas.

As características geográficas de uma região também influenciam o comportamento dos ventos. As informações necessárias para o levantamento das condições regionais podem ser obtidas a partir de mapas topográficos, imagens aéreas, dados de satélites e visitas ao local de interesse.


3.2 Sistema de conversão de energia eólica - Aerogeradores

O aerogerador é o sistema responsável por converter a energia cinética, contida na massa de ar que passa por ele, em energia elétrica ([THOMAS; CHERIYAN, 2012](#)). A energia cinética disponível no vento está associada ao movimento das massas de ar e é expressa na mecânica clássica pela Equação 3.1:

$$E = \frac{1}{2} M v^2, \quad (3.1)$$

onde, E é a energia disponível no vento, M é a massa do fluxo de ar e v , a velocidade do vento. A potência instantânea que passa pelo aerogerador é limitada pela área de varredura

Figura 5 – Componentes de um aerogerador de eixo horizontal



Fonte: [Dutra \(2008\)](#).

da turbina. Esta potência é calculada utilizando a Equação 3.2:

$$P_w = \frac{1}{2} \rho A v^3, \quad (3.2)$$

em que P_w (W) é a potencia instantânea disponível, A (m^2) é a área varrida pela turbina, ρ (kg/m^3) e v (m/s) são, respectivamente, a velocidade e a densidade da massa de ar que passa transversalmente pela turbina.


Embora existam várias maneiras de categorizar as turbinas eólicas, elas são classificadas principalmente com base em seu eixo de rotação em: máquinas de eixos horizontais e máquinas de eixos verticais. Os rotores de eixo horizontal são os mais comuns, e grande parte da experiência mundial está voltada para a sua utilização.

As principais configurações de um aerogerador de eixo horizontal podem ser observadas na Figura 5. Os aerogeradores são compostos, basicamente, por três partes principais: turbina, transmissão e gerador. A turbina eólica capta parte da energia cinética do vento que passa através da área varrida pelo rotor e converte em energia mecânica. Em seguida, essa energia mecânica é transmitida para o gerador através do sistema de transmissão, que muitas vezes apresenta uma caixa de engrenagens para aumentar a velocidade de rotação no eixo do gerador. Por fim, essa energia mecânica é convertida em energia elétrica pelo gerador.

3.2.1 Coeficiente de potência C_p

O aerogerador não é capaz de converter em energia elétrica toda a energia cinética da massa de ar que passa por ele. Como pode ser visto na Figura 6, o Sistema de Conversão de Energia Eólica (SCEE) passa por três etapas de transformação de energia: Energia cinética para mecânica (P_m)(turbina), Energia mecânica para mecânica (P_t)(caixa de engrenagens) e em seguida de mecânica para elétrica (P_e)(gerador) para cada etapa do processo existe uma perda de energia relacionada (MAHELA; SHAIK, 2016).

Figura 6 – Sistema de Conversão de Energia Eólica.



Fonte: Thapar, Agnihotri e Sethi (2011)

O coeficiente de potência C_p pode ser definido como a fração da potência eólica disponível extraída pelas pás do rotor. O C_p representa a eficiência aerodinâmica do SCEE (BURTON et al., 2001) e pode ser calculado pela Equação 3.3:

$$C_p = \frac{P_m}{P_w}, \quad (3.3)$$

em que P_w corresponde a potência disponível no vento e P_m , a potência absorvida pela turbina.

O valor máximo teórico de C_p é conhecido como o limite de Betz. Este limite foi calculado pelo físico alemão Albert Betz que definiu que uma turbina nunca pode extrair mais do que 59,3% da potência disponível em uma corrente de ar. Na prática, rotores de turbinas eólicas têm valores de rendimento na faixa de 25-45% (BURTON et al., 2001).

O coeficiente de potência $C_p(\lambda, \beta)$ depende das características da turbina. λ é a razão entre a velocidade tangencial da ponta da pá e a velocidade do vento incidente, como é demonstrado na Equação 3.4, onde, ω_r é a velocidade angular, r é o raio da turbina e v_{vento} a velocidade do vento incidente. β é o ângulo de passo das pás (*pitch*) da turbina. Na literatura, há várias equações que descrevem o comportamento de C_p , cujos termos variam para cada turbina eólica. Entretanto, a maioria destas tem como variáveis β e λ .

$$\lambda = \omega_t \cdot r / v_{vento} \quad (3.4)$$

Segundo Heier (2003), o C_p é descrito pelas equações 3.5 e 3.6.

$$C_p = \alpha_1 \left(\frac{\alpha_2}{\lambda_i} - \alpha_3 \beta - \alpha_4 \beta^{\alpha_5} - \alpha_6 \right) e^{\frac{-\alpha_7}{\lambda_i}} + \alpha_8 \lambda \quad (3.5)$$

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + \alpha_9 \beta} - \frac{\alpha_{10}}{\beta^3 + 1} \quad (3.6)$$


Podem ser encontrados na literatura diversos valores para as constantes α_1 a α_{10} usadas no modelo da turbina eólica, sendo que os mais citados (e utilizados em *softwares* de simulação) são apresentados na Tabela 2. Em Slootweg (2003) são apresentados valores aprimorados dos coeficientes utilizados em Heier (2003), de forma a representar mais precisamente a aerodinâmica de turbinas eólicas modernas. Por este motivo, optou-se pela utilização destas constantes.

Tabela 2 – Constante de Aproximação.

Ref.	α_1	α_2	α_3	α_4	α_5	α_6	α_7	α_8	α_9	α_{10}
Heier (2003)	0,5	116	0,4	0	-	5	21	-	80×10^{-3}	35×10^{-3}
Slootweg (2003)	0,73	151	0,58	2×10^{-3}	2,14	13,2	18,4	-	-20×10^{-3}	-3×10^{-3}

Na Figura 7 são ilustradas as curvas de $C_p \times \lambda$ para as constantes de Slootweg (2003) e β variando de 0 a 20°, com passo de 1°, onde a curva com maiores valores de C_p corresponde a $\beta = 0^\circ$. Ainda, são destacados pontos de $C_p(\text{máx})$ para cada curva de C_p , a partir dos quais se tem que $C_p(\text{máx})$ diminui à medida que β aumenta.

Figura 7 – Curvas de $C_p \times \lambda$ para diversos valores de β .



Fonte: Karthikeya e Schutt (2014).

Em aerogeradores de grande porte é utilizado a movimentação do ângulo de passo das pás (*pitch*) para controle da produtividade do aerogerador. Sabendo disto, deve-se

acrescentar C_p na equação 3.2.

$$P_m = \frac{1}{2} \rho A v^3 C_p \quad (3.7)$$

3.3 Curva de Potência

Como é apresentado na Equação 3.7 a potência energética disponível no vento é proporcional à velocidade do vento ao cubo, ou seja, pequenas variações da velocidade do vento implicam em grandes variações de potência. Por este motivo, para o dimensionamento de parques eólicos é necessário que os dados coletados sejam confiáveis e que se tenha um bom conhecimento das leis que governam o comportamento do vento e suas variações. Dados de má qualidade resultam no dimensionamento inadequado do sistema eólico, nos erros de estimativa de produção de energia e, conseqüentemente, produz prejuízo aos investidores.

A potência fornecida por uma aerogerador é normalmente representada através de sua curva de potência, onde é estabelecida a relação entre a velocidade do vento que incide pela turbina e a potência gerada pelo gerador. A Figura 8 corresponde à um exemplo da curva de potência de um aerogerador de velocidade variável real.

Para os aerogeradores de velocidade variável esta relação pode ser expressa da seguinte forma (CARRILLO et al., 2013):


$$P(v) = \begin{cases} 0 & : v < v_{ci} \text{ or } v > v_{co} \\ q(v) & : v_{ci} \leq v < v_r \\ P_r & : v_r \leq v \leq v_{co} \end{cases} \quad (3.8)$$

em que $p(v)$ é a potência elétrica; v_{ci} é a velocidade de conexão (*cut-in*), onde o aerogerador começa a gerar energia; v_{co} é a velocidade de corte (*cut-out*), onde a turbina eólica é desconectada por medida de segurança; v_r é a velocidade nominal (*rated wind speed*); P_r é a potência nominal do aerogerador.

3.4 Controle de Aerogeradores

O sistema de controle de cada aerogerador tem como objetivo principal a maximização da produção de energia elétrica, a operação contínua e a segura do SCIE. A Figura 9 é um fluxograma geral de operação de um aerogerador (KARTHIKEYA; SCHUTT, 2014). Se a velocidade do vento v for maior do que v_{cut-in} (velocidade mínima para que a turbina comece a fornecer energia útil), é dada partida no sistema (fazendo as velocidades de rotação do eixo da turbina, ω_t , ser maior que um dado valor mínimo ω_0), que entra em


Figura 8 – Exemplo da curva de potência de uma aerogerador de velocidade variável real.



Fonte: Autor.

operação normal, podendo operar, basicamente, nos modos de otimização e limitação de potência.

Figura 9 – Fluxograma do sistema de controle um aerogerador.

Fonte: Adaptado de [Karthikeya e Schutt \(2014\)](#).


Para velocidades de rotação do eixo da turbina ω_t abaixo da nominal $\omega_{t(nom)}$, de forma a se obter a máxima extração de potência do vento, busca-se operar a turbina no ponto $(\lambda_{otm}, C_{p(max)})$, com $\beta = 0^\circ$. Nessa situação a velocidade de rotação varia de forma linear com a velocidade do vento. Atingida a velocidade de rotação nominal, esta é mantida

constante e, como consequência, o C_p diminui à medida que a velocidade aumenta, dado que o λ não mais permanece em seu valor λ_{otm} , de acordo com a Equação 3.4.

Atingida a potência nominal da turbina P_r , o ângulo de passo é aumentado com a velocidade do vento de forma a manter a potência da turbina em seu valor nominal. A atuação do sistema de controle garante que a turbina apresente duas possíveis curvas de potência, conforme mostrado nas Figuras 11(a) e 11(b). As quatro regiões principais da curva de potência são:

- I Região inoperante: na qual a velocidade de vento ainda não atingiu v_{cut-in} , apresentando saída igual a zero;
- II Região de otimização de potência: estende-se de v_{cut-in} até v_{nom} (velocidade em que a potência nominal da turbina é alcançada), apresentando crescimento rápido até a máquina atingir a potência de saída nominal;
- III Região de limitação de potência: apresenta saída constante, até que $v_{cut-out}$ (velocidade máxima do vento em que se permite que haja entrega de energia, em geral limitada por questões técnicas e restrições de segurança) é alcançada; e
- IV Região de corte: na qual a velocidade de vento é superior a $v_{cut-out}$, apresentando saída igual a zero.

Figura 10 – Regiões da curva de potência de um aerogerador de velocidade variável.



Fonte: Adaptada de [Karthikeya e Schutt \(2014\)](#).

Em turbinas de grande porte, devido ao fato da turbina alcançar a velocidade nominal do gerador ω_g antes da potência nominal, há outra região intermediária às regiões II e III, sendo chamada de região II 1/2, como mostrado na Figura 11(b). Essa suavização do aumento da potência de saída da turbina com o aumento da velocidade do vento se deve à redução do coeficiente de potência devido ao aumento de λ (que não mais permanece em seu valor λ_{otm} , como na região II), que ocorre devido à manutenção da velocidade de rotação do eixo turbina/gerador constante.


3.5 Métodos de Regressão

A regressão é a etapa que define um modelo matemático de um problema. Um modelo matemático é a descrição matemática, por uma função ou equação, de um fenômeno do mundo real, neste caso, a produção de energia em um aerogerador. O propósito do modelo é entender o fenômeno e fazer previsões sobre o seu comportamento (STEWART, 2010).

Um modelo matemático nunca é uma representação perfeita de uma situação física. Um bom modelo matemático simplifica a realidade ao máximo para facilitar os cálculos matemáticos, mantendo a precisão suficiente para uma conclusão adequada (STEWART, 2010).

São ilustradas na Figura 11 as etapas de um processo de modelagem matemática baseado em equações fundamentais. A primeira etapa é identificar as variáveis e formular hipóteses que simplifiquem o problema para torná-lo matematicamente tratável. A segunda etapa é, através de análise matemática, chegar a conclusões que possam ser interpretadas. Em seguida, interpretar as conclusões matemáticas com as informações sobre o fenômeno original para poder explicar o fenômeno e fazer previsões. O modelo matemático encontrado é, então, testado para analisar o seu grau de representabilidade (STEWART, 2010).

Figura 11 – Processo de modelagem baseado em equações fundamentais.



Fonte: Stewart (2010).

O método de modelagem com base nas equações fundamentais, geralmente é mais complexo, pois necessita de um conhecimento amplo da situação física dos recursos matemáticos para relacionar as variáveis que envolvem o comportamento do sistema a ser modelado (THAPAR; AGNIHOTRI; SETHI, 2011; STEWART, 2010).

3.6 Reconhecimento de Padrões

Reconhecimento de Padrões é um campo de estudo interdisciplinar que abrange desenvolvimentos nas áreas de estatística, engenharia, inteligência artificial, ciência da computação, psicologia, fisiologia, entre outros. O seu objetivo é a classificação de objetos em categorias ou classes. Os objetos podem ser sinais em forma de imagens, ondas sonoras, radiação ou qualquer tipo de medida que necessite ser classificada. Reconhecimento de Padrões é utilizado em um grande número de aplicações, que vão desde o reconhecimento automático de caracteres e diagnóstico médico à mineração de dados como: análise de vendas, consumo e análise de transações de cartão de crédito. Este campo têm atraído um considerável esforço em pesquisa, com muitos métodos desenvolvidos e grandes avanços (WEBB, 2002).

A aplicação de Reconhecimento de Padrões consiste em caracterizar matematicamente o sistema dinâmico desconhecido de uma forma que o modelo matemático encontrado produza o menor erro em comparação a saída do sistema real (CAVALCANTI NETO, 2013). A tensão elétrica das tomadas residenciais do Ceará, por exemplo, apresenta um padrão bem definido. Este formato de onda é matematicamente modelado por uma função senoidal com frequência de $60Hz$ e valor de pico igual a $220\sqrt{2}$.

3.6.1 Perceptron Simples


O Perceptron Simples (PS) é considerado a primeira arquitetura neural inventada. Foi criado para emular a estrutura e a funcionalidade de um neurônio real, onde os detritos são emulados por conexões, as sinapses por pesos e o axônio pela saída do neurônio artificial, conforme ilustrado na Figura 12. Este neurônio artificial é composto por um vetor de entrada $\mathbf{x}(t)$

$$\mathbf{x}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_n(t) \end{bmatrix} \quad (3.9)$$

e para cada elemento do vetor $x(t)$ tem-se um respectivo peso, formando assim o vetor $\mathbf{w}$. $x_0 = -1$ e w_0 é uma constante chamada bias.

$$\mathbf{w} = \begin{bmatrix} w_0 \\ w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} \quad (3.10)$$

Figura 12 – Perceptron Simples



Para cada vetor de entrada $x(t)$ o perceptron gera uma saída $u(t)$ que, em seguida, passa por uma função de ativação φ . A função de ativação tem o papel de mudar a amplitude do intervalo de saída para um valor finito. Geralmente são utilizadas como função de ativação as funções degrau, pseudo-linear, logística, hiperbólica ou gaussiana (GOMES, 2014). A saída de um perceptron pode ser calculada a partir da Equação 3.11:

$$y(i) = \varphi \left(\sum_{i=0}^n x_i w_i \right). \quad (3.11)$$

3.6.2 Mínimos Quadrados

O método dos Mínimos Quadrados (MQ) é uma técnica que ajusta os parâmetros do modelo matemático através de regressão matemática. O resíduo r_i é a diferença entre os valores previstos pelo modelo matemático $P_e(i)$ e os dados reais $P_a(i)$ (Equação 3.12). O objetivo é encontrar os parâmetros do modelo matemático que resultem no menor valor de soma dos quadrados dos resíduos (LYDIA et al., 2013a; KUSIAK; ZHENG; SONG, 2009a).

$$S = \sum_{i=1}^m r_i^2 = \sum_{i=1}^m (P_a(i) - P_e(i))^2 \quad (3.12)$$

$$\mathbf{S} = \mathbf{E}^T \mathbf{E} \quad (3.13)$$

Considerando que a função modelada é polinomial como a Equação 4.3, pode ser

reescrita no formato matricial

$$\mathbf{P} = \mathbf{B} \cdot \mathbf{V} + \mathbf{E} \quad (3.14)$$

onde o vetor P são os valores de saída para cada valor do vetor V , que correspondem ao valor de entrada. O vetor B corresponde aos coeficientes do polinômio e E ao vetor de erros.

A partir da Equação 3.14, são utilizadas operações matemáticas com o objetivo de encontrar a matriz B , para isso, podemos considerar $E = 0$ e remover a matriz V do lado direito da equação. Caso a matriz V seja quadrada e $\det(X) \neq 0$, então X^{-1} existe. Logo, multiplicar as partes por esta matriz inversa temos que $P \cdot V^{-1} = B$. No entanto, se a matriz V não for quadrada, é necessário aplicar a Equação 3.15, onde T indica que a matriz é transposta (LYDIA et al., 2013a; CAVALCANTI NETO et al., 2015).

$$B = (V^T V)^{-1} V^T P \quad (3.15)$$

A matriz $(V^T V)^{-1} V^T$ é conhecida como matriz pseudo-inversa.

3.6.3 Máquina de Aprendizagem Extrema (ELM)

A Máquina de Aprendizagem Extrema (*Extreme Learning Machine*, ELM é uma rede neural do tipo *feedforward* em que a topologia apresenta apenas uma camada oculta (SLFN - *Single-hidden Layer Feedforward Network*). A saída de cada neurônio é calculada pela Equação 3.11, em que φ é geralmente uma das seguintes formas:

$$\varphi[u_i(t)] = \frac{1}{1 + \exp[-u_i(t)]} (\text{Logística}), \quad (3.16)$$

$$\varphi[u_i(t)] = \frac{1 - \exp[-u_i(t)]}{1 + \exp[-u_i(t)]} (\text{Tangente Hiperbólica}). \quad (3.17)$$

Os pesos da entrada para a camada oculta são escolhidos de forma aleatória, enquanto os pesos entre os neurônios ocultos e a saída são analiticamente determinados (WAN et al., 2014; BARROS; BARRETO, 2012; HUANG et al., 2012; CAVALCANTI NETO et al., 2015). Por estes motivos a ELM apresenta algumas vantagens como alta velocidade de aprendizagem e facilidade de implementação (BARROS; BARRETO, 2012; HORATA; CHIEWCHANWATTANA; SUNAT, 2013). No entanto, é necessário um grande número de neurônios na camada oculta para obter baixas taxas de erro (BARROS; BARRETO, 2012). Isso prejudica o desempenho da ELM em tempo real.

Além de modelar a curva de potência, a ELM pode ser utilizada para previsões de produção de energia, detecção e classificação de falhas nos aerogeradores, entre outras apli-

cações (WAN et al., 2014; HORATA; CHIEWCHANWATTANA; SUNAT, 2013; HUANG; ZHU; SIEW, 2006).

3.6.4 Função de Base Radial

A rede de Função de Base Radial (*Radial Basis Function*, RBF) é do tipo *feedforward* híbrida, que combina conceitos de aprendizagem supervisionada e não-supervisionada. A rede RBF apresenta uma camada de entrada, uma só camada intermediária com funções de ativação e uma camada de saída cujos neurônios são geralmente lineares.

Os pesos da camada oculta são determinados através da regra de aprendizagem da rede SOM (*self-organizing feature map*). As posições dos neurônios da rede SOM são adotados como os pesos dos neurônios da camada de entrada, $c_t = w_t$. Assim calcula-se a ativação do neurônio i por meio da expressão a seguir.

$$u_i(t) = ||x(t) - c_i||, \quad i = 1, \dots, q, \quad (3.18)$$

em que q é o número de neurônios da camada oculta. A saída dos neurônios é calculada por

$$\phi_i(u_i(t)) = \exp \left\{ -\frac{u_i^2(t)}{2\sigma_i^2} \right\}, \quad (3.19)$$

em que σ_i é chamado de *spread* e define a largura da função de ativação gaussiana. De acordo com a Equação 3.19, cada neurônio da camada oculta tem seu próprio campo receptivo (*receptive field*), que é uma região centrada em c_i com tamanho proporcional a σ_i . O valor máximo de $\phi_i \approx 1$ para vetores de entrada próximos de c_i .

É comum normalizar a saída dos neurônios da camada oculta para que a soma de todas as saídas seja igual a 1, assim, a resposta $y_i(t)$ é definida como:

$$y_i(t) = \frac{\phi_i(u_i(t))}{\sum_{l=1}^q \phi_l(u_l(t))} \quad (3.20)$$

Os pesos da camada de saída podem ser atualizados de uma vez aplicando o método dos mínimos quadrados. Equacionando a relação entre as saídas dos neurônios da camada oculta e dos neurônios de saída de forma matricial:

$$GM = D, \quad (3.21)$$

tal que G é uma matriz de saída da camada oculta, D é o vetor com os dados de saída desejados e M é o vetor de pesos da camada de saída. Pode-se, então, aplicar a Equação

3.15 na Equação 3.21 e obter a Equação 3.22.


$$M = (G^T G)^{-1} G^T D \quad (3.22)$$

3.7 Regressão baseada em Vetores-Suporte

A utilização de algoritmos baseados em vetores suporte foi proposto por Vapnik (1963). Originalmente as Máquinas de Vetores Suporte (*Support Vector Machines*, SVM) foram desenvolvidas para resolver problemas de reconhecimento de padrões. A ideia principal do SVM, quando utilizada para classificação, é construir um hiperplano como superfície de decisão de tal modo que a margem de separação entre as classes diferentes seja máxima (HAYKIN, 2001). Os vetores suporte consistem de um pequeno subconjunto dos dados de treinamento extraído pelo algoritmo capazes de representar a superfície de decisão (SOUZA, 2013).

Posteriormente a utilização de vetores suporte foi expandida por Vapnik e Kaufman (1997) ao problemas de regressão, e passaram a ser conhecidos como Regressão por Vetores-Suporte (*Support Vector Regressors*, SVR). Vapnik introduziu a função de perda ε -insensível e o conceito de tubo com o objetivo de manter as características do método também no contexto de aproximação de função (Figura 13). Esses novos elementos tornaram possível a aplicação de vetores suporte ao problema de regressão, permitindo assim, o desenvolvimento do SVR (SOUZA, 2013).

Figura 13 – Função de perda ε -insensível



Fonte: Souza (2013).

3.7.1 SVR para Regressão Linear

Considere um conjunto de dados para treinamento $D = (x_1, y_1), \dots, (x_N, y_N)$ formado por N pares de entradas $x_n \in R^d$ e saídas correspondentes $y_n \in R$, para $n=1, \dots, N$. Em um problema de regressão, o objetivo é encontrar uma função $f(\cdot)$ que apresente saídas mais próximas dos valores y_n para cada valor de x_n . Para regressão linear, $f(\cdot)$ apresenta a seguinte forma:

$$f(x_n) = \mathbf{w}^T \mathbf{x}_n + b, \quad (3.23)$$

em que $\mathbf{w} \in R^d$ é um vetor de parâmetros e $b \in R$ é o bias. Os parâmetros $\mathbf{w}$ e b , da Equação 3.23 com menor complexidade e maior generalização são encontrados pela minimização da norma Euclidiana $\|\mathbf{w}\|^2$:

$$\min J(\mathbf{w}, \xi, \xi^*) = \frac{1}{2} \|\mathbf{w}\|^2 + \gamma \sum_{n=1}^N (\xi_n + \xi_n^*), \quad (3.24)$$

$$\text{sujeito a } \begin{cases} y_n - \mathbf{w}^T x_n - b \leq \varepsilon + \xi_n \\ \mathbf{w}^T x_n - b - y_n \leq \varepsilon + \xi_n^* \\ \xi_n, \xi_n^* \geq 0, \text{ para } n = 1, \dots, N, \end{cases} \quad (3.25)$$

em que ξ_n e ξ_n^* são variáveis de folga correspondentes aos pontos onde $f(x_n) - y_n > \varepsilon$ (pontos acima da curva) e $y_n - f(x_n) > \varepsilon$ (pontos abaixo da curva). A constante $\gamma > 0$ é o parâmetro de regularização que estabelece uma ponderação entre a complexidade do modelo e a quantidade de desvios admitidos maiores que ε . Isso corresponde a lidar com uma chamada função de perda ε -insensível, ou função de perda de Vapnik (VAPNIK, 1995), descrita por:

$$|\xi|_\varepsilon := \max \{0, |y - f(x)| - \varepsilon\}, \quad (3.26)$$

em que ε é o raio desse tubo projetado sobre o conjunto de dados, como ilustrado na Figura 13. A função de perda, Equação 3.26, pode ser interpretada da seguinte forma: caso a amostra esteja posicionado dentro do tubo, não há perda e o valor do resíduo é zero e não é considerado na função de erro. Entretanto, se a amostra estiver situado fora do tubo, a perda é dada pela quantidade $|y - f(x)| - \varepsilon$ (SOUZA, 2013).

A formulação paramétrica na Equação 3.24 com as restrições de desigualdade na Equação 3.25 é um problema de otimização no espaço de peso primário, também conhecido como um problema em forma primal, uma vez que é definido no espaço original R^d dos dados de entrada x_n e o vetor de parâmetro $\mathbf{w}$. A solução desse problema primal pode ser conseguida através da construção de uma função Lagrangiana das Equações 3.24 e 3.25,

que transforma o problema primal em um problema dual (FLETCHER, 2013). Agora o problema é resolvido no espaço de $2N$ utilizando as variáveis α_n e α_n^* em vez de $\mathbf{w}$ no espaço primário. A solução dual da Equação 3.23 é dada por:

$$f(x^*) = \sum_{n=1}^N (\alpha_n - \alpha_n^*) x_n^T x + b \quad (3.27)$$

em que α_n e α_n^* são multiplicadores de Lafrange e o viés b pode ser determinado usando as condições de *Karush-Kuhn-Tucker* (KKT) (KUHN; TUCKER, 1951).

Uma propriedade importante do problema da Equação 3.27 é que muitos valores resultantes de α_n , α_n^* são iguais a zero. Assim, a solução obtida é esparsa, isto é, a soma na Equação 3.27 deve ser tomada apenas em valores não-nulos de $(\alpha_n - \alpha_n^*)$, em vez de todos os padrões de treinamento. Os exemplos de entrada $\mathbf{x}_n$, para os quais os multiplicadores de Lagrange correspondentes não são nulos, são os vetores suporte. Além disso, note que, ao contrário da solução espacial primária na Equação 3.23, a expressão na Equação 3.27 é independente do vetor de parâmetro $\mathbf{w}$. Portanto, deve-se dizer que o problema dual do SVR corresponde a um modelo não paramétrico, embora a sua formulação original na Equação 3.23 corresponde a um modelo paramétrico.

3.7.2 SVR para Regressão Não-Linear

A maioria dos problemas de regressão em aprendizagem de máquinas são essencialmente não-lineares. Portanto, a formulação linear do modelo SVR na Seção 3.7.1 deve ser estendida ao caso não-linear. Dado o conjunto de dados de treinamento $D = (x_1, y_1), \dots, (x_N, y_N)$, com $x_n \in R^d$ e $y_n \in R$, a função $f(\cdot)$ na Equação 3.23 agora assume a forma:

$$f(x_n) = \mathbf{w}^T \phi(\mathbf{x}_n) + b, \quad (3.28)$$

em que $\mathbf{w} \in R^{d_h}$, $b \in R$ e $\phi(\cdot) : R^d \rightarrow R^{d_h}$ é um mapeamento não linear em um espaço de característica dimensional maior (cuja a dimensionalidade d_h pode ser infinita), onde o problema é linearmente solucionado. A versão não linear do problema de otimização SVR no espaço primário (Equações 3.24 e 3.25) é dada por:

$$\min J(\mathbf{w}, \xi, \xi^*) = \frac{1}{2} \|\mathbf{w}\|^2 + \gamma \sum_{n=1}^N (\xi_n + \xi_n^*), \quad (3.29)$$

$$\text{sujeito a } \begin{cases} y_n - \mathbf{w}^T \phi(x_n) - b \leq \varepsilon + \xi_n \\ \mathbf{w}^T \phi(x_n) - b - y_n \leq \varepsilon + \xi_n^* \\ \xi_n, \xi_n^* \geq 0, \text{ para } n = 1, \dots, N, \end{cases} \quad (3.30)$$

em que a única diferença entre eles e a formulação linear, abordada anteriormente, é a substituição de x_n por $\phi(x_n)$ nas restrições da Equação 3.30. Mais uma vez, pode-se aplicar o Lagrangiano nas Equações 3.30 e 3.29 para obter a formulação do problema dual.

Finalmente, a saída prevista do modelo SVR não linear, para um novo vetor de entrada x^* , é dada por:

$$f(x^*) = \sum_{n=1}^N (\alpha_n - \alpha_n^*) k(x_n, x^*) + b, \quad (3.31)$$

onde $k(\cdot)$ é conhecida como uma função de kernel, que é usada para resolver os problemas de dimensionalidade nas versões não-lineares das condições de otimização, sem a necessidade de calcular explicitamente o mapeamento ϕ . Algumas escolhas comuns para a função de kernel estão resumidas na Tabela 3.

Tabela 3 – Função de Kernel

Kernel	Função	Hiperparâmetros
Linear	$k(x, x') = x^T x'$	-
Polinomial	$k(x, x') = (x^T x' + \tau)^p$	$p(\text{grau})$ e τ
Gaussiano	$k(x, x') = \exp\left\{-\frac{\ x-x'\ _2^2}{2\sigma^2}\right\}$	σ (Largura de banda)
Sigmoidal	$k(x, x') = \tanh\{k_1 x^T x' + k_2\}$	k_1, k_2 .


Assim como no caso linear, muitos valores de α_n , α_n^* são nulos e, portanto, a solução do modelo é esparsa. Mais uma vez, o problema dual resulta em um modelo não paramétrico que não depende da dimensionalidade dos dados de entrada, mas apenas do número de amostras de treinamento.

3.7.3 RNAs Recursivas

Uma Rede Neural Artificial (RNA) recursiva, ou recorrente, é aquela que contém conexões sinápticas realimentadas, permitindo o fluxo de sinais neurais das camadas mais posteriores para as camadas anteriores. Uma conexão sináptica é definida como uma ligação entre dois neurônios quaisquer. Existem dois tipos principais de conexões, a conexão de alimentação direta (*feedforward*) e conexão de realimentação (*feedback*). A conexão de alimentação direta ocorre quando um sinal tem orientação da entrada para a saída. Em contraste, a conexão de realimentação tem orientação da saída para a entrada. A recorrência funciona como um tipo de memória de curta duração que permite a rede relembrar de um passado recente.

Os modelos estatísticos auto-regressivos podem ser usado como um preditor, para prever o próximo valor do sinal de entrada. A previsão é um tipo de filtragem dinâmica, na qual valores passados de um ou mais séries temporais são usados para prever valores

Figura 14 – Preditor recursivo com realimentação.



Fonte: [Menezes Júnior \(2013\)](#).

futuros. Ele também pode ser usado para filtragem não-linear, em que a saída de destino é uma versão sem ruído do sinal de entrada.

Devido à sua capacidade de aprender a partir de exemplos, um preditor baseado em rede neural estima o valor futuro de um sinal apenas a partir de suas amostras passadas. Um modelo de predição deste tipo é chamado de não paramétrico, uma vez que não há necessidade de se conhecer os parâmetros do processo que gera o sinal. O modelo do processo é estimado através de um algoritmo de aprendizado em que os exemplos são apresentados à rede neural e seus pesos são atualizados em função do erro de saída.

Segundo [Menezes Júnior \(2013\)](#) a arquitetura da rede recursiva também é definida pela forma da sua saída. o termo MISO (multi-input, single-output) refere-se ao fato de a rede receber várias entradas e prever apenas uma saída por instante de tempo. Para utilizar a rede tipo MISO para um horizonte de predição maior que um é necessário que a saída da rede seja realimentada para a camada de entrada, como na Figura 14. Desta forma, os componentes de entrada, previamente compostos apenas por valores reais da série temporal, são gradativamente trocados por valores preditos, dos mais antigos para os mais recentes. Se o horizonte de predição tende ao infinito, em algum momento todas as entrada da rede serão compostas por estimativas da série temporal. Por conta disto, quanto maior a distância temporal requerida, maior a incerteza da estimativa ([MENEZES JÚNIOR, 2013](#)).


3.7.4 Rede NAR

No modelo NAR os valores futuros de uma série temporal $y(n)$ são previstos apenas a partir de valores passados dessa mesma série temporal, como ilustrado na Figura 14. A relação entre as saídas passadas e a saída prevista da rede NAR pode ser escrita da

seguinte forma:

$$\hat{y}(n+1) = f(y(n), \dots, y(n-d_y+1)), \quad (3.32)$$

Figura 15 – Exemplo de topologia NAR.



Fonte: [Menezes Júnior \(2013\)](#).

em que $y(n), \dots, y(n-d_y-1)$ são os valores anteriores de saída, medidos diretamente do sistema e $\hat{y}(n+1)$ é o valor estimado da próxima saída, calculado a partir dessas saídas anteriores. $d_y \geq 1$ é a ordem de memória da série temporal (retardo). O modelo, então, não apresenta entradas exógenas pois dispõe apenas do histórico da série temporal.

No exemplo da Figura 16, a rede NAR é utilizada para a estimação dos valores da série temporal caótica de Marckay-Glass. A topologia composta por duas camadas ocultas de seis e três neurônios, e com ordem na entrada de dezenove amostras da série temporal é utilizada para o treinamento desta rede.


Ao analisar os gráficos da Figura 16 é notável que, a medida que a janela temporal de previsão é estendida, a erro na previsão aumenta. Isso ocorre devido o método utilizar as previsões, $\hat{y}$, anteriores para previsão das estimativas futuras, fazendo com que o erro seja acumulativo.

3.8 Métricas de avaliação dos resultados

Muitos conjuntos de dados utilizados em problemas de regressão matemática apresentam imperfeições, denominadas ruídos. Um requisito importante para as técnicas de Aprendizagem de Máquinas (AM) é que elas sejam robustas a ruídos presentes nos dados, assim como capazes de lidar com dados de baixa representatividade.


Um modelo muito simples tende a não capturar os detalhes mais específicos dos dados, capturando apenas as características gerais, como ilustrado na Figura 17. Este fenômeno é chamado de *underfitting*. Ele apresenta alto erro de estimação, porém a variância da saída do modelo é baixa. Isso significa que o modelo apresenta alta taxa de

Figura 16 – Exemplo de resultado da rede NAR estimando série temporal.



Fonte: Autor.


erro no conjunto de treinamento e que apresenta baixa variação do erro no conjunto de teste.

Figura 17 – Exemplo de *underfitting*.

Por outro lado, se o modelo se especializar nos dados utilizados em seu treinamento e capturar características muito específicas dos dados, inclusive o ruído, ocorre o caso

conhecido como *overfitting*, como ilustrado na Figura 18. Ele apresenta baixo erro de estimação nas etapas de treinamento, mas a variância é alta, o que ocasiona erros elevados quando são apresentados dados diferentes dos que foram utilizados para a geração do modelo.

Figura 18 – Exemplo de *overfitting*.



O modelo ideal, chamado de *goodfitting*, é aquele com menor complexidade e maior representabilidade possível. Equilibrando estabilidade, precisão e desempenho.

O desempenho dos modelos paramétricos e não-paramétricos da curva de potência são mensuradas a partir da análise de diferentes métricas de desempenho estatísticos. Esta análises têm o objetivo de calcular a similaridade entre duas séries de dados. Existem diversas métricas de análise. Os métodos mais utilizados para a análise do modelo da curva de potência são: a raiz quadrada do erro quadrático médio (*Root Mean Square Error* - RMSE) (WAN et al., 2014) e o Coeficiente de determinação (*R square* - R^2) (LYDIA et al., 2015). Estas métricas ajudam a mensurar a qualidade de um modelo matemático em comparação com um fenômeno real que ele representa. Entretanto, o modelo que apresente o maior valor de R^2 e o menor valor de RMSE não é, necessariamente, o melhor modelo.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y(i) - q(i))^2} \quad (3.33)$$


$$R^2 = 1 - \frac{\sum_{i=1}^n (q(i) - y(i))^2}{\sum_{i=1}^n (q(i) - q_{med})^2} \quad (3.34)$$

onde q é valor real, y é o valor estimado e n é o numero de amostras.

4 Metodologia

Neste capítulo é apresentada a metodologia, utilizada neste trabalho, para estimar a produção de energia eólica em aerogeradores, a qual possui três etapas: a modelagem da curva de potência do aerogerador, a estimativa da velocidade de vento e a estimativa de produção energética. O fluxograma da Figura 19 ilustra o processo para a estimativa de energia eólica, onde é necessário, primeiramente, encontrar um modelo para a curva de potência do aerogerador que melhor represente o seu comportamento e prever a velocidade do vento.

Figura 19 – Etapas para estimação da produção energética de um aerogerador



Fonte: Autor.


Antes de aprofundar em cada etapa utilizada no presente trabalho, é necessário apresentar a base de dados utilizada, pois, como salientado no Seção 3.3, pequenas variações

da velocidade do vento implicam em grandes variações de potência gerada pelo aerogerador, isso significa que os dados coletados precisam ser de boa qualidade para que tenhamos uma análise confiável.

4.1 Bancos de dados

O banco de dados utilizado é composto por 56838 amostras de dados de velocidade do vento e potencia produzida pelo aerogerador em operação no período entre 0:0h do dia 25/05/2014 e 23:50h do dia 27/07/2015. Além disso, tem-se o registro da disponibilidade diária do aerogerador nesse mesmo período. O banco de dados é composto por valores médios da velocidade do vento e da produção energética a cada 10 minutos. A disponibilidade é a porcentagem de tempo que o aerogerador passou disponível a cada dia. Os gráficos da Figura 20 são amostras, em médias diárias, de um período de 140 dias das amostras coletados.

Figura 20 – Exemplo da relação de velocidade do vento, produção de energia e disponibilidade do aerogerador.



Fonte: Autor.

A informação sobre a disponibilidade do aerogerador VSWT é de grande importância, já que ela influencia a produtividade deste aerogerador. Como pode ser visto na Figura 20, no dia 40 a produtividade do aerogerador VSWT foi 0 kWh, apesar de haver vento com velocidade média de 8 m/s, por conta da disponibilidade do VSWT ser de 0%.


A especificação do modelo de aerogerador utilizado para gerar o banco de dados utilizado neste trabalho está apresentada na Tabela 4. A curva de potência deste aerogerador dada pelo fabricante é apresentada na Figura 21.

Tabela 4 – Características do Aerogerador.

Potência nominal	1500 kW
Velocidade mínima do vento	3 m/s
Velocidade nominal do vento	12 m/s
Velocidade máxima do vento	22 m/s
Faixa de velocidade angular	9 - 17,3 rpm
Diâmetro da turbina	82 m
Área de varredura	5.325 m ²
Altura do cubo	85 - 100 m

Fonte: VENYS (2012).

Figura 21 – Curva de potência do aerogerador utilizado dada pelo fabricante.



Fonte: VENYS (2012).


4.1.1 Filtragem de dados

Existem alguns fatores que contribuem para que a curva de potência do aerogerador apresente uma variância de valores de potencia para uma mesma velocidade de vento. Um dos fatores ocorre devido ao processo de controle do aerogerador não atualizar de forma instantânea, pois, o sistema de controle do aerogerador só considera a velocidade média do vento em cada dez minutos. Dentro deste intervalo de dez minutos a velocidade do vento pode apresentar grandes variações e o sistema de controle não acompanha essa variação, por este motivo, o aerogerador não está em configuração ótima o tempo todo. Outro fator importante é a turbulência que um aerogerador causa nos outros. Essa turbulência

funciona como uma "sombra". O vento, ao mudar de direção, incide no parque eólico de forma que o vento que sai de um aerogerador entra em outro. Isso causa uma turbulência que atrapalha o controle do aerogerador. Além destes motivos o aerogerador pode estar com defeito de funcionamento, ou até mesmo com limitação proposital da potência de geração máxima.

Considerando isto, antes de aplicar as técnicas para a modelagem das curvas de potência foi necessário a filtragem dos dados a partir de uma análise do gráfico da curva de potência. Observando o gráfico da Figura 22 é possível notar que existem amostras muito distantes do valor médio da curva de potência. A filtragem dos dados visa desconsiderar as amostras que correspondem ao funcionamento do aerogerador em condições anormais. Para isto, foi considerado como válidos os dados que estiverem a uma distância de duas vezes a variância média do valor mediano da curva de potência. No Figura 22 é possível notar tantos os limites, quanto os dados considerados e desprezados na etapa de modelagem da curva de potência.

Figura 22 – Filtragem dos dados



4.2 Regressão da curva de potência

A etapa de regressão da curva de potência é realizada com o objetivo de encontrar uma função que represente o comportamento do aerogerador. Os métodos de regressão são subdivididos entre modelos paramétricos e modelos não paramétricos.

4.2.1 Obtenção da curva de potência por modelos paramétricos

Existem vários tipos diferentes de funções que podem ser usadas para modelar fenômenos do mundo real (LYDIA et al., 2013a). Este método, embora simples, geralmente tem precisão satisfatória. O primeiro passo é encontrar uma função básica ou um conjunto de funções que mais se aproximem da função que se deseja modelar (THAPAR; AGNIHOTRI; SETHI, 2011), procurando equilibrar os fatores complexidade e precisão. A curva de potência, por exemplo, pode ser comparada às funções linear, exponencial, sigmoidal, polinomial ou associações entre elas.

4.2.1.1 Curva de potência cúbico aproximado

Este método é baseado na equação fundamental da máxima energia capaz de ser absorvida pela turbina. O modelo utiliza a equação a seguir:

$$P(v) = \frac{1}{2} \rho A C_{p,max} v^3, \quad (4.1)$$

em que ρ é a densidade do ar, A é a área de varredura da turbina do aerogerador, $C_{p,max}$ é o coeficiente de potência máximo e v é a velocidade do vento. Este modelo é parametrizado utilizando dados do aerogerador que se deseja modelar. Neste caso utilizou-se os dados presentes na Tabela 4.

4.2.1.2 Curva de potência exponencial

Este modelo é baseado em uma forma presumível de curva de potência. Embora simples, responde de forma satisfatória para velocidades de vento médias anuais mais elevadas (CARRILLO et al., 2013). Esta proposta é apresentada na Equação 4.2, a seguir

$$P(v) = \frac{1}{2} \rho A K_p (v^\beta - v_{ci}^\beta), \quad (4.2)$$

em que k_p e β são constantes que necessitam ser parametrizadas.

4.2.1.3 Curva de potência polinomial


Os polinômios são comumente utilizados para modelar fenômenos que ocorrem em ciências sociais e naturais (STEWART, 2010). Uma função P é denominada polinômio se

$$P(i) = b_k v_i^k + b_{k-1} v_i^{k-1} + \dots + b_2 v_i^2 + b_1 v_i^1 + b_0, \quad (4.3)$$

em que $b_0, b_1, \dots, b_k$ são chamados de coeficientes do polinômio e k é um número inteiro não negativo.

Um polinômio em que $k = 1$ equivale a uma função linear (Equação 4.4). As funções lineares apresentam taxa de variação constante (STEWART, 2010). Por esse motivo, para obter melhores resultados na modelagem da curva de potência é necessário utilizar combinações de funções lineares, como é ilustrado na Figura 23.

Figura 23 – Modelo com combinações de funções lineares.



Fonte: Lydia et al. (2013a).

$$P = b_1 v^1 + b_0 \quad (4.4)$$

A aproximação da curva de potência polinomial encontrada em (CARRILLO et al., 2013) utiliza uma equação polinomial de 2ª grau associada à Equação 3.8 para encontrar $q(v)$, como segue

$$P(v) = C_2 v^2 + C_1 v + C_0, \quad (4.5)$$

em que C_0 , C_1 e C_2 são calculados com v_{ci} e v_r .

$$C_0 = \frac{1}{(v_{ci} - v_r)^2} \left[v_{ci}(v_{ci} + v_r) - 4v_{ci}v_r \left(\frac{v_{ci} + v_r}{2v_r} \right)^3 \right] \quad (4.6)$$

$$C_1 = \frac{1}{(v_{ci} - v_r)^2} \left[4(v_{ci} + v_r) \left(\frac{v_{ci} + v_r}{2v_r} \right)^3 - 3v_{ci} - v_r \right] \quad (4.7)$$

$$C_2 = \frac{1}{(v_{ci} - v_r)^2} \left[2 - 4 \left(\frac{v_{ci} + v_r}{2v_r} \right)^3 \right] \quad (4.8)$$

4.2.1.4 Função logística

A função logística é uma das mais utilizadas para representar a curva de potência de aerogeradores (VILLANUEVA; FEIJÓO, 2016). Pode ser aproximada utilizando três

quatro ou cinco parâmetros como são apresentados nas Equações 4.9, 4.10 e 4.11 (LYDIA et al., 2013a), em que θ é o vetor de parâmetros. em que $\theta_3 = (a, b, c)$, $\theta_4 = (a, m, n, \tau)$ e $\theta_5 = (a, b, c, d, g)$, onde $c > 0$ e $g > 0$ (LYDIA et al., 2015).

$$P(v, \theta_3) = a \frac{1}{1 + e^{-b(v-c)}} \quad (4.9)$$

$$P(v, \theta_4) = a \frac{1 + me^{-v/\tau}}{1 + ne^{-v/\tau}} \quad (4.10)$$

$$P(v, \theta_5) = \frac{d + (a - d)}{\left(1 + \left(\frac{v}{c}\right)^b\right)^g} \quad (4.11)$$

Para encontrar os parâmetros do vetor θ Lydia et al. (2013a) utiliza mínimos quadrados:

$$\min \sum_{i=1}^N [P(v, \theta) - P_a(i)]^2, \quad (4.12)$$

que busca o valor do parâmetro vetorial $\hat{\theta}$ que resulte na saída $P(v, \theta)$ mais próxima da saída real $P_a(i)$.


4.2.2 Obtenção da curva de potência por modelos não paramétricos

Para a parametrização das funções de modelagem da curva de potência foi utilizada a técnica de *cross-validation* (validação cruzada). Os dados são divididos em dois conjuntos, sendo um utilizado para o treinamento e outro para teste. Isto é feito para que seja possível analisar o comportamento do modelo ao ser apresentadas amostras diferentes das amostras utilizadas para o treinamento. Sendo assim, do total de 46.175 amostras, 9.235 foram utilizadas para treino e 36.940 para teste. Isso corresponde à 20% de dados para treino e 80% para o teste. A seleção dos dados para treino foi realizada de forma aleatória. A Figura 24 apresenta estes dois conjuntos de dados.


4.3 Predição da velocidade do vento

O processo de predição do vetor de estados a partir de uma única série temporal é chamado de reconstrução do espaço de estado. A reconstrução do espaço de estado está baseada no Teorema da Imersão de Takens, que afirma que uma série temporal de tamanho N , suficientemente grande e livre de ruído, obtida a partir de uma das variáveis de um sistema dinâmico determinístico. O espaço de estado deste sistema pode ser reconstruído a partir de amostras atrasadas daquela série temporal (MENEZES JÚNIOR, 2013).

Figura 24 – Divisão dos dados para avaliação dos métodos não paramétrica na predição da curva de potência de um aerogerador.



(a) Dados para o treinamento



(b) Dados para os testes


Fonte: Autor.

Utilizamos um banco de dados com 5040 amostras de velocidade de vento de um aerogerador sendo 4320 amostras para treino e 720 para teste. Cada amostra corresponde a média da velocidade do vento no período de dez minutos. As 5040 amostras correspondem a um período de trinta e cinco dias e as 4320 amostras treino correspondem a um período de trinta dias. Os cinco dias posteriores ao período de treino são utilizados para teste. Nesta etapa do desenvolvimento são analisados os métodos NAR e SVR para predição da velocidade do vento.

Conforme já utilizado por [Piazza, Piazza e Vitale \(2014\)](#), o método NAR é aplicado para prever a velocidade do vento, o que segundo o autor é interessante pelo método

ser neuro-estatístico e já ter sido usado para estimação de séries temporais ruidosas (SCHOPF, 2007). Menezes Júnior (2013) também afirma que em predição de séries temporais normalmente são usados modelos de RNAs *feedforward*, treinados pelo algoritmo *backpropagation*. A topologia da rede foi encontrada de forma heurística através de testes realizados, conforme é apresentada na Figura 25. O ajuste dos elementos da topologia como o número de amostras de retardo, o número de dados de treinamento e o número de neurônios e camadas da rede neural influenciam no resultado. A topologia utilizada neste trabalho é composta por quatro neurônios na camada oculta e um neurônio na camada de saída.

Figura 25 – Topologia do modelo NAR para predição da velocidade do vento.



Fonte: Autor.


Para o método SVR foram utilizados os seguintes parâmetros: A constante γ , que corresponde ao parâmetro de regularização entre a complexidade do modelo, é igual a 8×10^{-6} . O ϵ , que corresponde ao raio do tupo, é igual a 0,3. O kernel utilizado foi do tipo gaussiano com σ (abertura da função gaussiana) igual a 0,0625.

4.4 Estimação do potencial energético

Neste trabalho a estimativa dos recursos eólicos foi realizada com base nos modelos auto-regressivos não-lineares e na modelagem da curva de potência do aerogerador. Os modelos autorregressivos não-lineares são responsáveis pela predição da velocidade de vento, que combinados com a modelagem da curva de potência, possibilita a estimativa

do potencial energético de um aerogerador. Em outras palavras, para a estimativa de produção é necessário combinar a previsão da velocidade do vento juntamente com o modelo da curva de potência, seguindo as etapas apresentadas na Figura 26.

Figura 26 – Etapas para estimativa do potencial eólico na abordagem proposta.



Fonte: Autor.

5 Resultados e Discussões

Neste capítulo são analisados o resultado da estimação de produção eólica aplicando a metodologia descrita no capítulo 3, em que primeiramente são apresentados os resultados dos métodos avaliados na obtenção da curva de potência do aerogerador. Em seguida são apresentados os resultados da previsão da velocidade do vento. Por fim, os resultados da estimativa de produção de energia são apresentados.

5.1 Modelagem da curva de potência

Neste trabalho são utilizados dois tipos de aproximação para obter a curva de potência, sendo a paramétrica e a não paramétrica. As subseções à seguir apresentam os resultados dos métodos avaliados, sendo os melhores destes utilizados na Seção 5.3 para previsão da produção de energia eólica.

5.1.1 Modelagem da curva de potência por modelos paramétricos

Na modelagem da curva de potência por modelos paramétricos são avaliadas a aproximação cúbica, a curva de potência exponencial, o modelo polinomial e a aproximação por função logarítmica. A seguir é detalhado como cada método foi utilizado neste trabalho, e por fim, uma comparação entre eles é realizada.

5.1.1.1 Aproximação Cúbica


Para obter a curva de potência através de aproximação cúbica, foram aplicados os parâmetros da turbina a Equação 4.1, onde que $A = 5,325$, $C_{p,max} = 0,45$ e $\rho = 1,225$, resultando em:

$$P(v) = \frac{1}{2}(1,225)(5,325)(0,45)v^3. \quad (5.1)$$

5.1.1.2 Curva de potência exponencial

A modelagem pelo método exponencial, como visto no Tópico 4.2.1.2, consiste principalmente em determinar o valor das constantes K_p e β da Equação 4.2. Para isto, foi utilizado o método eurístico, alterando os valores das constantes e analisando os resultados através do cálculo de R^2 para cada modelo resultante, onde os parâmetros encontrados foram: $K_p = 4,5$, $\beta = 1,9$. A análise de R^2 resultou nos gráficos 27(a) e 27(b). Aplicando as constantes na Equação 4.2 chegamos a Equação 5.2.

$$P(v) = \frac{1}{2}(1,225)(5,325)(4,5)(v^{1,9} - v_{ci}^{1,9}) \quad (5.2)$$

Figura 27 – Análise de similaridade da regressão exponencial variando K_p e β 

Fonte: Autor.

5.1.1.3 Modelo polinomial

O modelo polinomial da Equação 3.8 e os coeficientes C_0 , C_1 e C_2 , calculados a partir das Equações 4.6, 4.7 e 4.8 respectivamente, foram calculados considerando as características do aerogerador presentes na Tabela 4 resultando na seguinte equação:

$$p(v) = 0,0116v^2 - 0,0745v + 0,1191. \quad (5.3)$$

5.1.1.4 Aproximação por função logística


Como abordado no Capítulo 3, o modelo baseado na função logística é determinado buscando os valores dos vetores de parâmetros (θ) que resultem no modelo que apresente a maior similaridade com os dados reais. A busca pelos parâmetros (θ) da função logística foi realizada utilizando a expressão:

$$\min \sum_{i=1}^N [P(v, \theta) - P_a(i)]^2, \quad (5.4)$$

em que $P(v, \theta)$ corresponde a saída função logística para uma velocidade de vento v e um vetor de parâmetros θ e $P(P_a(i))$ corresponde a saída do sistema real.

A Figura 28 foi gerada a partir da análise de R^2 de acordo com a variação de b e c do vetor θ_3 , mantendo a constante.

Figura 28 – Análise de similaridade da regressão logística variando b e c do vetor θ_3



Fonte: Autor.

Tabela 5 – Resultados obtidos

θ	Parâmetros				
θ_5	$a = 0,3$	$b = 3,7$	$c = 26$	$d = 1500$	$g = 56$
θ_4	$a = 1500$	$m = -5,2$	$n = 71$	$\tau = 1,9$	
θ_3	$a = 1500$	$b = 0,6$	$c = 8,4$		

5.1.1.5 Comparação dos resultados dos modelos paramétricos

Ao comparar os resultados das aproximações por modelos paramétricos na Tabela 6, percebemos que a função logística de três parâmetros obteve o melhor resultados de aproximação, sendo o método com menor valor de RMSE, maior valor de R^2 e maior velocidade de aproximação, além de ser uma das métricas menos complexa.


Tabela 6 – Análise da regressão polinomial com MQ.

Modelo	RMSE	R^2	Tempo(s)
Fabricante	127,3423	0,8867	0,0219
Cúbico	358,3626	0,1026	0,0550
Exponencial	60,5159	0,9744	0,0578
Polinomial	234,5492	0,6156	0,0819
Logístico³	47,3406	0,9843	0,0047
Logístico ⁴	52,9304	0,9804	0,0031
Logístico ⁵	96,5083	0,9349	0,0051

Para analisar visualmente os modelos descritos na Tabela 6, na Figura 29 é apresentada a projeção das curvas aproximadas pelos modelos paramétricos em comparação com os dados reais, bem como com a curva dada pelo fabricante. Observando as curvas apresentadas na Figura 29, percebe-se que em geral o modelo polinomial e cúbico possuem curvas abaixo da nuvem de pontos reais e a curva dada pelo fabricante está na maior dos

casos acima da nuvem de pontos reais. Por outro lado, percebe-se que os modelos logísticos e exponencial estão mais próximos do centro da distribuição de amostras.

Figura 29 – Curvas de aproximação da curva de potência obtidas por modelos paramétricos, juntamente com a curva dada pelo fabricante.



Fonte: Autor.

Analisando a Tabela 6, temos que o modelo Logístico³ possui o menor RMSE e o maior R^2 , além de ter o menor tempo. Somando esta análise e o comportamento deste modelo apresentado no gráfico da Figura 29, que confirma os dados numéricos da Tabela 6, então este modelo é o escolhido dentro os métodos paramétricos para ser avaliado na predição da produção de energia posteriormente.


5.1.2 Modelagem da curva de potência por modelos não paramétricos

Na modelagem da curva de potência por modelos não paramétricos neste trabalho são avaliados os métodos de Mínimos Quadrados, *Extreme Learning Machine* e *Radial Basis Function*. A seguir é detalhado como cada método foi utilizado neste trabalho, e por fim, uma comparação entre eles é realizada.

5.1.2.1 Mínimos Quadrados

Para encontrar o modelo polinomial mais adequado para representar a curva de potência foi utilizado o modelo de regressão polinomial de ordens variadas. Analisando o gráfico de R^2 , Figura 30(a), nota-se que após o modelo polinomial de quarta ordem ($k = 5$) o aumento da ordem do polinômio é irrelevante. Isto pode ser confirmado analisando o gráfico do RMSE 30(b).

Figura 30 – Análise da regressão polinomial com MQ



Fonte: Autor.

Observando os gráficos da Figura 30 e a Tabela 7 é possível notar que para os modelo de ordem entre $k = 5$ e $k = 7$ o valor de R^2 e $RMSE$ são praticamente constantes. Mas quando $k > 7$ o valor de R^2 começa a decrescer e o $RMSE$ a crescer para os dados de teste, isso indica que o modelo entrou em *Overfitting*. Por apresentar alta representabilidade e baixa complexidade, o modelo polinomial de quarta ordem ($k = 4$) é o mais adequado.

Tabela 7 – Análise da regressão polinomial com MQ

k	RMSE do Treino	RMSE do Teste	R^2 do Treino	R^2 do Teste
1	71,6835	71,6368	0,9639	0,9642
2	71,4411	71,6684	0,9643	0,9641
3	47,1460	47,3799	0,9844	0,9843
4	47,1293	47,4968	0,9845	0,9842
5	45,5122	45,5941	0,9855	0,9855
6	45,2437	45,7115	0,9857	0,9854
7	45,4827	45,6273	0,9855	0,9854
8	45,2571	46,5899	0,9857	0,9848
9	45,3857	46,6347	0,9855	0,9847
10	45,2661	50,7919	0,9857	0,9808

5.1.2.2 *Extreme Learning Machine* (ELM)


Neste trabalho é implementada uma rede ELM com pesos da camada oculta entre -0,3 e 0,3, função de ativação logística e treinamento de cada saída através do algoritmo MQ. Isso torna o treinamento da rede rápido e fácil em relação a outras redes do tipo *feedforward*. Os passos utilizados para decidir a topologia da rede ELM são:

1. Divisão dos dados em dois grupos de forma aleatória com a proporção de 20% para treino e 80% para teste e validação do algoritmo;

2. Os pesos dos neurônios da camada oculta são gerados aleatoriamente entre -0.3 e 0.3;
3. Calcular a saída dos neurônios ocultos através da Equação 3.11, onde a função de ativação φ utilizada foi a logística, Equação 3.16
4. Os pesos da camada de saída são calculados através dos método dos MQ;
5. A saída da rede é analisada de acordo com o calculo de R^2 e RMSE.

Estes passos foram repetidos com vezes variando a quantidade de neurônios da camada oculta. A pesar da ELM ter sido projetada para ter um alto número de neurônios, analisando os gráficos da Figura 31 e a Tabela 8 é possível notar que o modelo não evolui significativamente com o número de neurônios ocultos maior que quatro. Então, a topologia da ELM adotada para a solução do problema proposto é com quatro neurônios na camada oculta.

Figura 31 – Análise do número de neurônios ocultos da ELM



Fonte: Autor.

Tabela 8 – Análise do número de neurônios ocultos da ELM

n	RMSE do Treino	RMSE do Teste	R^2 do Treino	R^2 do Teste
1	95,1636	95,3501	0,9331	0,9329
2	68,2321	68,4012	0,9673	0,9672
3	49,4827	49,6921	0,9827	0,9826
4	46,1988	46,5562	0,9851	0,9849
5	45,6260	45,7322	0,9855	0,9854
6	45,4390	45,5898	0,9856	0,9855
7	45,5116	45,6017	0,9855	0,9855
8	45,4356	45,7878	0,9856	0,9853
9	45,3781	46,2823	0,9856	0,9850
10	45,4007	46,4678	0,9855	0,9848


5.1.2.3 Radial Basis Function (RBF)

A rede RBF é composta por duas camadas de neurônios, em que os pesos da camada oculta são determinados pela posição dos neurônios de uma rede SOM. Em seguida, a camada de saída é calculada utilizando o método de MQ. Os passos utilizados para decidir a topologia da rede RBF são:

1. Divisão das amostras em dois grupos de forma aleatória com a proporção de 20% para treino e 80% para teste e validação do algoritmo;
2. Os neurônios da rede SOM são distribuídos com uma taxa de convergência de 0,3 decrescente em 100 épocas. A posição dos neurônios da rede SOM correspondem ao pesos da camada oculta da rede RBF;
3. Calcular a saída dos neurônios ocultos aplicando uma função exponencial como função de ativação ϕ (Equação 3.19);
4. Os pesos da camada de saída são calculados através dos método dos MQ;
5. A saída da rede é analisada de acordo com o calculo de R^2 e RMSE.

Os passos anteriores foram repetidos com vezes variando a quantidade de neurônios da camada oculta. Nos gráficos da Figura 32 e na Tabela 9, é possível notar que o modelo não evolui significativamente com o número de neurônios ocultos maior que três, então, a topologia da rede RBF adotada para a solução do problema proposto utiliza três neurônios na camada oculta.

Figura 32 – Análise do número de neurônios ocultos da RBF



Fonte: Autor.

5.1.2.4 Comparação dos resultados dos modelos não paramétricos

Quanto aos resultados da predição da curva de potência por modelos não paramétricos, a Tabela 10 mostra os resultados da análise de comparação dos métodos não

Tabela 9 – Análise do número de neurônios ocultos da RBF


k	RMSE do Treino	RMSE do Teste	R^2 do Treino	R^2 do Teste
1	383,8849	384,0923	0,0301	0,0312
2	73,0858	72,5565	0,9627	0,9632
3	52,8561	53,1092	0,9806	0,9803
4	46,1032	46,2818	0,9851	0,9850
5	46,0201	46,2847	0,9851	0,9850
6	45,5348	45,5389	0,9854	0,9855
7	45,2213	45,6305	0,9859	0,9854
8	45,1694	45,6539	0,9858	0,9854
9	45,4058	45,6114	0,9855	0,9855
10	45,7482	45,6188	0,9853	0,9855

paramétricos na etapa de treinamento. Podemos notar que nesta etapa o modelo ELM obteve os melhores resultados, apresentando o menor RMSE, o maior R^2 e o menor tempo de execução. No gráfico da Figura 33 podemos ver a projeção das curvas da ELM, RBF e MQ sobre os dados de treinamento.

Tabela 10 – Resultados obtidos durante o período de treino dos modelos não paramétricos.

Modelo	RMSE	R^2	Tempo(s)
MQ	46,4500	0,9851	0,0607
ELM	46,5269	0,9851	0,0004
RBF	44,2752	0,9860	5,7956

Figura 33 – Curvas de aproximação da curva de potência obtidas por modelos paramétricos durante o período de treino, juntamente com a curva dada pelo fabricante.




Apesar do modelo ELM ter obtido os melhores valores de RMSE e R^2 na etapa de treinamento, na etapa de teste o modelo MQ obteve os melhores resultados. O fato do

modelo MQ ser o menos complexo favorece ainda mais a escolha deste método como o melhor entre os métodos de regressão não paramétricos. No gráfico da Figura 34 podemos ver as curvas de regressão sobre os dados utilizados para o teste.

Tabela 11 – Resultados dos modelos não paramétricos aplicados às amostras de teste.

Modelo	RMSE	R^2	Tempo(s)
MQ	45,3056	0,9856	0,0002
ELM	45,3089	0,9856	0,0014
RBF	46,7684	0,9848	0,3844

Figura 34 – Curvas de aproximação da curva de potência obtidas por modelos paramétricos durante o período de teste, juntamente com a curva dada pelo fabricante.



Fonte: Autor.


Analisando as curvas apresentadas no gráfico da Figura 34, percebe-se que a estimativa dada pelo fabricante está acima dos dados reais, sendo otimista nos valores de velocidade menor que 8 m/s e exagerado nos valores acima de 8 m/s, pois o gráfico está sempre acima da nuvem de pontos reais. Os modelos MQ, ELM e RBF possuem comportamento semelhante até 13 m/s, e bem distinto acima disso. Deste modo, o método MQ é o método não paramétrico avaliado mais promissor na predição de energia levando em consideração os dados da Tabela 11 e o comportamento da curva da Figura 34.

5.2 Predição da velocidade do vento


Para a avaliação da previsão de velocidade do vento pelo método NAR foram utilizados 5040 amostras, sendo 4320 para treino e 720 para teste. Cada amostra corresponde à média da velocidade do vento no período de dez minutos. As 5040 amostras

correspondem a um período de trinta e cinco dias, em que 4320 amostras utilizada para treino correspondem a um período de trinta dias e as 720 amostras utilizadas para teste equivalem à 5 dias. Os dados utilizados nesta etapa de resultados são apresentados na Figura 35.

Figura 35 – Dados utilizados na análise dos métodos de previsão da velocidade do vento: a) dados de treino; b) dados de teste.



(a)



(b)

Fonte: Autor.

A topologia do método NAR utilizada nos testes é composta por quatro neurônios na camada oculta e um neurônio na camada de saída, além de uma dimensão de imersão

de 144 amostras com atraso de imersão 2. O método de otimização Levenberg–Marquardt foi utilizado no treinamento do método NAR. A comparação entre a serie temporal real e a estimativa obtida pelo modelo NAR pode ser vista nos gráficos da Figura 37(a), onde o R^2 e o RMSE foram 0,4769 e 1,1126, respectivamente.

O modelo SVR utilizado para a previsão da velocidade do vento obteve resultados inferiores ao modelo NAR na simulação livre. Entretanto, obteve-se resultados melhores que o método NAR ao reduzir o horizonte de previsão para três passos a frente, ou seja, na etapa de generalização, cada vez que o modelo prevê três valores, os valores reais são novamente apresentados para em seguida prever mais três amostras. O resultado obtido pelo método SVR esta ilustrado na Figura 37(b). Os valores de R^2 e RMSE calculados na análise de similaridade entre os dados previstos e os dados reais foram 0,6336 e 0,9330.

Analisando os resultados obtidos entre os métodos NAR e SVR, percebe-se que o método SVR é superior em termos de valores das métricas R^2 e RMSE. Entretanto, vale ressaltar que o método NAR obteve seu resultado com simulação livre, descartando amostras reais de velocidade do vento à medida que novos valores são preditos, sendo estes usados nas novas predições, enquanto o SVR tem horizonte de previsão de três passos a frente, ou seja, na etapa de generalização, cada vez que o modelo prevê três valores, os valores reais são novamente apresentados para em seguida prever mais três amostras.


5.3 Estimação da produção energética do aerogerador

Ao combinarmos o método de previsão da velocidade do vento com a modelagem da curva de potência podemos estimar a produtividade energética de um VSWT em um período de tempo que não temos dados, como momentos futuros ou lacunas em um banco de dados.


Sendo assim, como utilizamos dois modelos para aproximar a curva de potência, então temos duas abordagens propostas neste trabalho para realizar a previsão de produção de energia, um paramétrico (Logístico) e outro não paramétrico (MQ), em que ambas abordagens utilizam a previsão do vento obtida pelos métodos NAR e SVR, apresentado na Seção 5.2. A curva de potência dada pelo fabricante e a velocidade real do vento também avaliadas juntamente com os métodos apresentados, pois assim uma visão geral das etapas pode ser realizada, visto que a produção de energia real é utilizada para analisar todas as combinações possíveis.

Sendo assim, a Tabela 12 apresenta um resumo da estimativa média da produção de energia durante o período de teste analisado, em que a potência real gerada no período está na primeira linha para ser tomada como base na análise. As curvas de potência utilizadas são as obtidas pelas abordagens apresentadas, Mínimos Quadrados e Sigmoides Logístico, e também a curva dada pelo fabricante. Quanto às velocidades dos ventos utilizadas na

Figura 36 – Resultado da previsão de velocidade do vento no período avaliado, através dos métodos a) NAR em simulação livre; e b) SVR com horizonte de previsão de três passos a frente.



(a)



(b)

Fonte: Autor.

predição da produção são obtidas pelos métodos NAR e SVR, e também a velocidade real de vento utilizada.

Analisando os resultados apresentados na Tabela 12, observa-se que em relação à

Tabela 12 – Resultados das estimativas de produção de energia, obtida pela combinação da curva de potência (considerando os métodos mínimos quadrados (MQ), logístico e a curva do fabricante) e pela velocidade do vento (considerando os métodos NAR, SVR e a velocidade do vento real (VVR)).

Curva de potência	Velocidade do vento	RMSE	R ²	Média (W)
Potência real	-	-	-	526,7872
MQ	NAR	271,8795	0,2010	589,7970
	SVR	195,3541	0,5890	576,3963
	VVR	70,5710	0,9462	583,9737
Logístico	NAR	281,9127	0,1409	590,3827
	SVR	199,7910	0,5701	633,9331
	VVR	83,9283	0,9239	637,8701
Fabricante	NAR	309,7881	-0,0374	681,6575
	SVR	220,2452	0,4775	671,9324
	VVR	123,5668	0,8349	671,6176

métrica RMSE, a curva de potência obtida pelo método MQ obtém os menores valores, possuindo então os melhores resultados, independente da velocidade do vento utilizada, seja pelos métodos de predição NAR ou SVR, e até mesmo utilizando a velocidade do vento real, sendo seguido pelo método logístico, e ambos são superiores aos resultados obtidos usando a curva do fabricante, isto para todas as análises possíveis. Analisando a métrica RMSE quanto aos métodos de predição de vento, percebe-se que usar a velocidade do vento real é a abordagem mais promissora para todos os casos das curvas de potência, como já era de se esperar. Dentre os métodos de predição de vento, os melhores valores de RMSE são obtidos pelo método SVR, confirmando os resultados obtidos anteriormente na Seção 5.2. Sendo assim, a melhor combinação de resultados para a métrica RMSE na estimativa de produção de energia é o uso da curva de potência obtida pelo método MQ e a estimativa de vento do método SVR. Entretanto, vale ressaltar que se a estimativa de potência for realizada para um período mais elevado que três passos, então o método mais indicado é a combinação entre a curva de potência dos MQ e a estimativa de vento do método NAR, visto que este na abordagem avaliada este método utiliza a próprias predições para prever períodos futuros de vento, e consequentemente de produção de energia. Todas estas análises são confirmadas pelos resultados obtidos pela métrica R², em que os melhores resultados se aproximam de 1, e os piores de 0.

Analisando os resultados apresentados na Tabela 12 quanto à média da produção de energia em Watts, têm-se que o melhor resultado obtido é utilizando velocidade do vento estimada pelo método SVR com diferença de 49,60W para a produção real obtida, sendo seguido pela estimativa de produção usando a velocidade de vento real com 57,18W e NAR com 63,01W na mesma análise, ambas também com a curva obtida pela abordagem com MQ. A produção de energia foi menor que todas as estimativas, o que se deve ao

explicado na Seção 4.1.1, em que diversos motivos podem restringir a produção de energia, em que os principais são: o sombreamento entre torres, em que uma torre pode impedir que o vento chegue em uma segunda atrás da primeira; limitação da produção por temperatura elevada de alguns componentes; quebra parcial de alguns componentes do aerogerador, que limita sua eficiência, mas não seu funcionamento; entre outros motivos.

Para uma análise de todo o período de teste avaliado, a Figura 37 apresenta a estimativa da produção de energia pelas duas abordagens em relação à melhor estimativa obtida pelos dados do fabricante, utilizando os dados de vento reais, em que a Figura 37(a) apresenta estimativa utilizando modelo paramétrico Logístico e a Figura 37(b) apresenta estimativa utilizando o modelo não paramétrico MQ, ambos utilizando o método NAR para previsão de vento. Do mesmo modo, a Figura 38 apresenta a estimativa da produção pelas curvas de potência obtidas pela aproximação logística 38(a) e mínimos quadrados 38(b), ambas comparando com as do fabricante, em que a velocidade do vento é obtida pelo método SVR.


Analizando a Figura 37, podemos constatar que a diferença entre a estimativa pela aproximação paramétrica Logística possui média próxima aos dados reais de produção média do aerogerador, confirmando os dados apresentados na Tabela 12, obtendo resultados superiores à estimativa utilizando a curva de potência dada pelo fabricante, mesmo usando os valores de vento real. A abordagem proposta utilizando a estimativa da curva de potência pelo método não paramétrico MQ também obtém resultados melhores que o do fabricante e apresenta resultado similar ao obtido pela aproximação Logística³.

Por outro lado, analisando a Figura 38, podemos constatar que a diferença entre a estimativa pela aproximação não paramétrica obtida pelos MQ possui média próxima aos dados reais de produção média do aerogerador, confirmando os dados apresentados na Tabela 12, obtendo resultados superiores à estimativa utilizando a curva de potência dada pelo fabricante, mesmo usando os valores de vento real. A abordagem proposta utilizando a estimativa da curva de potência pelo método paramétrico logístico também obtém resultados melhores que o do fabricante.


5.4 Ferramentas de análise geradas pela abordagem proposta

Utilizando as abordagens propostas neste trabalho, algumas análises e funcionalidades podem ser usadas na gestão de parques eólicos. Dentre estes, as seções à seguir apresentam três destas: análise da curva de produção de energia, análise de produção de máquinas que não estão 100% disponíveis e uma análise da sazonalidade dos ventos.

Figura 37 – Resultados obtidos na estimativa de potência produzida utilizando o método NAR na estimativa do vento, e a curva de potência pelo método Logístico em (a) e MQ em (b), em relação aos dados reais do período avaliado.



(a)




(b)

Fonte: Autor.


5.4.1 Análise da curva de produção de energia

Para uma análise mais detalhada dos resultados obtidos pelas duas abordagens propostas quanto à superioridade diante da estimativa de produção utilizando a curva dada pelo fabricante, a Figura 39 apresenta a curva de potência dada por estas abordagens

Figura 38 – Resultados obtidos na estimativa de potência produzida utilizando o método SVR na estimativa do vento, e a curva de potência pelo método Logístico em (a) e MQ em (b), em relação aos dados reais do período avaliado.



(a)




(b)


Fonte: Autor.

e a nuvem de pontos total sem a filtragem apresentada na Seção 4.1.1.

Figura 39 – Curvas de potência obtidas pelos métodos propostos em contraste com a curva de potência informada pelo fabricante.



(a)



(b)

(c)

(d)

Fonte: Autor.

Analisando a Figura 39(a) é possível notar que a curva obtida pelas abordagens propostas utilizando o modelo MQ e o modelo logístico são praticamente iguais desde as velocidades 3 m/s até 9,5 m/s, e quase sempre aproximadamente no meio da nuvem de pontos dos dados reais de vento e potência gerada, diferente da curva dada pelo fabricante. Para uma melhor análise, três regiões estão em destaque nas Figuras 39(b)-(d).

Na primeira análise em destaque apresentada na Figura 39(b) percebe-se que a curva dada pelo fabricante é otimista, sempre prevendo a melhor produção possível dentre os dados reais obtidos para cada velocidade de vento, o que gera um erro de estimativa pelo gráfico do fabricante, visto que a maioria das produções reais alcançadas estão abaixo das estimadas pelo fabricante. As abordagens propostas são mais realistas e assim estimam uma produção realista. Deste modo, a curva de ambas abordagens propostas se encontram

no meio da nuvem de pontos, diminuindo o erro da estimativa em relação à curva otimista do fabricante.

Na segunda análise em destaque apresentada na Figura 39(c), o principal erro na estimativa de produção na curva dada pelo fabricante que superestima a produção de energia a partir da velocidade 8.5 m/s nos dados de vento, o que gera um erro ainda maior em relação a análise otimista do fabricante apresentada na análise da Figura 39(b). Analisando as abordagens propostas neste estudo, percebe-se que nesta região em que a velocidade do vento é acima de 9 m/s, o comportamento das curvas propostas deixa de ser similar, em que o modelo MQ se encontra mais ao centro da nuvem de pontos e o modelo logístico um pouco mais abaixo com uma análise um pouco mais pessimista da produção.


Por fim, a terceira análise apresentada na Figura 39(d) apresenta diversos dados reais de vento que estão bem distantes da curva, e que ocorreram por situações diversas ao longo do período analisado, o que podem ocorrer por limitação da produção desejada, ou por mal funcionamento do aerogerador, ou por período parado para manutenção ao longo de um mesmo dia, entre outros fatores. Vale ressaltar que estes pontos afastados da curva não foram usados para estimativa da curva de produção por estarem defasados dos demais na mesma faixa de produção em Watts. Esta análise não nos permite dizer a causa da queda de produção, mas permite uma análise mais detalhada do aerogerador e talvez melhorar o plano de manutenção e operação do equipamento, principalmente relatando que naquele período o aerogerador não estava em seu funcionamento normal.

5.4.2 Análise da produção do período em que a máquina não estava 100% disponível

Como uma segunda análise proveniente dos resultados deste trabalho, a Figura 40 apresenta uma aplicação do modelo MQ na análise de produção de aerogeradores que não tiveram sua disponibilidade 100% ao longo de um certo período.

A Figura 40 apresenta a produção diária de um aerogerador em azul, além da informação de disponibilidade do aerogerador e a velocidade de vento diária. A partir destes dados e utilizando a curva estimada pelo modelo MQ é possível estimar o quanto o equipamento teria produzido caso estivesse com a disponibilidade de 100% por todo o período, o que é extremamente útil no gerenciamento da produção de um parque eólico. Sendo assim, no período apresentado na Figura 40, o VSWT apresentou uma disponibilidade de 80,16% e produziu uma média de 6,9kWh. A partir do modelo calculado com a função logística de três parâmetros, calculamos que o mesmo VSWT teria produzido 9,8kWh caso estivesse com a disponibilidade de 100% em todo este período.

Figura 40 – Aplicação do modelo MQ na análise da produção de um período real em que a máquina estava parada.



Fonte: Autor.

5.4.3 Análise da sazonalidade dos ventos


Devido as massas de ar apresentarem comportamento sazonal, como visto no Seção 3.1, foi realizado uma análise da curva de potência dividindo as amostras de um ano em quatro períodos. Nos gráficos das Figuras 41(a)-(d) estão apresentados as curvas de potência divididas em quatro grupos com períodos de três meses diferentes. Para uma análise mais detalhada de cada trimestre citado na Figura 41, a Tabela 13 apresenta uma avaliação numérica das curvas de potência obtidas utilizando apenas os dados de cada período.

Tabela 13 – Análise dos modelos Sigmoide³ e MQ em cada trimestre do ano.

Trimestre	Modelo	RMSE	R^2
1	Logístico	46,3121	0,9740
	MQ	29,5934	0,9894
2	Logístico	36,4936	0,9908
	MQ	30,1203	0,9937
3	Logístico	54,4094	0,9780
	MQ	53,8885	0,9838
4	Logístico	56,8190	0,9820
	MQ	43,1923	0,9861

Nos meses de janeiro, fevereiro e março o aerogerador trabalha a maior parte do tempo com baixas velocidades de vento, como pode ser visto na Figura 41(a), as

Figura 41 – Análise sazonal das curvas de produção, considerando os meses: a) Janeiro, Fevereiro e Março; b) Abril, Maio, Junho; c) Julho, Agosto e Setembro; d) Outubro, Novembro e Dezembro.



Fonte: Autor.

velocidades do vento registradas nesse período são em maioria menores que 11 m/s. Além disso, têm-se uma nuvem de pontos menos espessa que os demais trimestres do ano, visto que em velocidades menores a oscilação também é menor. Neste período, os métodos de predição do vento MQ e logístico estão centralizados na nuvem de pontos da velocidade 7m/s até 9m/s e abaixo da curva após isto. Quanto aos modelos de predição da curva, o modelo MQ obtém os melhores valores de RMSE e R^2 , obtendo a melhor taxa de acerto em todos os períodos, o que se deve à baixa oscilação do vento em baixas velocidades.

No segundo trimestre, cuja a Figura 41(b) apresenta os dados do período de abril, maio e junho, percebe-se um aumento da velocidade do vento de forma moderada, e percebe-se um pequeno aumento da espessura da nuvem de pontos, principalmente nas velocidades acima de 10m/s. O modelo MQ se comporta de forma mais adequada neste período, estando no centro da nuvem de pontos por toda a curva, e assim obtém o melhor resultado dentre as curvas avaliadas, obtendo métricas de RMSE e R^2 pouco superiores ao período anterior, o que se deve à pequena variação da espessura da nuvem de pontos nas velocidades acima de 10m/s.

No terceiro trimestre, em que a Figura 41(c) apresenta os dados de produção dos meses de julho, agosto e setembro, têm-se a presença de mais pontos da nuvem na região acima de 10 m/s, o que torna o erro causado pela oscilação das altas velocidades maior, como pode ser observado na Tabela 13, em que este é o período com o maior erro apresentado nas métricas de RMSE e R^2 . No último período apresentado na Figura 41(d), referente aos meses de outubro, novembro e dezembro, percebe-se ainda um valor elevado no erro representado nas métricas RMSE e R^2 , mas ainda inferior ao terceiro trimestre do ano avaliado.

Segundo a FUNCEME (2017), o período do ano com maior intensidade de vento no estado do Ceará são os meses de agosto e setembro, mas já existe um valor elevado no mês de julho, o que confirma a análise realizada dos resultados da Tabela 13 e Figura 41, em que o terceiro trimestre é o período com maior intensidade de ventos. O quarto trimestre, segundo a mesma fonte, possui taxas elevadas similares ao mês de julho, mas inferior aos meses de agosto e setembro, confirmando também os resultados obtidos.

6 Conclusões

Podemos concluir, a partir dos resultados encontrados nas análises do capítulo anterior, que o modelo NAR tem capacidade para obter razoáveis estimativas de velocidade de vento para horizontes de 5 dias, enquanto o método SVR obtém melhores resultados, mas não para períodos elevados, já que os melhores resultados obtidos nos testes foi a previsão de três passos à frente. Além disto, concluímos que, para a etapa de modelagem da curva de potência, o método MQ é o mais adequado, dentro dos que foram aqui analisados inclusive superando a estimativa dada pelo fabricante, para modelar a curva de potência do aerogerador em estudo.

Concluimos também que realizar a predição de produção de energia é possível e eficaz, visto que as duas etapas intermediárias (predição da curva de potência e estimativa da velocidade do vento) foram realizadas de forma satisfatória, em que a melhor abordagem apresentada é utilizando o método NAR para estimar a velocidade do vento e o MQ para predição da curva de potência quando é necessário uma predição de energia de até 5 dias à frente, enquanto a melhor abordagem para períodos mais curtos é obtida pelo método SVR na estimativa da velocidade do vento e o MQ para predição da curva de potência.

Dentre as análises realizadas com as abordagens propostas, podemos concluir que as etapas de estimação da velocidade do vento e a modelagem da curva de potência podem ser utilizadas de forma separada, podendo, por exemplo, utilizar a estimativa de velocidade do vento para o planejamento das manutenções dos aerogeradores, programando as paradas da máquina para períodos de pouco vento ou até mesmo tornar o sistema de controle do aerogerador mais eficiente, visto que pontos muito distantes da curva estimada tendem a representar funcionamento fora do normal do aerogerador. Já a modelagem da curva de potência, além de contribuir na estimação de produção energética em períodos futuros, pode ser utilizada para calcular a potência não gerada em um momento que o aerogerador esteve parado para manutenção.

Uma análise sazonal da produção de energia foi realizada a partir da curva levantada para o período analisado, averiguando que nos períodos de altas velocidades de vento, terceira e quarto trimestre do ano, no Ceará percebe-se um maior erro na predição da energia devido uma maior variação do vento em velocidades elevadas, o que condiz com dados da FUNCEME.

6.1 Trabalhos futuros

Como trabalhos futuros têm-se alguns caminhos promissores à serem seguidos a partir dos resultados obtidos neste estudo, o que incluem:

- Estudar períodos mais longos que uma semana para estimar o vento, e assim analisar a produção de um aerogerador a longo prazo;
- Aplicar outros métodos de parametrização dos algoritmos para buscar melhores resultados na predição da curva de potência;
- Avaliar formas de paralelismo e otimização dos métodos computacionais empregados, principalmente do método NAR, visto que o mesmo necessita de hardware de alto desempenho no ato de sua execução, principalmente na estimativa de vento de longos períodos;
- Avaliar outros métodos para estimar a curva de potência, visto que mesmo o método MQ, que obteve os melhores resultados neste estudo, poderia ter melhores resultados em trechos da curva de potência, principalmente nos valores próximos à 11 m/s, em que a variação dos ventos é maior;
- Avaliar o desempenho dos métodos de modelagem da curva de potência em outros aerogeradores para confirmar qual o método mais adequado.
- Avaliar outros aerogeradores e regiões para averiguar se os resultados e análises encontrados se aplicam à outros locais e regiões;
- Aplicar a ferramenta na prática no gerenciamento de parques eólicos e averiguar quais análises e sub-produtos podem ser considerados para uma aplicação comercial.

Referências

- ABEEÓLICA. **Boletim de Dados Ago. 2016**. 2016. Disponível em: <<http://www.portalabeeolica.org.br/images/pdf/Boletim-de-Dados-ABEEolica-Agosto-2016-Publico.pdf>>.
- AFANASYEVA, S. et al. Technical, economic and uncertainty modelling of a wind farm project. **Energy Conversion and Management**, v. 107, p. 22–33, 2016.
- ANEEL. **Capacidade de Geração no Brasil**. [S.l.], 2017. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>>.
- AZAD, H. B.; MEKHILEF, S.; GANAPATHY, V. G. Long-term wind speed forecasting and general pattern recognition using neural networks. **Sustainable Energy, IEEE Transactions on**, v. 5, n. 2, p. 546–553, 2014.
- BARROS, A. L. B. P.; BARRETO, G. A. Extreme learning machine robusta para reconhecimento de faces. 2012.
- BRADSHAW, A. Regulatory change and innovation in Latin America: The case of renewable energy in Brazil. **Utilities Policy**, Elsevier Ltd, 2016.
- BROWN, B. G.; KATZ, R. W.; MURPHY, A. H. **Time Series Models to Simulate and Forecast Wind Speeds and Power**. 1984. 1184–1195 p.
- BURTON, T. et al. **Wind Energy Handbook**. [S.l.: s.n.], 2001. ISBN 0471489972.
- CARRILLO, C. et al. Review of power curve modelling for wind turbines. **Renewable and Sustainable Energy Reviews**, v. 21, p. 572 – 581, 2013. ISSN 1364-0321.
- CAVALCANTI NETO, E. **Desenvolvimento de sistema de Identificação e Reconhecimento Óptico de Algarismos Para Placas de Carros no Padrões Brasileiros**. Dissertação (Mestrado) — Instituto Federal de Educação, Ciência e Tecnologia, 2013.
- CAVALCANTI NETO, E. et al. Brazilian vehicle identification using a new embedded plate recognition system. **Measurement**, v. 70, p. 36 – 46, 2015. ISSN 0263-2241. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0263224115001852>>.
- CCEE. **Leilões**. 2017. Disponível em: <<https://www.ccee.org.br/>>.
- CEPEL. **Atlas do Potencial Eólico Brasileiro**. [S.l.: s.n.], 2001.
- CONRADSEN, K.; NIELSEN, L. B.; PRAHM, L. P. **Review of Weibull Statistics for Estimation of Wind Speed Distributions**. 1984. 1173–1183 p.
- DALBEM, M. C.; BRANDÃO, L. E. T.; GOMES, L. L. Can the regulated market help foster a free market for wind energy in Brazil?? **Energy Policy**, v. 66, n. 2013, p. 303–311, 2014.

DUTRA, R. **ENERGIA EÓLICA PRINCÍPIOS E TECNOLOGIAS**. [s.n.], 2008. Disponível em: <http://www.cresesb.cepel.br/download/tutorial/tutorial_eolica_2008_e-book.pdf>.

FAGIANI, R.; BARQUIN, J.; HAKVOORT, R. Risk-based assessment of the cost-efficiency and the effectivity of renewable energy support schemes: Certificate markets versus feed-in tariffs. **Energy Policy**, v. 55, p. 648 – 661, 2013. ISSN 0301-4215. Special section: Long Run Transitions to Sustainable Economic Structures in the European Union and Beyond. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0301421512011330>>.

FENG, J.; SHEN, W. Z. Wind farm power production in the changing wind: Robustness quantification and layout optimization. **Energy Conversion and Management**, v. 148, p. 905–914, 2017.

FLETCHER, R. **Practical Methods of Optimization**. 2. ed. [S.l.: s.n.], 2013. ISBN 9781118723203.

FUNCEME. **Elevação da velocidade do vento já é percebida em julho no Ceará**. 2017. Disponível em: <<http://www.funceme.br/index.php/comunicacao/noticias/809-eleva~ao-da-velocidade-do-vento-já-é-percebida-em-julho-no-ceará>>.

GE. **Analysis of Wind Generation Impact on ERCOT Ancillary Services Requirements**. [S.l.], 2008. 19 p.

GOMES, S. L. **Desenvolvimento de Sistema de Detecção e Reconhecimento Óptico de Caracteres Aplicados a Sinalização Vertical das Vias de Trânsito do Brasil**. Dissertação (Mestrado) — Instituto Federal de Educação, Ciência e Tecnologia, 2014.

GWEC. **Global Wind Report 2016**. [S.l.], 2017. 76 p. Disponível em: <<http://files.gwec.net/files/GWR2016.pdf>>.

GWEC. **Wind Energy Outlook: 2000 gigawatts by 2030**. 2017. Disponível em: <<http://www.gwec.net/wind-energy-outlook-2000-gigawatts-2030/>>.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2. ed. [S.l.: s.n.], 2001. ISBN 0-13-273350-1.

HEIER, S. **Grid Integration of Wind Energy Conversion Systems**. [S.l.: s.n.], 2003.

HOLTTINEN, H. Impact of hourly wind power variations on the system operation in the nordic countries. **Wind Energy**, v. 8, n. 2, p. 197–218, 2005.

HORATA, P.; CHIEWCHANWATTANA, S.; SUNAT, K. Robust extreme learning machine. **Neurocomputing**, v. 102, p. 31 – 44, 2013. ISSN 0925-2312. Advances in Extreme Learning Machines (ELM 2011). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231212004171>>.

HUANG, G. B. et al. Extreme learning machine for regression and multiclass classification. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 42, n. 2, p. 513–529, April 2012. ISSN 1083-4419.

- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. **Neurocomputing**, v. 70, n. 1–3, p. 489 – 501, 2006. ISSN 0925-2312. Neural Networks Selected Papers from the 7th Brazilian Symposium on Neural Networks (SBRN '04) 7th Brazilian Symposium on Neural Networks. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231206000385>>.
- JONG, P. de et al. Integrating large scale wind power into the electricity grid in the Northeast of Brazil. **Energy**, v. 100, p. 401–415, 2016.
- KARTHIKEYA, B.; SCHUTT, R. Overview of wind park control strategies. **Sustainable Energy, IEEE Transactions on**, v. 5, n. 2, p. 416–422, April 2014. ISSN 1949-3029.
- KATZENSTEIN, W.; APT, J. The cost of wind power variability. **Energy Policy**, v. 51, p. 233–243, 2012.
- KHALFALLAH, M. G.; KOLIUB, A. M. Suggestions for improving wind turbines power curves. **Desalination**, v. 209, n. 1–3, p. 221 – 229, 2007. ISSN 0011-9164. The Ninth Arab International Conference on Solar Energy (AICSE-9), Kingdom of Bahrain. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0011916407001221>>.
- KIVILUOMA, J. et al. A simple atmospheric boundary layer model applied to large eddy simulations of wind turbine wakes. **Wind Energy**, v. 17, n. April 2013, p. 657–669, 2015.
- KUHN, H.; TUCKER, A. Nonlinear programming. **Proceedings, Second Berkeley Symposium on Mathematical Statistics and Probabilistics**, p. 481–492, 1951.
- KUSIAK, A.; ZHENG, H.; SONG, Z. Models for monitoring wind farm power. **Renewable Energy**, v. 34, n. 3, p. 583 – 590, 2009. ISSN 0960-1481.
- KUSIAK, A.; ZHENG, H.; SONG, Z. On-line monitoring of power curves. **Renewable Energy**, v. 34, n. 6, p. 1487 – 1493, 2009. ISSN 0960-1481.
- LAHOUAR, A.; Ben Hadj Slama, J. Hour-ahead wind power forecast based on random forests. **Renewable Energy**, v. 109, p. 529–541, 2017.
- 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.
- LYDIA, M. et al. A comprehensive review on wind turbine power curve modeling techniques. **Renewable and Sustainable Energy Reviews**, v. 30, p. 452–460, 2014.
- LYDIA, M. et al. Wind resource estimation using wind speed and power curve models. **Renewable Energy**, v. 83, p. 425 – 434, 2015. ISSN 0960-1481.
- LYDIA, M. et al. Advanced algorithms for wind turbine power curve modeling. **Sustainable Energy, IEEE Transactions on**, v. 4, n. 3, p. 827–835, 2013. ISSN 194.
- LYDIA, M. et al. Advanced Algorithms for Wind Turbine Power Curve Modeling. p. 1–9, 2013.
- MAHELA, O. P.; SHAIK, A. G. Comprehensive overview of grid interfaced wind energy generation systems. **Renewable and Sustainable Energy Reviews**, v. 57, p. 260 – 281, 2016. ISSN 1364-0321. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1364032115014318>>.

- MENEZES, J. M. P.; BARRETO, G. A. Long-term time series prediction with the NARX network: An empirical evaluation. **Neurocomputing**, v. 71, n. 16-18, p. 3335–3343, 2008.
- MENEZES JÚNIOR, J. M. P. de. **Contribuições ao problema de predição recursiva de série temporais univariadas usando redes neurais recorrentes**. [S.l.: s.n.], 2013.
- MILLER, W. T.; GLANZ, F. H.; KRAFT, L. G. CMAC: An Associative Neural Network Alternative to Backpropagation. **Proceedings of the IEEE**, v. 78, n. 10, p. 1561–1567, 1990.
- OLIVEIRA, C.; ZULANAS, C.; KASHIWAGI, D. A Long-term Solution to Overcome the Problems Caused by Droughts in the Brazilian Power Systems. **Procedia Engineering**, v. 145, n. 480, p. 948–955, 2016.
- ONS. **Geração de Energia**. 2017. Disponível em: <http://www.ons.org.br/historico/geracao_energia.aspxf>.
- PANAHI, D.; DEILAMI, S.; MASOUM, M. A. S. Evaluation of parametric and non-parametric methods for power curve modelling of wind turbines. **2015 9th International Conference on Electrical and Electronics Engineering (ELECO)**, p. 996–1000, 2015.
- PARADA, L. et al. Wind farm layout optimization using a Gaussian-based wake model. **Renewable Energy**, Elsevier Ltd, v. 107, p. 531–541, 2017.
- PATEL, J. et al. Layout optimization of a wind farm to maximize the power output using enhanced teaching learning based optimization technique. **Journal of Cleaner Production**, v. 158, p. 81–94, 2017.
- PELLETIER, F.; MASSON, C.; TAHAN, A. Wind turbine power curve modelling using artificial neural network. **Renewable Energy**, Elsevier Ltd, v. 89, p. 207–214, 2016.
- PIAZZA, A. D.; PIAZZA, M. D.; VITALE, G. Estimation and forecast of wind power generation by ftdnn and narx-net based models for energy management purpose in smart grids. **algorithms**, v. 8, p. 10, 2014.
- RAHIMI, E. et al. On the management of wind power intermittency. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 28, n. x, p. 643–653, 2013.
- REIS, J. M. V. da S. **COMPORTAMENTO DOS GERADORES EÓLICOS SÍNCRONOS COM CONVERSORES DIANTE DE CURTO-CIRCUITOS NO SISTEMA**. Dissertação (Mestrado) — Instituto Alberto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia, 2013.
- ROLIK, Y. Risk Management in Implementing Wind Energy Project. **Procedia Engineering**, The Author(s), v. 178, p. 278–288, 2017.
- SANTOS, G. F.; HADDAD, E. A.; HEWINGS, G. J. D. Energy policy and regional inequalities in the Brazilian economy. **Energy Economics**, v. 36, p. 241–255, 2013.
- SATHYAJITH, M. **Wind Energy**. [S.l.: s.n.], 2014. ISBN 3642421563.

- SCHOPF, E. C. Método neuro-estatístico para predição de séries temporais ruidosas. 2007.
- Serrano González, J. et al. Maximizing the overall production of wind farms by setting the individual operating point of wind turbines. **Renewable Energy**, v. 80, p. 219–229, 2015.
- SHI, R. jing; FAN, X. chao; HE, Y. Comprehensive evaluation index system for wind power utilization levels in wind farms in China. **Renewable and Sustainable Energy Reviews**, v. 69, n. May 2016, p. 461–471, 2017.
- SHOKRZADEH, S.; Jafari Jozani, M.; BIBEAU, E. Wind turbine power curve modeling using advanced parametric and nonparametric methods. **IEEE Transactions on Sustainable Energy**, v. 5, n. 4, p. 1262–1269, 2014. ISSN 19493029.
- SLOOTWEG, J. G. **Wind Power: Modelling and Impact on Power System Dynamics**. Dissertation, 2003.
- SOUZA, R. C. S. N. P. **Algoritmos Online Baseados em Vetores Suporte para Regressão Clássica e Ortogonal**. 2013.
- SOVACOO, B. K. The intermittency of wind, solar, and renewable electricity generators: Technical barrier or rhetorical excuse? **Utilities Policy**, v. 17, n. 3-4, p. 288–296, 2009.
- STEWART, J. **Calculus**. 6. ed. [S.l.: s.n.], 2010. ISBN 978-85-221-0660-8.
- TASLIMI-RENANI, E. et al. Development of an enhanced parametric model for wind turbine power curve. **Applied Energy**, v. 177, p. 544–552, 2016.
- THAPAR, V.; AGNIHOTRI, G.; SETHI, V. K. Critical analysis of methods for mathematical modelling of wind turbines. **Renewable Energy**, v. 36, n. 11, p. 3166 – 3177, 2011. ISSN 0960-1481.
- THOMAS, T.; CHERIYAN, E. P. Wind energy system for a laboratory scale micro-grid. In: **Electrical, Electronics and Computer Science (SCEECS), 2012 IEEE Students' Conference on**. [S.l.: s.n.], 2012. p. 1–5.
- TRIVELLATO, F.; BATTISTI, L.; MIORI, G. The ideal power curve of small wind turbines from field data. **Jnl. of Wind Engineering and Industrial Aerodynamics**, Elsevier, v. 107-108, p. 263–273, 2012.
- UMMELS, B. C. et al. Integration of wind power in the liberalized dutch electricity market. **Wind Energy**, v. 9, n. 6, p. 579–590, 2006. ISSN 10954244.
- VALODKA, I.; VALODKIEN, G. The Impact of Renewable Energy on the Economy of Lithuania. **Procedia - Social and Behavioral Sciences**, v. 213, p. 123–128, 2015.
- VAPNIK, A. Y. L. V. F. Pattern recognition using generalized portrait method. **Automation and Remote Control**, v. 24, p. 774–780, 1963.
- VAPNIK, V. F. The nature of statistical learning theory,. 1995.
- VAPNIK, V. F.; KAUFMAN, A. J. S. H. D. C. J. B. L. Support vector regression machines. **Advances in neural information processing systems**, p. 155–161, 1997.

VELO, R.; LÓPEZ, P.; MASEDA, F. Wind speed estimation using multilayer perceptron. **Energy Conversion and Management**, v. 81, p. 1–9, 2014.

VENYS. **VENYS 82 - Technical data**. [S.l.], 2012.

VILLANUEVA, D.; FEIJÓO, A. E. Reformulation of parameters of the logistic function applied to power curves of wind turbines. **Electric Power Systems Research**, v. 137, p. 51 – 58, 2016. ISSN 0378-7796. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378779616300992>>.

WAN, C. et al. Probabilistic forecasting of wind power generation using extreme learning machine. **IEEE Transactions on Power Systems**, v. 29, n. 3, p. 1033–1044, May 2014. ISSN 0885-8950.

WANG, J.; HU, J. A robust combination approach for short-term wind speed forecasting and analysis - Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts. **Energy**, v. 93, p. 41–56, 2015.

WEBB, A. R. **Statistical Pattern Recognition**. 2. ed. [S.l.: s.n.], 2002.

YESILBUDAK, M.; SAGIROGLU, S.; COLAK, I. A new approach to very short term wind speed prediction using k-nearest neighbor classification. **Energy Conversion and Management**, v. 69, p. 77–86, 2013.

YUAN, S.; PENG, S. Trends in the economic return on energy use and energy use efficiency in China's crop production. **Renewable and Sustainable Energy Reviews**, v. 70, n. May, p. 836–844, 2017.

ZOLFAGHARI, S.; RIAHY, G. H.; ABEDI, M. A new method to adequate assessment of wind farms' power output. **Energy Conversion and Management**, v. 103, p. 585–604, 2015.