

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
ENGENHARIA ELÉTRICA – ENERGIA

MATHEUS CARVALHO GOUVEIA

**IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL PARA PREVISÃO DE
CURTO PRAZO DA POTÊNCIA EÓLICA DISPONÍVEL**

**Juiz de Fora
2020**

MATHEUS CARVALHO GOUVEIA

**IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL PARA PREVISÃO DE
CURTO PRAZO DA POTÊNCIA EÓLICA DISPONÍVEL**

Dissertação apresentada como Trabalho de Conclusão de Curso para obtenção do título de Bacharel em Engenharia Elétrica – Habilitação em Energia na Faculdade de Engenharia da Universidade Federal de Juiz de Fora.

Orientador: Prof. Leonardo Willer de Oliveira

**Juiz de Fora
2020**

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Gouveia, Matheus Carvalho.

Implementação de uma Rede Neural Artificial para previsão de curto prazo da potência eólica disponível / Matheus Carvalho

Gouveia. -- 2020.

63 p.

Orientador: Leonardo Willer de Oliveira

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia, 2020.

1. Energia Eólica. 2. Redes Neurais Artificiais. 3. Previsão do Vento. 4. Estimação de Energia. 5. Mercado de Energia. I. Oliveira, Leonardo Willer de, orient. II. Título.

MATHEUS CARVALHO GOUVEIA

**IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL PARA PREVISÃO DE
CURTO PRAZO DA POTÊNCIA EÓLICA DISPONÍVEL**

Dissertação apresentada como Trabalho de Conclusão de Curso para obtenção do título de Bacharel em Engenharia Elétrica – Habilitação em Energia na Faculdade de Engenharia da Universidade Federal de Juiz de Fora.

BANCA EXAMINADORA

Leonardo Willer de Oliveira - Orientador
Universidade Federal de Juiz de Fora

Bruno Henriques Dias
Universidade Federal de Juiz de Fora

Aprovada em _____ de _____ de _____.

AGRADECIMENTOS

Ao fim de longas e árduas jornadas como essa, é necessário dar os devidos agradecimentos às pessoas que sempre estiveram ao nosso lado, constantemente nos apoiando no que fosse. Agradeço primeiramente aos meus pais Ana Cláudia e José Flávio pelo eterno apoio, incentivo e encorajamento, e por tornar, sob todas as medidas, possível a minha graduação. Em segundo lugar, agradeço às minhas irmãs Isabela e Ana Clara por toda a assistência, apoio e companhia em todos os momentos.

Às famílias Carvalho e Gouveia e a todos os meus amigos, que me guiaram e me ajudaram a trilhar o caminho até aqui. Obrigado a todos vocês pelo carinho, pelas brincadeiras e pelas viagens aventureiras por esse Brasil afora.

Agradeço, por fim, ao meu orientador Leonardo Willer de Oliveira pelo direcionamento na elaboração deste trabalho e também pelo suporte durante a conclusão da minha graduação.

A todos vocês obrigado, serei eternamente grato. *Live long and prosper.*

“Se você acha que pode fazer algo ou se acha que não pode, de qualquer forma, você está certo.”

Henry Ford.

RESUMO

Neste trabalho, foi estudada e aplicada uma técnica que utiliza modelagem computacional através de *Deep Learning* com a implementação de uma Rede Neural Artificial (RNA) para estimação da energia eólica disponível para a geração de energia elétrica. Portanto, o foco deste trabalho de conclusão de curso em Engenharia Elétrica - Energia é uma rede neural para realizar a previsão *hour-ahead* da velocidade do vento a partir de séries temporais obtidas pelo Sistema de Organização Nacional de Dados Ambientais (SONDA), da estação de Natal – RN. A partir da previsão da velocidade do vento, podem ser estimadas a potência e a energia disponíveis no local num período futuro. Os dados de entrada da rede neural utilizados foram pressão atmosférica (atm), umidade relativa do ar (%), temperatura (°C) e a velocidade do vento no momento da previsão (m/s). A rede tem como saída a velocidade do vento (m/s) prevista para as horas seguintes. Para treinamento e teste da rede, foram utilizados os dados do mês de janeiro do ano de 2016. Para estimativa da energia eólica, utilizou-se a curva de potência da turbina Verne 555 (Enersud). Foram obtidos também parâmetros como o fator de capacidade previsto da turbina e direção média do vento. Finalmente, discorreu-se sobre a eficácia do método proposto em comparação com os métodos vigentes no mercado, incluindo os métodos físicos que são utilizados para previsões a longo prazo.

Palavras-chave: 1.Energia Eólica. 2.Redes Neurais Artificiais. 3.Previsão do vento. 4.Estimação de Energia. 5. Mercado de Energia.

ABSTRACT

This paper consists of a study and application of a technique that uses computational modeling through Deep Learning with the implementation of an Artificial Neural Network (ANN) to estimate the available wind energy for electric power generation. Therefore, the focus of this paper, a course conclusion in Electrical Engineering – Energy, is a neural network to perform a hour-ahead wind speed prediction from the time series obtained by the National Organization System of Environmental Data (*Sistema de Organização Nacional de Dados Ambientais - SONDA*) of the station in Natal – RN, Brazil. From the prediction of wind speed, it is possible to estimate the available power and energy at the location, at a future time. The input data of the neural network used were atmospheric pressure (atm), relative air humidity (%), temperature (°C) and wind speed at the moment of forecast (m/s). The net output is the forecasted wind speed (m/s) for the following hours. For training and testing the network, it was used data from January 2016. To estimate wind power, the power curve from the turbine Verne 555 (Enersud) was applied. Parameters such as the predicted turbine capacity factor and mean wind direction were also obtained. Finally, it is discussed the effectiveness of the proposed method in comparison with current market methods, including the physical methods used for long-term forecasting.

Keywords: 1.Wind Energy. 2. Artificial Neural Network. 3. Wind Forecasting. 4. Energy Estimation. 5. Energy Market.

LISTA DE ILUSTRAÇÕES

Figura 1 – Instituições do setor elétrico brasileiro.....	17
Figura 2 – Potencial Eólico Brasileiro.....	22
Figura 3 – Efeito da viscosidade na velocidade do vento.....	24
Figura 4 – Disposição das turbinas no parque eólico.....	28
Figura 5 – Tipos de turbina eólica.....	28
Figura 6 – Anemômetro digital, modelo AN-1C da S&E instrumentos.....	30
Figura 7 – Estrutura de uma RNA.....	33
Figura 8 – Modelagem da RNA.....	34
Figura 9 – Amostras de treinamento, validação e teste.....	39
Figura 10 – Estrutura da RNA do modelo.....	41
Gráfico 1 – Matriz Elétrica Nacional em 2018.....	14
Gráfico 2 – Matriz Energética Mundial em 2016.....	15
Gráfico 3 – Preço de Compensação Marginal.....	19
Gráfico 4 – Curvas de Weibull para diferentes fatores de forma.....	23
Gráfico 5 – Exemplo de ajuste pela distribuição de Weibull.....	24
Gráfico 6 – Efeito da altura na velocidade do vento pelo modelo exponencial.....	25
Gráfico 7 – Rosa dos ventos.....	26
Gráfico 8 – Curva de potência ideal das turbinas.....	29
Gráfico 9 – Curva de potência real das turbinas.....	29
Gráfico 10 – Função Sigmoid Hiperbólica.....	35
Gráfico 11 – Distribuição do vento em Natal, RN.....	36
Gráfico 12 – Rosa dos ventos em Natal, RN, no mês de janeiro.....	36
Gráfico 13 – Medições da velocidade do vento a cada minuto.....	37
Gráfico 14 – Medições da Umidade Relativa e Temperatura a cada minuto.....	37
Gráfico 15 – Medições da pressão atmosférica a cada minuto.....	38
Gráfico 16 – Erro médio nos conjuntos de validação e treinamento.....	39
Gráfico 17 – Curva de Potência da Turbina.....	45
Gráfico 18 – Curva de potência ideal considerada.....	45
Gráfico 19 – Previsão com horizonte de 1h ao longo de um período de 24h.....	47
Gráfico 20 – Treinamento da rede com horizonte de previsão de 1h.....	47
Gráfico 21 – Previsão 1 <i>Hour-Ahead</i> da velocidade do vento ao longo de 36h.....	48

Gráfico 22 – Regressão do treinamento e da validação no modelo 1 <i>Hour-Ahead</i>	48
Gráfico 23 – Previsão 1 <i>Hour-Ahead</i> da potência eólica teórica disponível.....	49
Gráfico 24 – Previsão 1 <i>Hour-Ahead</i> da potência eólica aproveitável.....	49
Gráfico 25 – Previsão 1 <i>Hour-Ahead</i> da potência eólica aproveitável a 50 metros.....	50
Gráfico 26 – Previsão com horizonte de 2h ao longo de um período de 24h.....	51
Gráfico 27 – Previsão com horizonte de 4h ao longo de um período de 24h.....	51
Gráfico 28 – Previsão com horizonte de 6h ao longo de um período de 24h.....	52
Gráfico 29 – Treinamento da rede com horizonte de previsão de 6 h.....	53
Gráfico 30 – Previsão com horizonte de 1h com treinamentos múltiplos.....	53
Gráfico 31 – Previsão com horizonte de 6h com treinamentos múltiplos.....	54
Gráfico 32 – Regressão do treinamento e da validação no modelo 4 <i>Hour-Ahead</i>	54
Gráfico 33 – Erro quadrático no treinamento e validação.....	55
Gráfico 34 – Previsão <i>Day-Ahead</i> com algoritmo sequencial, com faixa de incerteza.....	56
Gráfico 35 – Previsão <i>Day-Ahead</i> com inclusão de 2 janelas, com faixa de incerteza.....	56

LISTA DE TABELAS

Tabela 1 – Coeficiente de atrito de acordo com as características do terreno.....	25
Tabela 2 – Porcentagem dos conjuntos na amostra.....	41
Tabela 3 – Especificações da Turbina.....	44
Tabela 4 – Comparação entre medições e previsões com horizonte de 1h.....	50
Tabela 5 – Comparação entre medições e previsões com horizonte de 2h.....	50
Tabela 6 – Comparação entre medições e previsões com horizonte de 4h.....	52
Tabela 7 – Comparação entre medições e previsões com horizonte de 6h.....	52
Tabela 8 – Comparação entre os valores com horizontes de previsão distintos.....	55

LISTA DE ABREVIATURAS E SIGLAS

ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulada
AI	Inteligência Artificial
ANEEL	Agência Nacional de Energia Elétrica
AR	<i>Auto Regressive</i>
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
CCEE	Câmara de Comercialização de Energia Elétrica
CMSE	Comitê de Monitoramento do Setor Elétrico
CNPE	Conselho Nacional de Política Energética
DAM	<i>Day-Ahead Market</i>
DL	<i>Deep Learning</i>
DR	<i>Demand Response</i>
EPE	Empresa de Pesquisa Energética
FC	Fator de Capacidade
IEA	<i>International Energy Agency</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MATLAB	<i>Matrix Laboratory</i>
MCP	<i>Market Clearing Price</i>
MIBEL	Mercado Ibérico de Energia Eólica
ML	<i>Machine Learning</i>
MME	Ministério de Minas e Energia
MSE	<i>Mean Squared Error</i>
ONS	Operador Nacional do Sistema Elétrico

PROCEL	Programa Nacional de Conservação de Energia Elétrica
RMSE	<i>Root Mean Squared Error</i>
RNA	Rede Neural Artificial
SE	<i>State Estimation</i>
SGD	<i>Stochastic Gradient Descent</i>
SIN	Sistema Interligado Nacional
SONDA	Sistema de Organização Nacional de Dados Ambientais
UFJF	Universidade Federal de Juiz de Fora
UTHEIL	Coeficiente U de Theil

LISTA DE SÍMBOLOS

k	Fator de Forma
C	Fator de Escala
v	Velocidade
$P(v)$	Probabilidade da velocidade v
H	Altura
Γ	Função Gama
\bar{x}	Valor Médio
x_0	Valor Inicial
m	Massa de ar passante
E	Energia Cinética
P	Potência Eólica
C_p	Coefficiente de Potência
C_{pmax}	Limite de Lanchester-Betz-Joukowsky
α	Coefficiente de Atrito de Hellman
$\frac{d}{dt}$	Derivada de uma função do tempo
$\left. \frac{d}{dt} \right _{t=a}$	Derivada de uma função do tempo no ponto a
ρ	Densidade do Ar
$\int dt$	Integral Indefinida no tempo
$\int_{t_1}^{t_2} dt$	Integral definida no tempo
η	Eficiência do gerador
$F[n]$	Função de valores discretos

$F(t)$	Função do tempo
φ	Função de Ativação
δ	Taxa de Aprendizagem
e^x	Função exponencial natural
Σ	Somatório
v_j	Elemento j do vetor v
x_i	i-ésimo sinal de entrada
w_{ji}	Peso entre o sinal de entrada i e o neurônio j
b_j	Parâmetro “bias”
y_j	Saída do neurônio j
$t_{periodo}$	Tempo decorrido no período em questão
V	Volume
π	Proporção numérica pi
D	Diâmetro
$v_{prev,i}$	Velocidade prevista i
$v_{real,i}$	Velocidade real i

SUMÁRIO

1.	INTRODUÇÃO	14
1.1.	Contexto.....	14
1.2.	Objetivo do trabalho.....	15
1.3.	Estrutura da monografia.....	16
2.	PLANEJAMENTO DO SETOR ELÉTRICO	17
2.1.	Resumo do capítulo.....	17
2.2.	Diretrizes do planejamento e Mercados de Energia.....	17
2.3.	Mercados <i>Day-Ahead</i>	18
2.4.	A importância da previsão no planejamento.....	20
2.5.	A Energia Eólica.....	20
2.5.1.	Histórico.....	20
2.5.2.	Modelagens e definições.....	22
2.6.	Conclusões parciais do capítulo.....	30
3.	MÉTODO EMPREGANDO REDES NEURAS ARTIFICIAIS	32
3.1.	Resumo do Capítulo.....	32
3.2.	<i>Machine Learning</i> e Redes Neurais Artificiais.....	32
3.3.	Metodologia.....	35
3.3.1.	Processamento dos dados.....	35
3.3.2.	Treinamento, Validação e Teste.....	38
3.3.3.	A Rede Neural.....	40
3.3.4.	CrITÉRIOS de acurácia.....	41
3.3.5.	Análises adicionais.....	42
3.3.6.	Previsão da potência e estimação da energia disponível.....	43
3.4.	Conclusões parciais do capítulo.....	45
4.	RESULTADOS	46
4.1.	Resumo do capítulo.....	46
4.2.	Desempenho da Rede.....	46
4.3.	Conclusões parciais.....	57
5.	CONCLUSÕES	58

5.1.	Conclusões Finais.....	58
5.2.	Desenvolvimentos Futuros.....	59
	REFERÊNCIAS.....	60
	ANEXO – Especificações da Turbina Verne 555	63


1. INTRODUÇÃO

1.1. Contexto

Diante do contexto atual de diversificação da matriz energética mundial, há uma necessidade cada vez maior de aprimorar as diferentes tecnologias de obtenção de energia. Nesse cenário, a atuação do engenheiro eletricista nas áreas de energia e potência se torna cada vez mais ampla, cobrindo um universo vasto de possibilidades de pesquisa em diversas áreas do conhecimento, sendo temas como fontes alternativas, *Smart Grids*, mercados de energia, operação de sistemas integrados e planejamento energético alguns exemplos muito comuns de estudo no presente momento. A área de energia, não apenas na engenharia, é hoje responsável por intensa pesquisa em todo o mundo devido à crescente diligência por um futuro mais sustentável, mais focado em energias renováveis e alternativas. O conceito de sustentabilidade é hoje um ideal em ascensão, sendo constantemente exigido em todo o planeta, sobre o qual a exigência do desenvolvimento tecnológico mantendo o compromisso com as gerações futuras é imprescindível e inevitável.

Alcançar a meta de sustentabilidade, no entanto, se mostra um dos maiores desafios da idade contemporânea a serem enfrentados pelo homem, que deve não apenas manter a sua imensa demanda energética, mas aumentá-la para atender às necessidades de um mundo em desenvolvimento tecnológico acelerado, cuja população cresce a cada ano. Desde a primeira revolução industrial, as fontes de energia predominantes são as provenientes dos combustíveis fósseis – o petróleo, o carvão e o gás natural. Até hoje, os combustíveis fósseis cobrem cerca de 80% da matriz energética e 65% da matriz elétrica mundiais. O Brasil, por sua vez, tem maior parte da sua matriz elétrica proveniente de energias renováveis, que cobrem cerca de 83,2% da matriz elétrica do país. O Gráfico 1 ilustra a Matriz Elétrica brasileira.

Gráfico 1 – Matriz Elétrica Nacional em 2018.




Fonte: BEN-2019, EPE, 2019.

Os recursos energéticos são responsáveis por disputas geopolíticas desde a primeira revolução industrial, e, nos últimos anos, a questão energética tem gerado novos debates sobre consumo, recursos naturais e mudanças climáticas. Têm sido debatidas as questões que envolvem o dilema energético, o conceito que parte da contradição inicial entre dobrar a meta energética e, ao mesmo tempo, reduzir pela metade a emissão de gases poluentes e causadores

do efeito estufa. A contradição ocorre porque maior parte dos processos energéticos que acontecem em todo o mundo ainda estão ligados aos combustíveis fósseis e, portanto, às emissões dos gases do efeito estufa. Logo, o cumprimento da meta, a princípio, parece incompatível com a realidade da produção de energia no mundo hoje. Não obstante, organizações como a *International Energy Agency* (IEA) e, no Brasil, a Empresa de Pesquisa Energética (EPE) têm encontrado medidas para reduzir o desperdício a partir de programas como o “*Sustainable Development Goal*” (SDGs), o “*The Energy Efficiency in Emerging Economies*” (E4) e o “Programa Nacional de Conservação de Energia Elétrica” (PROCEL), que buscam alertar a população e colocar em prática as ideias de eficiência energética para atender às demandas evitando o desperdício de energia.

No Gráfico 2, está ilustrada a Matriz Energética mundial em 2016. Os países desenvolvidos foram os grandes impulsionadores de avanços tecnológicos que tiveram suma importância no desenvolvimento de novas fontes renováveis de energia, entre elas a eólica e solar. Entretanto, muitos países em desenvolvimento, como o Brasil, estão a cada ano investindo mais nessas fontes, o que leva à maior participação dessas novas tecnologias nas suas respectivas matrizes energéticas. No caso da energia eólica, o investimento tem crescido exponencialmente no Brasil. Em alguns leilões recentes, apresentou competitividade frente à fonte hídrica, que é historicamente a mais competitiva. As formas de geração solar e eólica ganharam grande evidência também no cenário internacional. O mercado de energia eólica, por se apresentar em estágio de tecnologia madura a preços competitivos, foi impulsionado por esse contexto e apresentou crescimento nos últimos anos.



Fonte: International Energy Agency, 2018.

1.2. Objetivo do Trabalho

Dada a importância da energia eólica tanto no contexto nacional quanto no contexto mundial, a presente monografia de conclusão de curso tem como objetivo investigar o potencial de aplicação de ferramentas computacionais para previsão de geração eólica. Mais

especificamente, o presente trabalho objetiva desenvolver uma rede neural artificial para aplicação ao problema da previsão eólica.

1.3. Estrutura da Monografia

Além deste capítulo introdutório, a presente monografia de conclusão de curso dispõe de outros quatro capítulos. O capítulo dois trata do planejamento do setor elétrico, elucidando conceitos como políticas energéticas e mercados de energia, além de discorrer sobre os mercados de energia *Day-Ahead*. Finalmente, traz conhecimentos importantes sobre a energia eólica no Brasil e no mundo, contextualizando essa forma de geração e explicitando alguns aspectos técnicos que serão importantes posteriormente na elaboração deste trabalho.

O capítulo três discute as redes neurais artificiais, explicando a sua origem e sua relevância no mundo hoje, além de apresentar conceitos introdutórios a respeito do tema, que serão fundamentais para o desenvolvimento deste trabalho. No mesmo capítulo, a metodologia é proposta e são feitas algumas observações iniciais sobre os dados da região escolhida.

No quarto capítulo, são apresentados os resultados obtidos pela rede neural artificial proposta, com o uso de gráficos e tabelas, aplicando os métodos enunciados no capítulo anterior.

O capítulo cinco conclui o estudo, discutindo os resultados obtidos pela rede mostrados no capítulo anterior, trazendo também algumas ideias para desenvolvimentos futuros com base no contexto atual e nas expectativas para os próximos anos.

2. PLANEJAMENTO DO SETOR ELÉTRICO

2.1. Resumo do capítulo

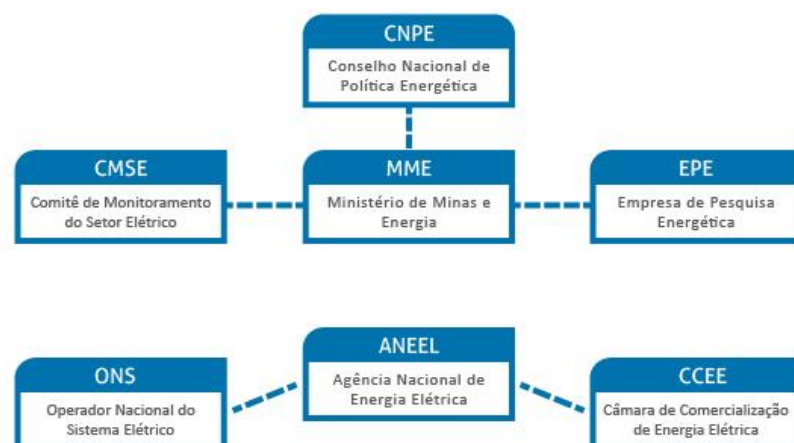
Neste capítulo, serão discutidos os desafios da inserção de energias renováveis de natureza intermitente, como a energia solar e a própria energia eólica, nos sistemas de energia elétrica. Serão apresentados os problemas trazidos pela imprevisibilidade dos sistemas eólicos e as diferentes abordagens existentes para contorná-los. Conceitos como mercado de energia, planejamento energético e operação do sistema elétrico também serão mencionados e explicados, a fim de legitimar a aplicabilidade deste estudo no cenário atual. Finalmente, serão apresentados conceitos fundamentais para o entendimento dos sistemas de geração eólica, contextualizando essa forma de energia.

2.2. Diretrizes do planejamento e Mercados de Energia

Nos sistemas integrados de eletricidade, há colaboração entre várias entidades, tais como as instituições de política energética, as agências de fiscalização e regulamentação, os operadores dos sistemas interligados, as agências de comercialização, as empresas de pesquisa, entre outros. Tudo isso funciona para manter o sistema constantemente alinhado em termos de produção e demanda, atendendo aos consumidores de maneira politicamente e economicamente viável. Isto é, a geração e o consumo de energia do sistema elétrico devem ser balanceados, e tanto a falta de energia gerada em relação à demanda quanto seu excesso podem trazer prejuízos ao sistema, danificando equipamentos, prejudicando a qualidade da energia ou levando a quedas no fornecimento.

Há uma hierarquia para o funcionamento de todo o setor elétrico, de forma a planejar, antecipar e executar as ações, permitindo a adaptação às novas tecnologias e mantendo o atendimento seguro, econômico e ambiental e socialmente sustentável. A Figura 1 mostra o esquema brasileiro para a tomada de ações no setor elétrico. As instituições e seus papéis são divididos como se segue:

Figura 1 – Instituições do setor elétrico brasileiro.



Fonte: CCEE.

- CNPE: É responsável pela formulação das políticas e diretrizes energéticas;
- MME: Implementa políticas para o setor energético de acordo com o CNPE;

- EPE: Destinada à realização de pesquisas importantes para planejamento da expansão e planejamento energético. Atua em diversas áreas como: Energia Elétrica, Estatísticas, Economia de Energia, Petróleo, Gás e Biocombustíveis, etc;
- CMSE: Acompanha e avalia permanentemente a continuidade e a segurança do suprimento elétrico em todo o território nacional; também recomenda ações preventivas;
- ONS: Responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN) e pelo planejamento da operação dos sistemas isolados do país, sob a fiscalização e regulação da ANEEL;
- ANEEL: Regula e fiscaliza a produção, transmissão, distribuição e comercialização de energia elétrica;
- CCEE: Responsável por viabilizar e gerenciar a comercialização da energia elétrica no país nos Ambientes de Contratação Regulada (ACR) e Contratação Livre (ACL), além de efetuar a contabilização e a liquidação financeira das operações realizadas no mercado de curto prazo.

Alguns exemplos de mercados da Europa e nos EUA são o Mercado Ibérico de Energia Elétrica (MIBEL), que é uma cooperação entre os governos de Portugal e da Espanha com o objetivo de promover integração dos sistemas elétricos dos dois países e o PJM (*Pennsylvania-Jersey-Maryland*), que é responsável por dirigir a operação do sistema de transmissão do nordeste americano e por coordenar as subestações do sistema de transmissão, sem fins lucrativos e independente de seus participantes. Nos mercados de energia, ocorrem as negociações de compra e venda de energia; podem se referir a mercados de eletricidade, mas também a outras formas de energia. Normalmente, o desenvolvimento energético é resultado de uma política de energia que incentiva o desenvolvimento de maneira competitiva. No Brasil, as relações comerciais no atual modelo se estabelecem no ACR e no ACL. A compra e a venda da energia no ambiente regulado são formalizadas por meio de contratos celebrados entre os geradores e os distribuidores, que participam dos leilões de compra e venda de energia. Os contratos deste ambiente têm regulação específica para aspectos como preço da energia, submercados de registro do contrato e vigência de suprimento, não passíveis de alterações bilaterais pelos agentes. Já no ambiente livre, os geradores, comercializadores, importadores e exportadores de energia e consumidores livres e especiais têm liberdade para negociar e estabelecer em contratos os volumes de compra e venda de energia e seus respectivos preços. Todos os contratos firmados nos ambientes livre e regulado são registrados na CCEE.

2.3. Mercados *Day-Ahead*

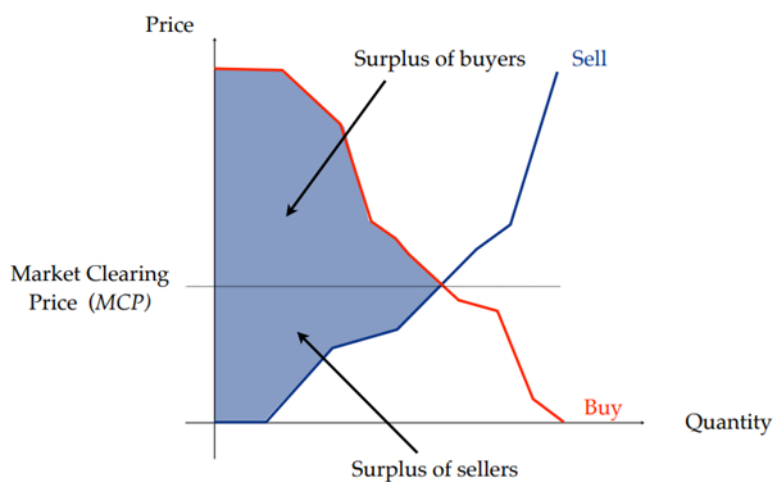
Nos mercados *Day-Ahead* (*Day-Ahead Market* – DAM), os negócios de compra e venda de energia, que consistem em leilões, são realizados para o dia seguinte; dessa forma, os participantes do mercado fazem os lances especificando a quantidade de energia máxima e mínima e os preços máximos e mínimos que estão dispostos a vender ou a comprar. As sessões ocorrem em horários especificados, no dia anterior ao dia de entrega da energia comprada. As ofertas são aceitas de acordo com termos econômicos e levando em consideração também as limitações do sistema de transmissão. Todas as ofertas são avaliadas com base no preço de

compensação marginal (*Market Clearing Price*), que é determinado a cada hora pela intersecção das curvas de demanda e oferta da zona à qual pertencem.

Atualmente, os mercados *Day-Ahead* esperam vários desafios para o futuro, como por exemplo a integração dos sistemas com inserção de geração distribuída e energias renováveis intermitentes. Principalmente, tem-se em vista as expectativas futuras para a presença de *Smart Grids*. Nos últimos anos, a introdução dos programas de resposta à demanda (*Demand Response* – DR) trouxe novas soluções para os mercados lidarem com esses problemas; o DR é definido como o conjunto de tarifas ou programas que motivam as mudanças no consumo de eletricidade pelos clientes do mercado de eletricidade. Atualmente, alguns sistemas operadores independentes nos EUA oferecem dois tipos principais de programas de DR: a redução de demanda e os programas de demanda por resposta a preços. Em programas de redução de demanda oferecidos pela PJM, entidades consumidoras são compensadas pela redução da demanda em lances nos mercados *Day-Ahead*. Em programas de demanda por resposta a preços oferecidos por outros mercados, a demanda das entidades consumidoras pode ser modificada quando o preço muda.

Quanto à inserção da energia eólica, para garantir confiabilidade da operação e um planejamento eficiente, deve-se analisar o impacto da energia eólica nos sistemas de energia. A própria variabilidade da potência eólica gerada causa impactos não só nas redes, mas nos próprios mercados de eletricidade por causar variações nos preços de oferta em função da oscilação do preço de compensação, ilustrado no Gráfico 3. É claro que esses impactos serão muito mais relevantes quanto maior for a presença de energia eólica na matriz elétrica, e, portanto, nos mercados locais.

Gráfico 3 – Preço de Compensação Marginal



Fonte: How the European day-ahead electricity market works, 2017.

Na China, é interessante mencionar que a agência de Administração Nacional de Energia requer os dados de todos os parques eólicos conectados às redes para instalar o Sistema de Previsão de Energia Eólica (*Wind Power Forecast System – WPFS*), e assim fornecer previsões com horizonte de 24 horas, ou até mais. Na prática, no entanto, o erro de previsão do dia seguinte geralmente está longe do desejável se forem utilizadas apenas RNAs e métodos de análises de séries temporais. Dessa forma, muitos estudos vêm investigando sobre a escolha do melhor algoritmo de previsão para resolver o problema considerando apenas horizontes curtos, com menos de 6 horas. Os participantes dos mercados precisam lidar com a variabilidade da produção de energia eólica para minimizar os equívocos nas negociações.

2.4. A importância da previsão no planejamento

Diferentemente de outras fontes de energia, a energia eólica tem um forte aspecto de intermitência, algo que pode trazer complicações para os sistemas de eletricidade. A capacidade de geração de energia de uma usina eólica depende de condições ambientais, que podem variar consideravelmente ao longo do dia, dificultando a previsão da capacidade de geração de energia num determinado momento. Essa imprevisibilidade traz dificuldades técnicas e comerciais para a operação do sistema de energia elétrica; o operador deve aumentar ou reduzir a quantidade de energia gerada para atender a essa demanda. O problema reside no fato de que, nas energias intermitentes com maior variação, não há garantia de suprimento de energia num determinado instante. A complexidade é ainda maior quanto maior for a participação dessas fontes de energia na matriz elétrica. No Brasil, a energia elétrica é proveniente principalmente de hidrelétricas de grande porte, sendo que as usinas térmicas também desempenham papel fundamental, pois complementam a geração hidrelétrica em períodos de estiagem e em horários de pico.

Além disso, a baixa confiabilidade na quantidade da energia disponível num determinado instante exige que as operadoras tenham uma fonte de energia alternativa que possa ser acionada rapidamente para atender a demanda do sistema. Esse suprimento normalmente é feito através de outras fontes de energia mais confiáveis, como as termelétricas, o que pode aumentar os custos de operação do sistema.

Empresas têm investido em inovações tecnológicas para prever de forma mais eficaz a energia disponível e tornar as fontes intermitentes mais “previsíveis”. Recentemente, o Google através da *DeepMind*, anunciou que está aplicando técnicas de ML para prever a capacidade de geração de energia de parques eólicos da empresa nos EUA. Dados históricos das turbinas eólicas e previsões do tempo foram utilizados para treinar redes neurais capazes de fazer uma previsão razoável da potência gerada ao longo do dia pelas turbinas com horizonte de até 36 horas. Com base nessas previsões, modelos foram utilizados para criar recomendações ótimas para negociação da energia gerada.

A previsibilidade, por sua vez, agrega confiabilidade aos operadores dos sistemas elétricos, que poderão planejar adequadamente o uso da energia para atender à demanda em tempo real. Tudo isso possibilita o aumento da participação das energias renováveis na matriz elétrica. A previsão da potência eólica é, portanto, uma ferramenta muito importante para operar com mais eficiência os sistemas de energia com maiores penetrações de energia eólica, além de ser útil para manter em ordem os negócios dos mercados de eletricidade *Day-Ahead*.

2.5. A Energia Eólica

2.5.1. Histórico

Nos últimos anos, a geração eólica, assim como outras formas de geração renovável, tem crescido em ritmo acelerado. A energia eólica representa uma das três formas de energia renovável emergentes no mercado, em conjunto com a energia solar e a biomassa. Hoje, a capacidade mundial de geração de energia elétrica através da energia eólica já é suficiente para suprir mais do que a demanda elétrica de todo o Brasil. Suas principais vantagens residem no fato de que é uma energia renovável, limpa (excluindo a poluição sonora), que teoricamente pode ser construída em qualquer região e que geralmente requer menos terreno para ser instalada. Em contraste, suas desvantagens giram em torno da não-linearidade do vento e, como consequência, da necessidade de recorrer a outras formas de energia de base para suprir o consumo.

O primeiro aerogerador de grande dimensão com a finalidade de geração de energia elétrica foi construído em 1929 na França, mas logo foi destruído por uma tormenta, assim

como outros que foram construídos em seguida. Os maiores avanços nessa área ocorreram por volta da década de 1980, quando vários modelos revolucionários de turbinas começaram a ser construídos. Mesmo sendo estes avanços muito recentes, a ideia de utilizar a energia do vento nas atividades humanas (utilizada primeiramente em moinhos para moer grãos) já existe há vários séculos.

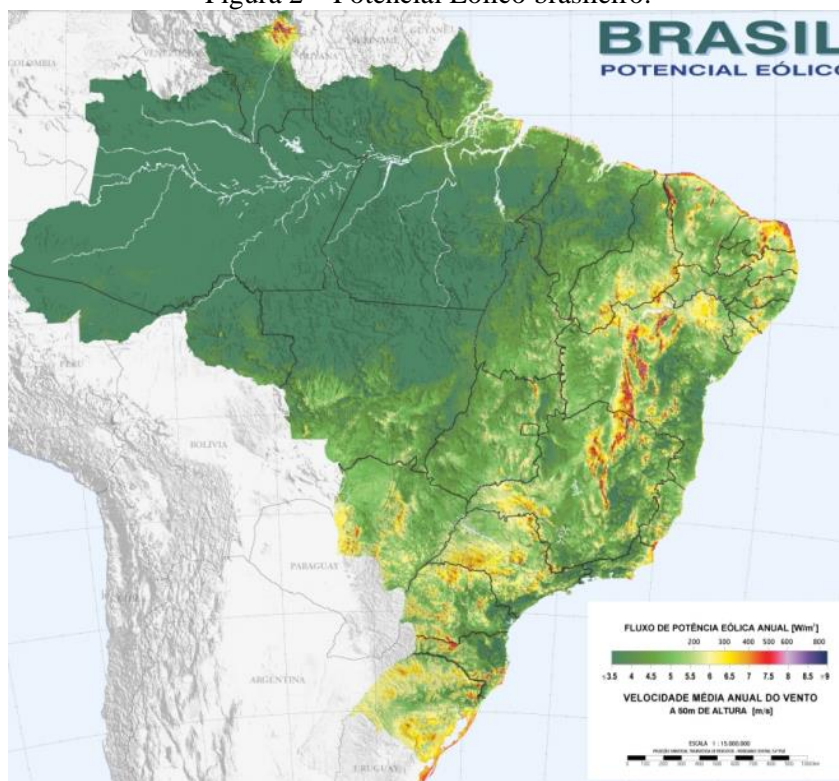
Para trabalhar com sistemas eólicos, é necessário fazer estimativas do comportamento dos ventos no local em que se planeja instalar as turbinas, já que se trata de um fenômeno de natureza aleatória. Portanto, para que um projeto de usina eólica seja rentável, é necessário que se faça uma análise estatística dos dados climáticos do local, analisando principalmente as informações relativas à incidência e à intensidade dos ventos. O conhecimento da velocidade média dos ventos é essencial para a escolha da turbina a ser instalada e para estimar a energia que pode ser produzida no local, uma vez que há uma faixa de velocidade específica em que os aerogeradores funcionam sob operação nominal. A conversão da energia das condições locais para a produção de energia elétrica pode ser visualizada através de curvas de potência dos fabricantes. Há também alguns elementos que são úteis para realizar a avaliação da produtividade da geração; um deles é o fator de capacidade, que compara a produção momentânea do sistema com a quantidade de energia que o sistema pode produzir em sua total capacidade. Em média, esse fator fica entre 10% e 50% na maioria dos sistemas de geração de energia eólica.

Em redes conectadas a instalações eólicas de maior porte, é necessário o constante monitoramento do sistema através da aplicação de técnicas de estimação de estado (SE), que foram inicialmente desenvolvidas a partir da década de 1970, com estudiosos como Schweppe e Zimmerman. Hoje boa parte das pesquisas na área de energia eólica estão voltadas para a busca por métodos alternativos de realizar essas estimações, através da criação de novos algoritmos e novas maneiras de se fazer análises e levantamentos estatísticos.

Os países que lideram em potência eólica instalada são China, Estados Unidos, Alemanha e Espanha, ficando o Brasil em oitavo lugar nessa lista, mesmo que estudos mostrem que o país tem um bom potencial eólico, com destaque para o Nordeste, onde se estima um valor para a velocidade média do vento (a 50 metros de altura em relação à superfície) superior a 7 m/s em locais onde a incidência eólica é maior. Em 2005, a capacidade de geração eólica instalada no país era de cerca de 25MW; em 2014, este número já aumentou para cerca de 4500 MW, com mais de 180 parques instalados.

Em 2017, foram investidos R\$ 11,4 bilhões nos parques de energia eólica, e sua capacidade de produção cresceu 26,2%. Atualmente a capacidade instalada brasileira é de 14,34 GW, distribuídos em 568 parques eólicos com 7.000 aerogeradores em operação em 12 estados brasileiros – 80% deste total instalado no Nordeste. Em 2019, de acordo com dados divulgados pela Associação Brasileira de Energia Eólica, a energia eólica foi responsável por 8,4% da produção de energia elétrica do país, chegando a abastecer 14% de todo Sistema Interligado Nacional no mês de setembro. Destaque para o parque Geribatu (RS), que tem 258 MW de potência instalada e é um dos três parques que compõem o Complexo Eólico Campos Neutrais – o maior da América Latina –, e para o parque Oitis, que está em construção nos estados do Piauí e da Bahia, com previsão de entrada operacional em 2020; é investimento da empresa Iberdrola, e terá capacidade instalada de 566 MW, o que o caracteriza como o futuro maior parque eólico da América Latina. É evidente, portanto, que o Brasil está aproveitando cada vez mais o potencial eólico em seu território com a instalação de novos sistemas e parques eólicos. A Figura 2 mostra o potencial eólico do território brasileiro de acordo com os estudos do Atlas do Potencial Eólico Brasileiro.

Figura 2 – Potencial Eólico brasileiro.



Fonte: Atlas do Potencial Eólico Brasileiro, 2001.

2.5.2. Modelagem e definições

O vento é consequência da energia proveniente da luz irradiada do sol e dos processos energéticos envolvidos na atmosfera (principalmente a rotação planetária). Trata-se de um mecanismo solar-planetário permanente, cuja duração é mensurável na escala de bilhões de anos, sendo, portanto, considerado uma fonte renovável de energia.

Os estudos para criar modelos matemáticos para o comportamento do vento começaram a se desenvolver mais a partir do século passado, quando distribuições aleatórias e processos estocásticos passaram a ser aplicados para descrever a natureza do fenômeno. Atualmente, é importante mencionar os modelos estatísticos mais modernos, como o *Auto Regressive* (AR) e o *Auto Regressive Integrated Moving Average* (ARIMA), que são inclusive utilizados em programas de previsão de séries temporais mais sofisticados. Os métodos de *Machine Learning* (ML) que envolvem Redes Neurais Artificiais (RNA) também ganham relevância nos últimos anos. Os modelos físicos são úteis para estimar o recurso eólico a partir de informações meteorológicas, adaptando-as às influências físicas locais; são utilizados por agências de previsões meteorológicas para previsão de umidade, chuva, temperatura e ventos. Essa abordagem é muito eficaz no curto a médio prazo (após 6 horas). No entanto, os modelos que apresentam maior taxa de validação e maior eficácia são os modelos híbridos, que combinam os métodos estatísticos e os físicos. Estes modelos incrementam aos programas de Inteligência Artificial (AI) as descrições físicas relevantes para a previsão do clima. Esses são dotados de maior complexidade, e envolvem maior número de variáveis a serem levadas em consideração para realização das previsões em tempo real. No entanto, nem sempre as abordagens estatísticas ou combinadas são possíveis, devido ao desafio de se incluir dados reais no processo de previsão. Como consequência, as abordagens físicas são predominantes. Neste trabalho, foi aplicado o método de *Deep Learning* (DL).


Hoje é amplamente aceito o modelo da distribuição de Weibull, expressão dada em (1.1), para a descrição do comportamento do vento, em termos de probabilidade da velocidade. Os parâmetros para aproximar a curva de Weibull ao histograma de velocidades podem ser convencionalmente calculados de acordo com (1.2). Sabemos que o fator de forma impacta na constância e ocorrência de valores extremos; quanto maior o valor deste fator, maior é a constância e menor a ocorrência de valores extremos, como pode ser visto no Gráfico 4. Valores de k anuais variam tipicamente entre 2 e 3. Excepcionalmente, durante alguns meses do ano em regiões de ventos alísios, como no Nordeste brasileiro, o fator de forma pode atingir valores mensais superiores a 6. O Gráfico 5 mostra um exemplo de distribuição de Weibull para os ventos de uma região.

$$P(v) = \frac{k}{C} \left(\frac{v}{C}\right)^{k-1} e^{-\left(\frac{v}{C}\right)^k} \quad (1.1)$$

$$\bar{v} = C\Gamma\left(1 + \frac{1}{k}\right) \quad (1.2)$$

$P(v)$ = Probabilidade da velocidade v
 k = Fator de Forma
 C = Fator de Escala
 Γ = Função Gama
 \bar{v} = Velocidade Média

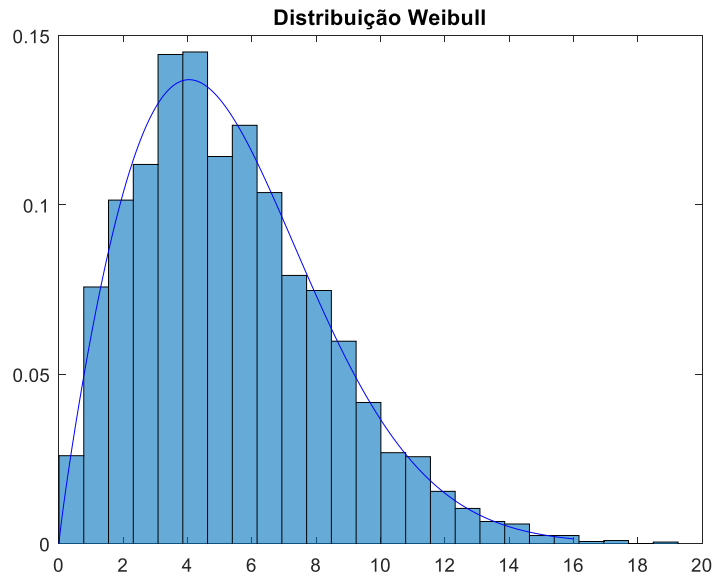
Gráfico 4 – Curvas de Weibull para diferentes fatores de forma.



Fonte: Atlas do Potencial Eólico Brasileiro, 2001.

Sabe-se também que a velocidade média do vento varia com a altura. Embora a viscosidade do ar seja relativamente reduzida se comparada com outros fluidos, ela é suficiente para que haja aderência significativa entre moléculas e superfície. A mecânica dos fluidos explica que, ao entrar em contato com uma superfície sólida, os fluidos tendem a aderir à superfície. Essa tendência se deve à viscosidade. Isto ocorre porque existem forças de atração que mantêm as moléculas do fluido unidas.


Gráfico 5 – Exemplo de ajuste pela distribuição de Weibull.



Fonte: Elaborado pelo autor.

A velocidade do vento, portanto, aumenta quanto maior for a altura, até um ponto em que os efeitos da viscosidade no fluxo de massa de ar são praticamente desprezíveis; neste ponto se encontra a chamada camada-limite ou camada de Prandtl, ilustrada na Figura 3. A característica do solo que determina o quanto os efeitos da viscosidade irão impactar na velocidade do vento no local é a chamada rugosidade. Essa grandeza, estudada pela área da orografia (estudo das nuances de relevos) quantifica o nível de irregularidade do solo – regiões mais planas como campos abertos possuem menor rugosidade, enquanto locais com maior presença de árvores possuem rugosidade mais elevada.

Figura 3 – Efeito da viscosidade na velocidade do vento.



Fonte: O aproveitamento da energia eólica, 2007 (adaptado).

Para que as turbinas fiquem expostas a regiões com maior incidência de ventos, elas são instaladas no alto de torres de sustentação. O modelo utilizado neste trabalho para avaliar a variação da velocidade do vento com a altura foi a fórmula de altitude de Hellman, que consiste em um modelo exponencial dado pela equação (1.3). O efeito exponencial pode ser visualizado no Gráfico 6. O coeficiente de atrito tem correlação com a rugosidade do terreno; quanto maior

a rugosidade, maior será o seu valor. A Tabela 1 mostra os valores a serem adotados para tipos de relevos diferentes.

$$v = v_0 \left(\frac{H}{H_0} \right)^\alpha \quad (1.3)$$

v = Velocidade do vento na altura H


H = Altura a ser avaliada

H_0 = Altura inicial

v_0 = Velocidade do vento na altura H_0

α = Coeficiente de atrito ou coeficiente de Hellman

Gráfico 6 – Efeito da altura na velocidade do vento pelo modelo exponencial.



Fonte: Diagnosis of the Best Method for Wind Speed Extrapolation, 2015.

Outro fator a ser considerado é a turbulência, que é um conjunto de flutuações repentinas e caóticas na velocidade do vento. A presença de turbulência não somente diminui a potência disponível, mas impõe cargas de fadiga à turbina. Neste fenômeno, pequenas diferenças nas condições iniciais ou condições de contorno podem resultar em grandes diferenças nas previsões após intervalos de tempo relativamente curtos. Por não poder ser explicado de forma determinística, o processo é estudado através de modelos estatísticos; as variações de velocidade de ventos turbulentos podem ser consideradas aproximadamente gaussianas.

Tabela 1 – Coeficiente de atrito de acordo com as características do terreno.

Características do Terreno	Coeficiente de Atrito (α)
Superfície aquática serena ou solo suave	0,1
Gramma alta ao nível do solo	0,15
Arbustos e cercas	0,2
Áreas rurais com muitas árvores	0,25
Pequenas cidades com árvores e arbustos	0,3
Grandes cidades com prédios elevados	0,4

Fonte: Rohatgi, 1994 (adaptado).

A modelagem física da energia a ser extraída dos ventos pode ser deduzida a partir das definições da mecânica clássica, adicionando-se alguns fatores limitantes teóricos devido à própria natureza das turbinas. Essas definições, descritas nas equações (1.4) a (1.12), nos permitem obter a energia cinética teórica disponível e a potência disponível em função da velocidade do vento, da massa de ar passante e da área a ser considerada para extração da energia.

$$E = \frac{mv^2}{2} [J] \quad (1.4)$$

$$P = \frac{dE}{dt} = \frac{1}{2} \frac{dm}{dt} v^2 = \frac{1}{2} \rho \frac{dV}{dt} v^2 = P = \frac{1}{2} \rho A v^3 [W] \quad (1.5)$$

ρ = densidade do ar em kg/m^3

$A = \pi D^2/4$, em que D é o diâmetro do rotor em m

v = velocidade do vento em m/s

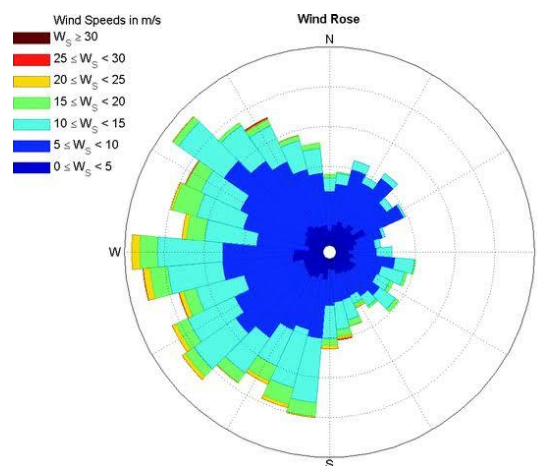
V = volume em m^3

m = massa passante por uma área em Kg

t = tempo em s

Portanto neste modelo, através de uma determinada área e considerando para o vento a massa específica constante, a potência eólica pode ser calculada em função da velocidade do vento no local. Observa-se também que a potência varia com o cubo da velocidade, portanto pequenas mudanças na velocidade ocasionam maiores variações na potência eólica. Em seguida, a potência instantânea será dada como uma função temporal como mostrado na equação (1.6), de forma que a energia disponível será calculada de acordo com a equação (1.7). A determinação da direção da velocidade no local também é importante para a análise antes da implementação das turbinas. A partir dela, será escolhido o direcionamento das turbinas, de acordo com as direções predominantes dos ventos ao longo do ano. A direção pode ser melhor visualizada a partir da rosa dos ventos, que mostra a intensidade dos ventos e a ocorrência para diferentes direções. O Gráfico 7 mostra um exemplo de rosa dos ventos.

Gráfico 7 – Rosa dos ventos.



Fonte: Floating Offshore Wind Energy, 2016.

Para completar o modelo, deve-se levar em conta o limite de Lanchester-Betz-Joukowsky, além das perdas próprias do gerador. Albert Betz assume que a velocidade do vento através da turbina seja igual à média das velocidades de entrada e saída, e desta forma consegue-se chegar à expressão em (1.8).

$$P(t) = \frac{1}{2} \rho A v(t)^3 [W] \quad (1.6)$$

$$E = \int_{t_1}^{t_2} P(t) dt = \int_{t_1}^{t_2} \rho A v(t)^3 dt [J] \quad (1.7)$$

A função passa a ser máxima quando λ é igual a um terço, de forma a obter a máxima eficiência possível da turbina, igual a cerca de 0,593 conforme (1.9). Na prática, as turbinas no mercado atual trabalham com coeficiente de potência entre 0,35 e 0,45.

$$C_p = [0.5 * (1 + \lambda)(1 - \lambda^2)] \quad (1.8)$$

$$C_{pmax} = \frac{16}{27} = 59,25 \% \quad (1.9)$$

$$P(t) = \frac{1}{2} \eta C_p \rho A v(t)^3 [W] \quad (1.10)$$

η = eficiência do gerador

C_p = coeficiente de potência da turbina

C_{pmax} = Limite de Lanchester-Betz-Joukowsky

Levando em conta as medições, que no caso da SONDA acontecem em intervalos de um minuto, as velocidades serão amostradas no tempo, portanto, a expressão discreta para a potência ficará de acordo com (1.11). Para o intervalo de médias horárias, conforme utilizado posteriormente neste estudo, a equação utilizada para cálculo da energia, em kWh, será (1.12).

$$P[n] = \frac{1}{2} \eta C_p \rho A v[n]^3 10^{-3} [kW] \quad (1.11)$$

$$E[n] = \sum_{n=n_1}^N \frac{1}{2} \eta C_p \rho A v[n]^3 10^{-3} [kWh] \quad (1.12)$$


n = discretizações horárias

Nos parques eólicos, existem algumas regras práticas para a otimização do aproveitamento eólico. Primeiramente, deve ser considerado que a absorção de energia cinética reduz a velocidade do vento a jusante do disco do rotor. Gradualmente, essa velocidade se mistura com as massas de ar predominantes do escoamento livre.

Após alguma distância a jusante da turbina, o escoamento praticamente recupera as condições de velocidade originais e as turbinas adicionais podem ser instaladas, minimizando as perdas de desempenho causadas pela interferência de turbinas anteriores. Essa distância entre as turbinas varia com a velocidade do vento, as condições de operação da turbina, a rugosidade do terreno e a condição de estabilidade térmica vertical da atmosfera.

A distância considerada segura para a instalação de novas turbinas é da ordem de 10 vezes o diâmetro se instalada a jusante e 5 vezes se instalada ao lado em relação ao vento predominante, como pode ser visto na Figura 4.


Figura 4 – Disposição das turbinas no parque eólico.



Fonte: Atlas do Potencial Eólico Brasileiro, 2001.

As turbinas de 3 pás apresentam melhor distribuição de peso, sendo dinamicamente mais estáveis; além disso, apresentam menos ruído em função da menor velocidade se comparada às turbinas de 1 ou 2 pás. As turbinas podem ser classificadas de acordo com a sua disposição em relação ao vento: podem receber o vento de frente, denominadas turbinas *upwind* ou por trás, chamadas *downwind*. As turbinas *downwind* possuem a vantagem de não necessitarem de um mecanismo para direcionamento da turbina em relação à direção do vento, no entanto, isto é apenas para turbinas de pequeno porte, uma vez que em turbinas de portes maiores existe o risco de colisão das pás com a torre. A principal desvantagem das turbinas *downwind* é o fato de que a torre causa uma turbulência maior no vento, o que por sua vez gera mais ruídos. Por outro lado, as turbinas *upwind* evitam a interação da torre com o vento, reduzindo, portanto, os ruídos. Atualmente, as turbinas *upwind* são a tecnologia dominante no mundo.

Figura 5 – Tipos de turbina eólica.




Fonte: FLTXNY Maglev e Wind turbine control systems and techniques, 2011.

Quanto às novas tecnologias, alguns modelos mais modernos usam um sistema de giro com tecnologia de levitação magnética, reduzindo drasticamente o atrito e melhorando a eficiência das turbinas. Esses modelos contam com turbinas de giro vertical, uma nova e inovadora forma de aproveitar a energia.

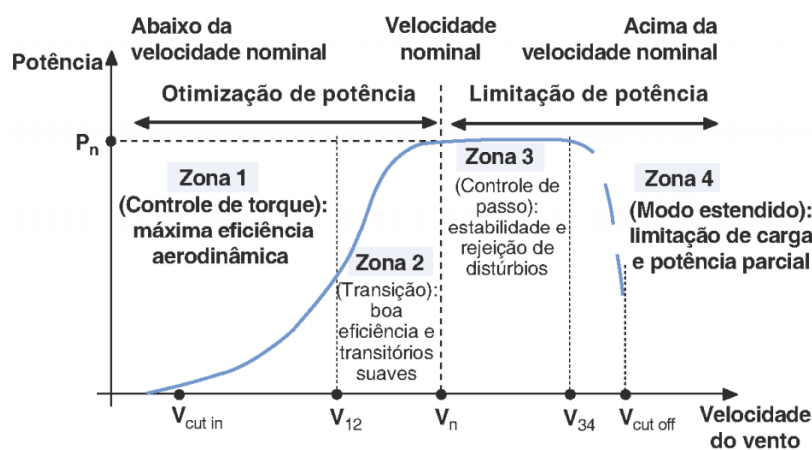
As turbinas contam também com curvas específicas de potência. Para uma dada velocidade mínima do vento, o gerador da turbina entra em operação. Essa velocidade é chamada de *Cut-In Speed*. O contrário também acontece, existindo uma velocidade máxima de operação da turbina, valor limite de segurança para manter as condições de estabilidade e evitar eventuais danos ao sistema. Essa velocidade é chamada de *Cut-Off Speed*, a partir da qual a potência aproveitada é zero. Entre a velocidade máxima e a velocidade denominada *Rated speed*, a turbina conta com um sistema de controle que atua para manter a velocidade das pás constante, operando em seu máximo, sob potência nominal. As curvas de potência ideal e real da turbina podem ser vistas nos Gráficos 8 e 9. A curva ideal fornece uma estrutura de equilíbrio entre o diâmetro do rotor e o tamanho do gerador, logo o dimensionamento do rotor e do gerador devem ser adequados ao perfil do vento no local. Aumentando o tamanho do rotor e mantendo o mesmo gerador, há um desvio da curva de potência da turbina para ventos com baixa velocidade.

Gráfico 8 – Curva de potência ideal das turbinas.



Fonte: O aproveitamento da energia eólica, 2007 (adaptado).

Gráfico 9 – Curva de potência real das turbinas.



Fonte: O aproveitamento da energia eólica, 2007 (adaptado).

Uma ferramenta útil para avaliar o desempenho da turbina ao longo do tempo é o chamado fator de capacidade. Este fator relaciona a quantidade de energia sendo gerada pela turbina durante um certo período de tempo com a quantidade de energia que ela, sob potência nominal, poderia gerar durante o mesmo período. Geralmente, esse fator fica entre 5 a 20% em sistemas

menores e a menores alturas – cerca de 10 metros em relação ao solo – e entre 30 a 45% em locais com maior incidência de ventos, a alturas elevadas (acima de 50 metros em relação ao solo). A expressão para o fator de capacidade que será utilizada posteriormente neste trabalho consta em (1.13).

$$FC = \frac{\sum_{n=n_1}^N \frac{1}{2} \eta C_p \rho A v[n]^3 10^{-3} [kWh]}{P_{nominal} t_{periodo} [kWh]} \quad (1.13)$$

$t_{periodo}$ = Tempo em horas decorrido no intervalo analisado

$P_{nominal}$ = Potência nominal da turbina em kW

O instrumento medidor de velocidade do vento é o anemômetro, mostrado na Figura 6. Existem vários tipos de anemômetros, sendo que a opção de escolha de cada um deles depende da forma como será feita a leitura, da necessidade de precisão, entre outros. A S&E Instrumentos é fabricante nacional de anemômetros medidores de velocidade do vento, com 3 modelos e diversas opções de suporte de instalação.

Figura 6 – Anemômetro digital, modelo AN-1C da S&E Instrumentos.



Fonte: S&E Instrumentos.

Os valores são medidos em intervalos de minutos, que consistem em 4 medições por segundo, depois transformados para médias. A direção pode ser determinada, por exemplo, por um cata-vento, que produz um valor medido a cada segundo.

Estes valores também têm médias em intervalos de minutos e, em seguida, agregados a valores por hora. A velocidade e a direção do vento mudam com o aumento da altitude sobre o solo. Portanto, os mastros meteorológicos costumam ter sensores de vento instalados em diferentes altitudes (2m, 10m, 80m, etc.). Na estação meteorológica da SONDA, em Natal – RN, cujos dados foram utilizados neste estudo, as medições da velocidade do vento são realizadas na altura média padronizada de 10 metros em relação ao solo.

2.6. Conclusões parciais do capítulo

Neste capítulo, discorreu-se sobre alguns detalhes envolvendo os sistemas de energia elétrica, envolvendo por exemplo os sistemas de planejamento e comercialização da eletricidade, sendo apresentados também os conceitos de mercado de eletricidade e mercados *Day-Ahead*. Os desafios da inserção da energia eólica e das energias de natureza intermitente nos sistemas e mercados de energia foram também explicitados e discutidos, inclusive as novas propostas e abordagens para os cenários futuros. Aspectos técnicos gerais da energia eólica também foram apresentados.

Concluimos que a previsão do vento será não só muito útil, mas necessária em um futuro com possível predominância de energias renováveis e redes inteligentes, revelando que a previsão da potência eólica é uma ferramenta muito importante para operar com maior eficiência os sistemas de energia com maiores penetrações de energias intermitentes, além de ser útil para manter em ordem os negócios dos mercados *Day-Ahead*.

3. MÉTODO EMPREGANDO REDES NEURAIAS ARTIFICIAIS

3.1. Resumo do Capítulo

Este capítulo detalha o estudo de previsão da potência e da energia eólica a partir da previsão da velocidade do vento empregando uma rede neural artificial (RNA) com múltiplas camadas ocultas (*Deep Learning*), definindo a metodologia e a execução do projeto. Também traz uma breve explicação sobre os conceitos de *Machine Learning* e de RNA, elucidando o seu funcionamento e sua aplicação por meio do MATLAB. Por fim, estabelece as informações necessárias para o desenvolvimento do próximo capítulo.

3.2. *Machine Learning* e Redes Neurais Artificiais

O *Machine Learning* (ML) ou “aprendizado de máquina” nasceu quando pesquisadores interessados em Inteligência Artificial (AI) tentaram responder se as máquinas poderiam aprender com os dados. Surgiu do reconhecimento de padrões e da teoria de que computadores podem aprender de forma semelhante aos humanos, obtendo maior índice de acertos conforme a experiência, sem serem programados para realizar apenas tarefas específicas. É o ramo da AI baseado na ideia de que sistemas podem de fato aprender, identificar padrões e tomar decisões com o mínimo de intervenção humana. O aspecto iterativo do aprendizado é essencial, pois quando os modelos são expostos a novos dados, eles são capazes de se adaptar independentemente; aprendem com dados anteriores para produzir decisões e resultados confiáveis, passíveis de repetição. Esta é uma ciência que ganha cada vez mais impulso atualmente, sendo vista como o futuro da era digital, e como a protagonista de uma nova era tecnológica que está por vir, ilustrada pela presença da indústria 4.0. Alguns exemplos muito relevantes de aplicações de ML hoje são detecção de fraudes em bancos, previsão de séries temporais, reconhecimento de áudio, veículos autônomos, entre vários outros. Os tipos básicos de algoritmos de ML podem ser divididos em duas sessões:

- **Supervisionados:** São usados para prever valores alvo a partir de dados prévios disponíveis; são os algoritmos de classificação e os de regressão. Os primeiros são usados para avaliar variáveis de natureza discreta, como identificar um objeto, por exemplo. Os segundos são usados para avaliar de forma contínua os dados, ou seja, identificar padrões regressivos.
- **Não supervisionados:** São usados para criar algoritmos que aprendem e encontram estruturas em dados não disponibilizados previamente. Alguns exemplos são o *clustering*, que encontra nos dados grupos com instâncias similares, e o detector de *outlier*, que encontra elementos que destoam muito do padrão geral dos dados.


A indústria 4.0, uma expressão criada por Klaus Schwab, é uma mudança que está transformando toda a forma como consumimos e nos relacionamos. É não apenas mais uma etapa do desenvolvimento tecnológico, mas uma mudança de paradigma. A quarta revolução industrial é definida pela transição em direção a novos sistemas construídos sobre a infraestrutura da revolução digital; é a chamada “fábrica inteligente”.

As redes neurais artificiais fazem parte dessa mudança. Estão inseridas no contexto da indústria 4.0 e listam entre os diferentes métodos de ML; são modelos computacionais inspirados pelo sistema nervoso central humano, sendo capazes de realizar o ML e de reconhecer de padrões. Consistem em sistemas de computação com nós interconectados que funcionam como os neurônios do cérebro humano, absorvendo valores de entradas e

respondendo com valores de saída, simulando o comportamento de redes neurais biológicas. A partir de métodos iterativos, elas podem, com o tempo, aprender e melhorar continuamente. Podem, por exemplo, ajudar a criar programas que identificam objetos a partir de imagens. A primeira rede neural foi concebida por Warren McCulloch e Walter Pitts em 1943, quando escreveram um artigo sobre como os neurônios devem funcionar e, então, modelaram suas ideias criando uma rede neural simples com circuitos elétricos.

Como pode ser visto na Figura 7, que representa a estrutura básica da RNA, os círculos são chamados “nodes” ou “neurônios”. As conexões, representadas por setas, indicam os “weights” ou “pesos”. Na ponta esquerda, estão os dados de entrada, na ponta direita as saídas da rede, e no centro as camadas ocultas. Quando uma RNA possui apenas uma camada oculta, é denominada “*Single Layer Neural Network*” – Rede Neural de Camada Simples; quando possui duas ou mais camadas ocultas, passa a ser denominada rede *Deep Learning*.

Figura 7 – Estrutura de uma RNA.

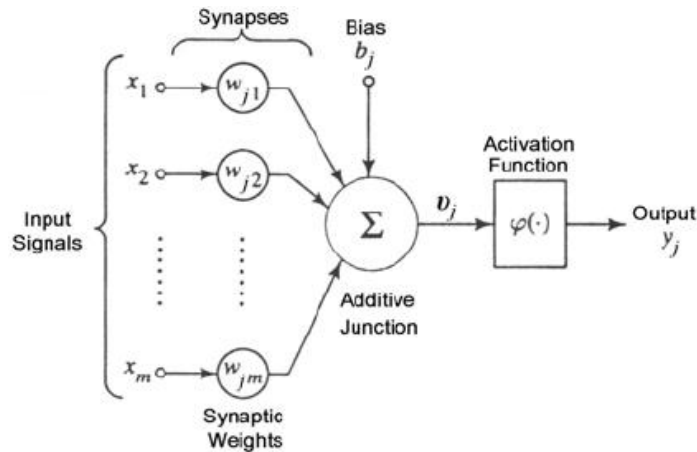


Fonte: Digital Trends, 2019.

Os dados de entrada consistem em sinais que são aplicados à rede neural, cuja estrutura interna responde com sinais de saída. Ao inserir os dados de entrada, a resposta do sistema é provida de um erro de cálculo quando comparada com a saída esperada. Para reduzir esse erro de cálculo e expandir o alcance e aplicabilidade da rede, é realizado o processo de treinamento e validação, que consiste em um algoritmo iterativo cujo objetivo central é reduzir o erro de saída em cada uma das respostas da rede a partir de um número elevado de dados de entrada. Em seguida, é realizado o teste, que utiliza um conjunto de dados de entrada distinto dos conjuntos de treinamento e validação, justamente para verificar o êxito da rede quando ela é sujeita a sinais diferentes daqueles utilizados no aprendizado. A saída da rede neural é modelada pelas equações (3.1) e (3.2), de acordo com o modelo literal visto na Figura 8.

O processo de aprendizagem da rede neural acontece por meio de um algoritmo que ajusta os pesos para atender à condição ótima de mínimo erro. Esse processo de ajuste dos pesos é chamado “*Learning Rule*”, e o algoritmo usado é o *backpropagation*, que se baseia na retropropagação dos erros para ajustar os pesos das camadas intermediárias. O *backpropagation* geralmente usa o método *gradient descent* ou suas variantes como o *stochastic gradient descent* (SGD), modelado de acordo com o código (c3.1).

Figura 8 – Modelagem da RNA.



Fonte: Solar radiation forecast using artificial neural networks in south Brazil, 2006.

$$v_j = \sum_{i=1}^m w_{ji} x_i + b_j \quad (3.1)$$

$$y_j = \varphi(v_j) \quad (3.2)$$

v_j = elemento j do vetor v

x_i = i -ésimo sinal de entrada

w_{ji} = peso entre o sinal de entrada i e o neurônio j

b_j = parâmetro "bias"

y_j = saída do neurônio j

φ = função de ativação

Em uma RNA, as saídas dos nós em uma camada são entradas para a próxima camada; em seguida, o resultado é modificado por uma função antes da saída. Essa função é chamada de função de ativação, geralmente uma função não linear. Neste trabalho, foram utilizadas as funções Sigmoid Hiperbólica, ilustrada no Gráfico 10, e a linear, a primeira dada por (3.3). Essas funções são utilizadas para adaptar melhor ao processo de aprendizado. Por exemplo, em programas de algoritmo supervisionado para classificação, algumas funções apresentam um melhor desempenho se comparado com a performance das mesmas em problemas de regressão. É preciso, portanto, identificar o tipo do processo para escolher as funções adequadas. A função Sigmoid, por sua vez, tende a reduzir o efeito de valores extremos de entrada, proporcionando a melhor performance da RNA. O algoritmo de treinamento se inicia com um chute inicial para os pesos, que ao longo das iterações se ajustam conforme os dados.

$$\varphi(v) = \frac{2}{1 + e^{-2v}} - 1 \quad (3.3)$$


$$w_{ij} \leftarrow w_{ij} + \delta \frac{d\varphi}{dv} \Big|_{v=v_j} e_j x_i \quad (c3.1)$$

e_j = erro no neurônio j

δ = taxa de aprendizagem ("*Learning Rate*")

Em seguida é obtida a saída e calculado o erro. O terceiro passo é atualizar o valor dos pesos de acordo com o método de otimização, dado por (c3.1). Todos esses passos se repetem até atingir o critério de parada. Ao conjunto de todos os passos anteriores, se dá o nome de *epoch*. O parâmetro *bias* é um parâmetro a ser descoberto na etapa de aprendizagem a partir dos dados observados, consistindo em uma constante que ajuda o modelo a se ajustar melhor aos dados.

Gráfico 10 – Função Sigmoid Hiperbólica.



Fonte: Code Project, 2017.

3.3. Metodologia

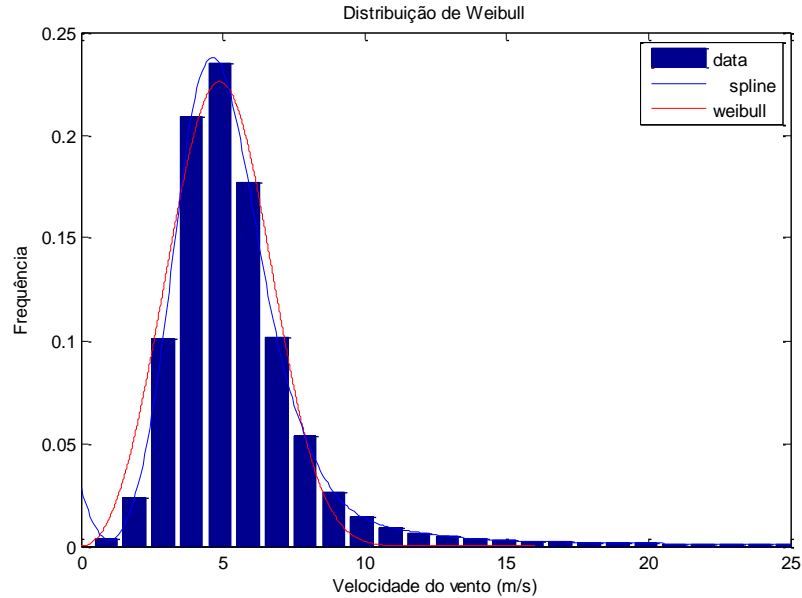
Nessa seção, comenta-se sobre a região de estudo, as especificidades das medições disponibilizadas pela instituição escolhida, o processamento dos dados e sobre os métodos utilizados para definir a rede e aqueles usados para avaliar a acurácia da mesma. Todos os passos deste estudo foram realizados a partir do *software* MATLAB com uso do *Simulink*, com tratamento dos dados pelo Excel.

3.3.1. Processamento dos Dados

Os dados deste estudo foram obtidos das medições da SONDA, na cidade de Natal (5.75° S – 35.35° W) no Rio Grande do Norte. A instituição é uma importante fonte de dados, que são utilizados em pesquisas e previsões em todo o Brasil. A escolha deste local se deve ao conhecido potencial eólico da região Nordeste, com presença de ventos abundantes bem distribuídos ao longo do ano. Os dados utilizados para treinamento, validação e teste da rede foram obtidos do mês de janeiro do ano de 2016, todos disponíveis no site da instituição. Entretanto, como resultado deste trabalho, podem ser utilizados também dados de outras localidades e outros anos para treinamento e eventual teste da rede. Os dados meteorológicos disponibilizados para a região e para o período escolhidos são Radiação Global Média, Radiação Direta, Radiação Difusa, Radiação Onda Longa, Radiação Fotossinteticamente Ativa, Iluminância, Temperatura Superficial, Umidade Relativa do Ar, Pressão Atmosférica, Precipitação, Velocidade do Vento

a 10 metros e Direção do Vento a 10 metros. Podemos visualizar os dados nos Gráficos 11 a 15.


Gráfico 11 – Distribuição do vento em Natal, RN.



Fonte: Elaborado pelo autor.


Durante o tratamento de dados, é comum que algumas medições tenham falhas e os seus valores não sejam disponibilizados por baixa confiabilidade, devido a defeitos de equipamentos, acidentes, entre outros. Quando isso ocorre, são seguidas normas para preencher o vazio destes dados de forma coerente com o padrão encontrado no local, no instante da ocorrência dessas falhas. Essas normas consideram a interpolação ou a média das medidas anteriores e posteriores às falhas, ou também, em alguns casos, a recorrência a dados de anos anteriores, se o número de falhas for demasiado grande. No entanto, os dados de janeiro de 2016 na região não contaram com essas falhas, por isso essa abordagem não será feita neste trabalho. Todos os dados aplicados são originais da estação no período especificado.

Gráfico 12 – Rosa dos ventos em Natal, RN, no mês de janeiro.




Fonte: Iowa State University, 2019.

Gráfico 13 – Medições da velocidade do vento a cada minuto.




Fonte: Elaborado pelo autor.

Gráfico 14 – Medições da Umidade Relativa e Temperatura a cada minuto.



Fonte: Elaborado pelo autor.

Gráfico 15 – Medições da pressão atmosférica a cada minuto.



Fonte: Elaborado pelo autor.

- Variáveis Anemométricas Utilizadas como Entrada:
 - Velocidade do Vento a 10 metros em (m/s);
 - Temperatura Superficial em °C.
- Variáveis Meteorológicas Utilizadas como Entrada:
 - Umidade Relativa do Ar (%);
 - Pressão Atmosférica (Atm).
- Saída da Rede:
 - Velocidade do Vento a 10 m prevista para a hora i seguinte (m/s).

3.3.2. Treinamento, Validação e Teste


Quanto aos conjuntos envolvidos no aprendizado – treinamento, validação e teste – cada um deles deve ser especificado dentro do modelo. O conjunto de dados de validação consiste em uma amostra de dados inseridos no conjunto de treinamento que é usada para estimar a habilidade do modelo de realizar previsões certas. Envolve dividir aleatoriamente o conjunto de observações disponíveis em duas partes, um conjunto de treinamento e um conjunto de validação. A avaliação final do modelo deve ser realizada em um conjunto de dados que não foi usado anteriormente para construir o modelo, para que eles forneçam um senso imparcial da eficácia do modelo. Quando uma grande quantidade de dados está disponível, um conjunto de amostras pode ser separado para avaliar o modelo final. O conjunto de dados de "treinamento" é o termo usado para as amostras usadas na criação do modelo, enquanto o conjunto de dados de "validação" é usado para qualificar o desempenho. Já o conjunto de teste

é usado para estimar a habilidade do modelo final ajustado com novos dados. As matrizes dos dados de treinamento, validação e teste utilizados neste trabalho ficam de acordo com as equações (3.5) a (3.7). As medições foram todas realizadas em períodos de 1 minuto, mas, para fins de praticidade e melhor desempenho do algoritmo, foram passadas para médias horárias, reduzindo o efeito de variações bruscas de curta duração ao longo das séries temporais.

- **Conjunto de treinamento:** Amostra de dados usada para ajustar o modelo.
- **Conjunto de validação:** Amostra de dados usada para fornecer uma avaliação do modelo no conjunto de dados de treinamento ao ajustar os parâmetros do modelo.
- **Conjunto de teste:** Amostra de dados usada para fornecer uma avaliação imparcial final do modelo.


À medida que a rede é treinada, os erros tendem a reduzir, até que o critério de parada do algoritmo seja atendido. Quando se inicia o processo de validação, a rede é avaliada e os erros tendem a ser maiores. Finalmente, o teste é aplicado e a eficácia da rede final pode ser observada. A Figura 9 ilustra os processos de treinamento, validação e teste, e o Gráfico 16 mostra o erro médio nos processos de acordo com a complexidade do modelo.

Figura 9 – Amostras de treinamento, validação e teste.



Fonte: Medium – Towards Data Science, 2017.

Gráfico 16 – Erro médio nos conjuntos de validação e treinamento.



Fonte: Fast AI, 2018.

Se a rede for treinada por muito tempo ou tiver muitos nós ocultos, ela poderá se tornar excessivamente específica para o conjunto de treinamento e falhará em generalizar os dados

durante o conjunto de validação, no fenômeno conhecido como *overfitting*. Neste fenômeno, o modelo memoriza os dados de treinamento em vez de aprender o padrão verdadeiro e não generaliza bem os dados não vistos. Ou seja, a perda no conjunto de validação começará a aumentar à medida que a perda do conjunto de treinamento cair. Se o erro durante a validação começar a crescer a cada iteração, o algoritmo pode estar em *overfitting*, e assim o certo é cessar o processo e realizar a parada do programa.

Se a taxa de aprendizagem for muito grande, os pesos tendem a explodir e a rede não consegue ajustar os dados. Em um modelo em que todos os pesos estão otimizados, quanto mais nós ocultos tiver, mais precisas serão as previsões do modelo, no entanto, quanto mais nós ocultos mais difícil é também otimizar os pesos do modelo, e mais provável será que os pesos abaixo do ideal levem ao *overfitting*.

$$train = \begin{bmatrix} pressure[n] & & pressure[n + 24d] \\ temp_sup[n] & & temp_sup[n + 24d] \\ humidity[n] & \cdots & humidity[n + 24d] \\ wind_speed_10[n] & & wind_speed_10[n + 24d] \end{bmatrix} \quad (3.4)$$

$$validation = \begin{bmatrix} pressure[n + 24d] & & pressure[n + 24(d + 1)] \\ temp_sup[n + 24d] & & temp_sup[n + 24(d + 1)] \\ humidity[n + 24d] & \cdots & humidity[n + 24(d + 1)] \\ wind_speed_10[n + 24d] & & wind_speed_10[n + 24(d + 1)] \end{bmatrix} \quad (3.5)$$

$$test = \begin{bmatrix} pressure[n + 24(d + 1)] & & pressure[n + 24(d + 2)] \\ temp_sup[n + 24(d + 1)] & & temp_sup[n + 24(d + 2)] \\ humidity[n + 24(d + 1)] & \cdots & humidity[n + 24(d + 2)] \\ wind_speed_10[n + 24(d + 1)] & & wind_speed_10[n + 24(d + 2)] \end{bmatrix} \quad (3.6)$$


n = hora da medição

d = número de dias do conjunto de treinamento

3.3.3. A Rede Neural

A rede foi implementada com a função *newff*, com o algoritmo de *backpropagation* com regularização Bayesiana usando a Toolbox “*trainbr*”. A configuração do modelo é uma rede de múltiplas camadas com a função tangente sigmoid (Toolbox “*tansig*”) nas camadas ocultas e com a função linear (Toolbox “*purelin*”) para a camada de saída. O número de neurônios na camada de saída é igual ao número de variáveis de saída. O número de neurônios nas camadas ocultas foi escolhido para otimizar o desempenho e a precisão da previsão do modelo, com base nos dados disponíveis; duas camadas ocultas foram utilizadas com 9 e 4 neurônios e a camada de saída com um neurônio, como ilustrado na Figura 10.

Figura 10 – Estrutura da RNA do modelo.



Fonte: Elaborado pelo autor.

Foram feitas diferentes análises neste estudo, entre elas a previsão a um certo número de horas a frente e a previsão sequencial, que utiliza como dados de entrada as próprias previsões para prever a velocidade nas horas seguintes. Essas análises serão detalhadas mais a frente. Para o treinamento da rede, foram utilizados os dados de medição de um número d de dias. Os conjuntos de validação e teste seguem com $d+1$ e $d+2$, de acordo com os códigos (c3.2) e (c3.3). Os conjuntos de treinamento, validação e teste ficarão distribuídos de acordo com a Tabela 2.

Tabela 2 – Porcentagem dos conjuntos na amostra.

Treinamento	Validação e Teste
83.33%	16.67%

Fonte: Elaborado pelo autor.

$$input \leftarrow \begin{bmatrix} pressure[n] \\ temp_sup[n] \\ humidity[n] \\ wind_speed_10[n] \end{bmatrix} \quad (c3.2)$$

$$output \leftarrow [wind_speed_10[n + horiz]] \quad (c3.3)$$

input = entrada da rede neural
output = saída da rede neural
horiz = horizonte de previsão em horas
n = hora da medição

Os parâmetros da rede foram dados como mostrado a seguir:

- Número máximo de *Epochs* = 1000;
- Erro alvo da performance = 0.0001;
- Taxa de aprendizagem = 0.01;
- Performance = ‘*Mean Squared Error – (MSE)*’
- Treinamento = ‘*Bayesian Regulation*’

3.3.4. Critérios de acurácia

Nessa seção serão detalhados os métodos para avaliar o desempenho do modelo através de análise estatística dos erros. A primeira variável considerada será a Raiz do Erro Médio

Quadrático (“*Root Mean Squared Error*” – RMSE). Valores próximos de zero indicam melhor ajuste, enquanto erros maiores tendem a apresentar valores mais elevados. O RMSE é dado pela equação (3.7) e tem como unidade (m/s).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (v_{prev,i} - v_{real,i})^2} \quad (3.7)$$

A segunda medida de erro utilizada será a Média do Erro Absoluto Percentual (“*Mean Absolute Percentage Error*” – MAPE), dado pela equação (3.8). Essa medida possui como vantagem a observação dos erros em porcentagem (%), de forma mais prática; no entanto, elementos da amostra com valor muito pequeno podem fazer com que essa variável apresente valores muito altos, distorcendo a observação.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{v_{prev,i} - v_{real,i}}{v_{real,i}} \right| \cdot 100 \quad (3.8)$$

A terceira medida será o erro médio absoluto (“*Mean Absolute Error*” - MAE), que dá simplesmente a média dos erros absolutos entre valores reais e previsão. A unidade dessa variável equivale a (m/s), expressão em (3.12).

$$MAE = \frac{1}{n} \sum_{i=1}^n |v_{prev,i} - v_{real,i}| \quad (3.9)$$

A última métrica será o índice U de Theil; esse coeficiente U será usado para avaliar o desempenho da previsão comparado ao desempenho da previsão trivial (esta é simplesmente a previsão em que o valor futuro é igual ao valor presente). A equação desta medida é dada por (3.13).

$$UTHEIL = \frac{\sqrt{\sum_{i=1}^n (v_{prev,i} - v_{real,i})^2}}{\sqrt{\sum_{i=1}^n (v_{real,i} - v_{real,i-1})^2}} \quad (3.10)$$

A avaliação é feita de acordo com o que se segue:

- se $U > 1$, o erro do modelo é maior que o erro da previsão trivial, o que mostra um desempenho não desejável.
- se $U < 1$, o erro do modelo é menor que o erro da previsão trivial, resultado que é desejável. Quanto mais próximo de 0, melhor o desempenho da rede.

3.3.5. Análises Adicionais

Depois da abordagem inicial da rede neural criada, foram feitos aprimoramentos para verificar como a rede responde, e assim, verificar se há possibilidade de melhoria do desempenho ao fazer as alterações.

A primeira análise é a análise sequencial, em que o programa usa na entrada as próprias previsões até uma dada hora $n+horiz-1$ para prever a hora em $n+horiz$, diferentemente da maneira elaborada previamente, em que apenas os dados na hora n são utilizados para realizar a previsão na hora $n+horiz$.

A segunda análise leva em conta não só os dados na hora n , mas também os dados das horas $n-1, n-2, \dots, n-k$, sendo k o número de janelas (dados da amostra) utilizadas como entrada para prever a velocidade em $n+horiz$. As modelagens de ambas as análises podem ser vistas nos códigos (c3.4) e (c3.5), respectivamente. Em seguida, os resultados serão comparados e a acurácia do método será averiguada.

$$input(4,1) \leftarrow wind_speed_10[n + horiz - 1] \quad (c3.4)$$

$$input \leftarrow \begin{bmatrix} pressure[n - k] & & pressure[n] \\ temp_sup[n - k] & & temp_sup[n] \\ humidity[n - k] & \dots & humidity[n] \\ wind_speed_10[n - k] & & wind_speed_10[n] \end{bmatrix} \quad (c3.5)$$

k = número de janelas anteriores à medição atual

3.3.6. Previsão da potência e estimação da energia disponível

A partir da previsão da velocidade do vento na localidade, é possível fazer a previsão da potência média horária, e, portanto, fazer também a estimação da energia disponível usando as equações (1.11) e (1.12). Deve-se considerar também que os erros de previsão da velocidade são propagados para erros de ordem cúbica na previsão da potência e energia. Por conseguinte, determinações como fator de capacidade também serão afetados dessa forma.


Para aplicar o estudo a um parque eólico hipotético, foi considerada a turbina Verne-555 da empresa Enersud, cuja potência nominal é igual a 6 kW, com diâmetro igual a 5,55 metros. É uma turbina eólica de eixo horizontal de três pás, desenvolvida para atender às necessidades de energia que superam o consumo individual. A depender da velocidade do vento no local de instalação, a turbina Verne é ideal para alimentar pequenos conjuntos residenciais, suprir energia de localidades isoladas como ilhas e zonas rurais e atender a demandas de agricultura e indústrias de pequeno porte. A turbina conta com alternador de baixa rotação de ímãs permanentes, tecnologia PM-DD, e é construída com materiais resistentes à oxidação, o que a torna um equipamento de alta confiabilidade, permitindo a instalação em ambientes agressivos. As especificações da turbina podem ser vistas na Tabela 3, e a curva de potência da turbina é vista no Gráfico 17; o Gráfico 18 ilustra a curva de potência ideal considerada para a turbina neste estudo. A densidade do ar considerada foi de 1,2928 kg/m³. Já que não são parâmetros dados pelas especificações da turbina, o rendimento do gerador e o coeficiente de potência foram estimados de acordo com a curva de potência e com a velocidade nominal informada, considerando o controle de passo. Dessa forma, ao conjunto foi estimado um fator igual a 0,23, equivalente a 39% do limite de Betz.

Tabela 3 – Especificações da Turbina.

Parâmetro	Modelo 555
Diâmetro da Hélice	5,55 m
Número de Pás	3
Tipo de pás	Torcida (10 aerofólios)
Vida útil	20 anos
Peso Total	200 Kg
Proteção contra altas velocidades	Controle de Passo – 17.5 m/s
Controle de velocidade	<i>Active Stall</i>
Sistema elétrico	Sem escovas e Trifásico - Saída CA
Potência Nominal	6 kW
Rotação Nominal	240 RPM
Tensão de Saída	120/240/400 V
Velocidade Nominal	12,5 m/s
Velocidade de Partida	2,2 m/s
Velocidade Máxima	137 Km/h
Temperatura de Operação	-10 a 50 °C


Fonte: Enersud, Verne-555 (adaptado).

Gráfico 17 – Curva de Potência da Turbina.



Fonte: Enersud, Verne-555.

Gráfico 18 – Curva de potência ideal considerada.



Fonte: Elaborado pelo autor.

3.4. Conclusões parciais do capítulo

Este capítulo trouxe uma breve explicação sobre os conceitos de *Machine Learning* e de RNA, contextualizando os mesmos no cenário atual; realizou-se também uma breve análise e observação gráfica dos dados. Além disso, foram detalhadas as metodologias usadas neste estudo de previsão da potência e da energia eólica a partir da previsão da velocidade do vento empregando uma rede neural artificial (RNA). As metodologias serão a base para o desenvolvimento dos resultados, presentes no próximo capítulo; entre elas, constam a estrutura interna da rede construída e os conjuntos de treinamento, validação e teste. Foram especificadas também as métricas utilizadas para avaliação da precisão do modelo, e incluídas as análises adicionais a serem incrementadas no estudo. Por fim, foi especificada a turbina na qual a estimação de energia e de potência foi baseada, de acordo com a curva de potência, as velocidades de entrada e de saída de operação e as dimensões das pás.

4. RESULTADOS

4.1. Resumo do capítulo

Serão apresentados nessa seção os resultados da rede implementada, incluindo as análises de acurácia do modelo de acordo com as métricas Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE), Erro Médio Absoluto Percentual (MAPE) e o coeficiente U de Theil (UTHEIL), as quais foram mencionadas no capítulo anterior. Também estão incluídos os gráficos das previsões de acordo com os horizontes especificados, que nos permitem visualizar a performance da rede e verificar se ela revela tendências a curto prazo do cenário de vento do local. A curva de potência da turbina escolhida também foi aplicada para realizar a previsão da potência eólica disponível nas próximas horas e, a partir desta previsão, obter também a estimativa de geração de energia pela turbina dentro de um período futuro, sendo consideradas as velocidades de entrada e corte, além do controle de passo, que atua a partir da velocidade nominal.


4.2. Desempenho da rede

Os resultados seguem a seguir de acordo com a seguinte estruturação: primeiramente, foram mostradas as previsões *hour-ahead* com horizonte de, respectivamente, 1, 2, 4 e 6 horas, ilustrando as previsões de velocidade comparadas com os verdadeiros valores medidos pela estação. Foram incluídas também as tabelas com os resultados relevantes para análise do desempenho da rede, a fim de realizar comparações. Foram plotados também os gráficos referentes à performance da rede, sendo eles: erros de validação e treinamento da rede e regressão.

Os gráficos da previsão da potência eólica estão mostrados em seguida. Está incluída também uma análise gráfica da previsão considerando medições a 50 metros de altura, de acordo com a fórmula de variação exponencial do vento com a altura de Hellman. O coeficiente de atrito escolhido de acordo com a região da medição e com a Tabela 1 foi $\alpha = 0,2$.

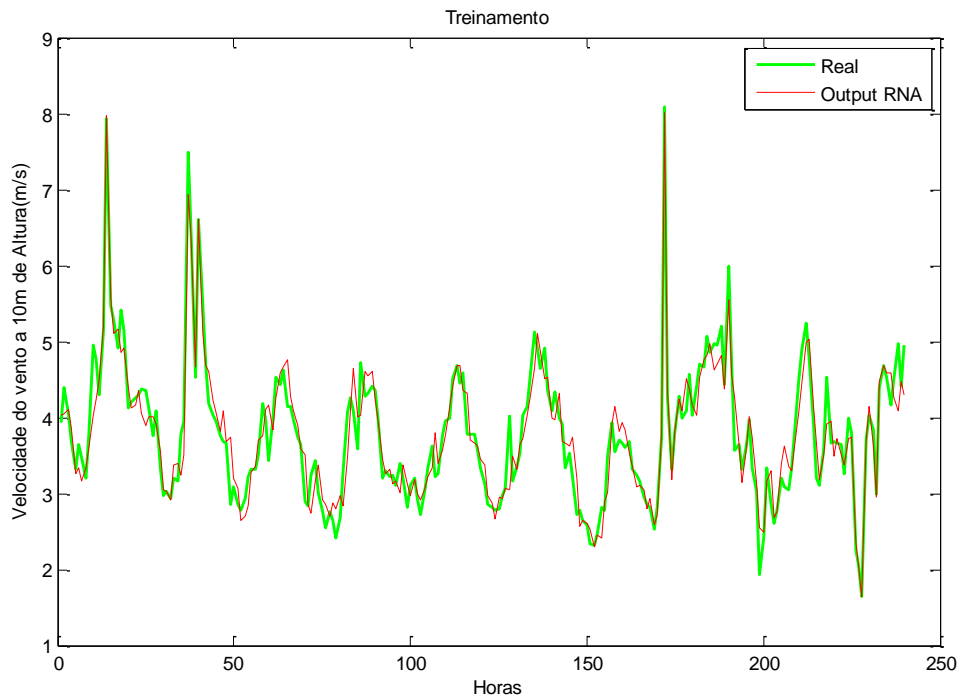
As análises adicionais seguem por último, avaliando o impacto da inserção do método sequencial para a previsão da velocidade do vento a um prazo maior (de até 24h) e o impacto com a inserção de duas janelas ($k = 2$) na entrada da rede. Este gráfico conta também com uma faixa de incerteza de segunda ordem, útil para visualizar como os valores reais medidos se adequam a essa faixa de previsão. O Gráfico 19 mostra a previsão ao longo de 24h com horizonte de 1h, com os erros absolutos ilustrados abaixo, com o respectivo valor de RMSE. Essas previsões são realizadas com treinamentos periódicos de 1 hora, que atualizam as entradas da rede conforme os valores em tempo real se alteram. Desta forma, a rede é também atualizada ao longo do dia. É possível ver que na previsão com horizonte de 1 hora, o desempenho da rede é satisfatório, com regressão linear de treinamento de 0,95, como pode ser visto no Gráfico 22. No Gráfico 20 é vista a resposta ao conjunto de treinamento da rede para o horizonte de 1h. O Gráfico 21 mostra os dados reais seguidos da previsão ao longo de 36h. No Gráfico 23, a operação da turbina não é levada em conta aqui, apenas a potência disponível cinética dos ventos que passam pela área da seção da turbina; a curva de potência ideal da turbina é levada em conta no Gráfico 24. Já no Gráfico 25, vemos a previsão eólica a 50 metros de altura considerando a curva da turbina com coeficiente de atrito de $\alpha = 0,2$. À medida que o horizonte da previsão aumenta, a rede perde acurácia e se torna menos eficiente, como pode ser visto nos Gráficos 26 a 29. Os Gráficos 30 e 31 mostram os resultados da rede para treinamentos múltiplos com horizonte de, respectivamente, 1h e 6h. O Gráfico 32 dá a regressão no caso da rede com horizonte de 4h. No Gráfico 33, vemos os erros quadráticos ao longo das *epochs* dos processos de treinamento e validação.

Gráfico 19 – Previsão com horizonte de 1h ao longo de um período de 24h.

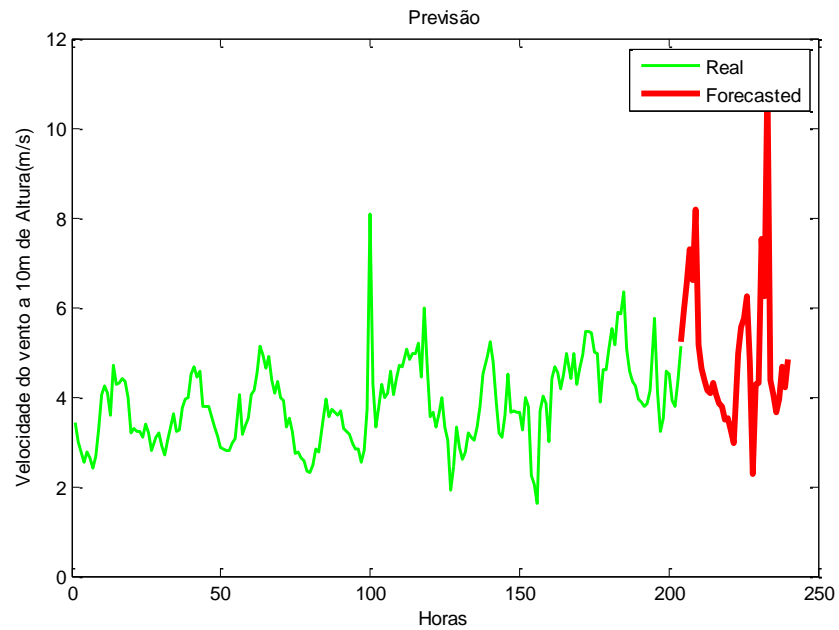


Fonte: Elaborado pelo autor.

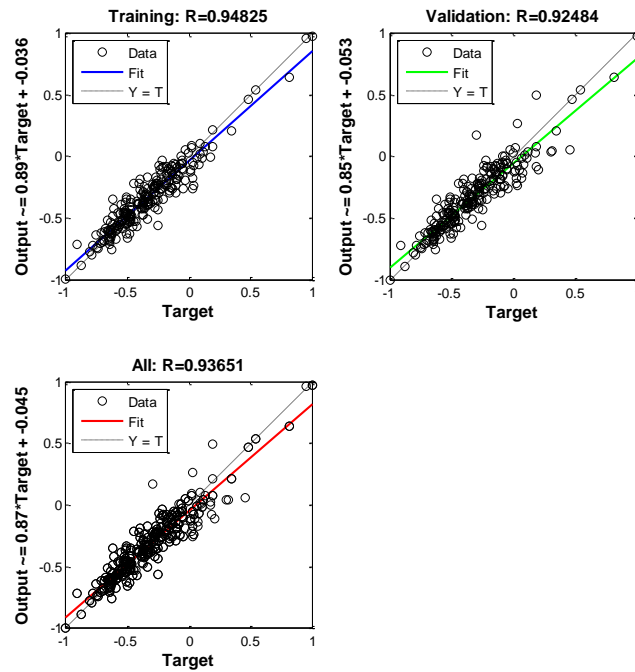
Gráfico 20 – Treinamento da rede com horizonte de previsão de 1h.




Fonte: Elaborado pelo autor.

Gráfico 21 – Previsão 1 *hour-ahead* da velocidade do vento ao longo de 36h.


Fonte: Elaborado pelo autor.

Gráfico 22 – Regressão do treinamento e da validação no modelo 1 *hour-ahead*.


Fonte: Elaborado pelo autor.

Gráfico 23 – Previsão 1 *hour-ahead* da potência eólica teórica disponível.

Fonte: Elaborado pelo autor.

Gráfico 24 – Previsão 1 *hour-ahead* da potência eólica aproveitável.

Fonte: Elaborado pelo autor.

Gráfico 25 – Previsão 1 *hour-ahead* da potência eólica aproveitável a 50 metros.

Fonte: Elaborado pelo autor.

No Gráfico 19 constam as previsões da velocidade do vento com horizonte de uma hora durante o período de um dia. Essas previsões são realizadas com treinamentos periódicos de 1 hora. A Tabela 4 mostra os resultados para essas previsões.

Tabela 4 – Comparação entre medições e previsões com horizonte de 1h.

	Potência Eólica Média (kW)	Energia Gerada no período (kWh)	Fator de Capacidade (%)	Velocidade Média do Vento (m/s)
Previsão	0,52	12,48	8,67	4,72
Real	0,53	12,72	8,83	4,78

Fonte: Elaborado pelo autor.


No Gráfico 26 constam as previsões da velocidade do vento com horizonte de duas horas durante o período de um dia. Essas previsões são realizadas com treinamentos periódicos de 1 hora. A Tabela 5 mostra os resultados para essas previsões.

Tabela 5 – Comparação entre medições e previsões com horizonte de 2h.

	Potência Eólica Média (kW)	Energia Gerada no período (kWh)	Fator de Capacidade (%)	Velocidade Média do Vento (m/s)
Previsão	0,42	10,08	7,01	4,53
Real	0,52	12,48	8,67	4,72

Fonte: Elaborado pelo autor.


Gráfico 26 – Previsão com horizonte de 2h ao longo de um período de 24h.



Fonte: Elaborado pelo autor.

No Gráfico 27 constam as previsões da velocidade do vento com horizonte de quatro horas durante o período de um dia. Essas previsões são realizadas com treinamentos periódicos de 1 hora. A Tabela 6 mostra os resultados para essas previsões.

Gráfico 27 – Previsão com horizonte de 4h ao longo de um período de 24h.



Fonte: Elaborado pelo autor.

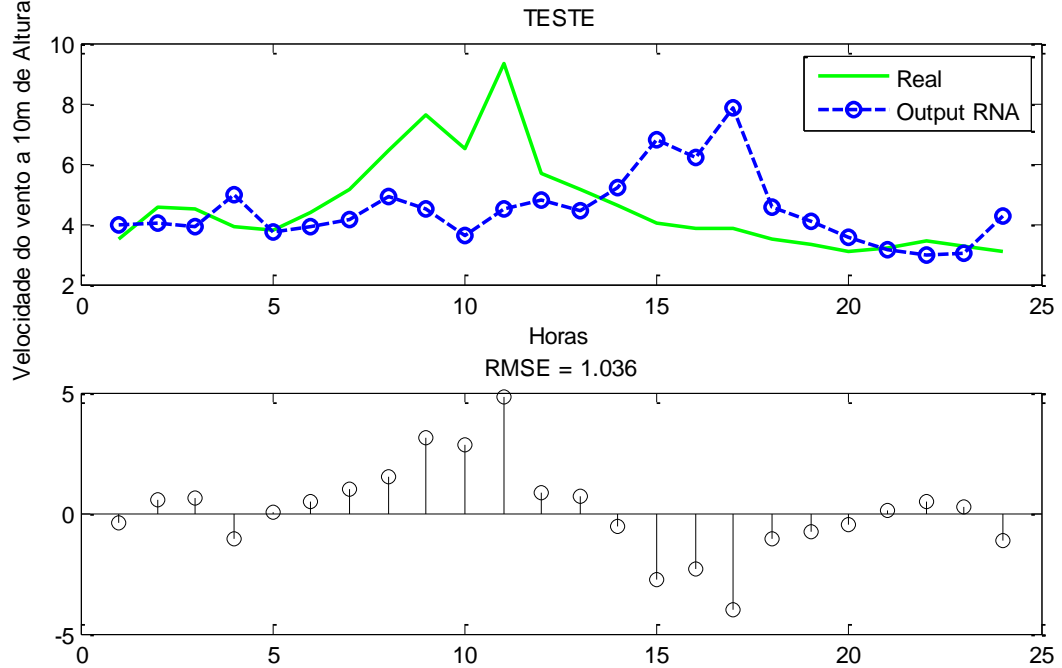
Tabela 6 – Comparação entre medições e previsões com horizonte de 4h.

	Potência Eólica Média (kW)	Energia Gerada no período (kWh)	Fator de Capacidade (%)	Velocidade Média do Vento (m/s)
Previsão	0,34	8,16	5,67	4,31
Real	0,50	12	8,33	4,67

Fonte: Elaborado pelo autor.

No Gráfico 28 constam as previsões da velocidade do vento com horizonte de seis horas durante o período de um dia. Essas previsões são realizadas com treinamentos periódicos de 1 hora. A Tabela 7 mostra os resultados para essas previsões.

Gráfico 28 – Previsão com horizonte de 6h ao longo de um período de 24h.




Fonte: Elaborado pelo autor.

Tabela 7 – Comparação entre medições e previsões com horizonte de 6h.

	Potência Eólica Média (kW)	Energia Gerada no período (kWh)	Fator de Capacidade (%)	Velocidade Média do Vento (m/s)
Previsão	0,41	9,84	6,83	4,51
Real	0,49	11,76	8,17	4,63


Fonte: Elaborado pelo autor.

Gráfico 29 – Treinamento da rede com horizonte de previsão de 6h.




Fonte: Elaborado pelo autor.

Gráfico 30 – Previsão com horizonte de 1h com treinamentos múltiplos.

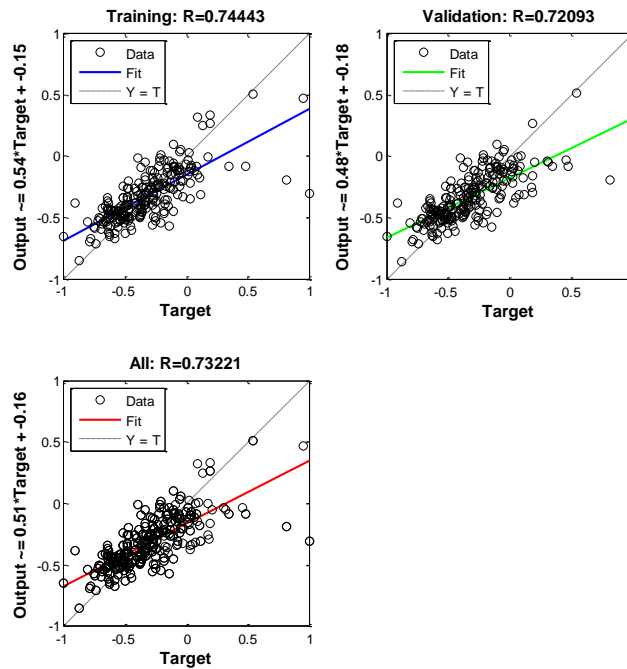


Fonte: Elaborado pelo autor.

Gráfico 31 – Previsão com horizonte de 6h com treinamentos múltiplos.



Fonte: Elaborado pelo autor.

Gráfico 32 – Regressão do treinamento e da validação no modelo 4 *hour-ahead*.

Fonte: Elaborado pelo autor.

A Tabela 8 compara os resultados obtidos para as previsões de curto prazo mostradas anteriormente, de acordo com os diferentes horizontes escolhidos. Vale destacar que cada


métrica tem uma unidade; o RMSE e o MAE têm unidade de (m/s). Já MAPE é dado em percentual (%), enquanto UTHEIL não possui unidade, e seu valor deve ser avaliado comparando-o com 1. Para $UTHEIL < 1$, a rede apresenta desempenho superior à previsão trivial. Se $UTHEIL > 1$, não há sentido em adotar a rede, uma vez que a própria previsão trivial apresenta previsões mais certas. O ideal é que essa métrica fique mais próxima possível de zero.

Tabela 8 – Comparação entre os valores com horizontes de previsão distintos.

Métrica	horiz = 1h	horiz = 2h	horiz = 4h	horiz = 6h
RMSE	0,65	0,79	0,91	1,04
MAPE	10,1	19,1	19,3	24,4
MAE	0,56	1,06	1,01	1,42
UTHEIL	0,69	0,77	0,74	0,91
Regressão Total	0,94	0,79	0,73	0,59


Fonte: Elaborado pelo autor.

Gráfico 33 – Erro quadrático no treinamento e validação.




Fonte: Elaborado pelo autor.

Nos Gráficos 34 e 35 constam os resultados das análises adicionais considerando a previsão a um prazo expandido, com horizonte de 24 horas. Na primeira análise, a rede foi treinada para cada um dos horizontes, de 1h até a previsão *Day-Ahead* considerando um algoritmo sequencial, na qual as próprias previsões já obtidas pela rede são utilizadas como entrada para realizar as previsões seguintes.

Gráfico 34 – Previsão *Day-Ahead* com algoritmo sequencial, com faixa de incerteza.

Fonte: Elaborado pelo autor.

Gráfico 35 – Previsão *Day-Ahead* com inclusão de 2 janelas, com faixa de incerteza.

Fonte: Elaborado pelo autor.

O Gráfico 34 mostra esse resultado. Já a segunda análise conta com a inserção de valores prévios ao valor atual de entrada (pressão, umidade, temperatura, velocidade do vento), incluindo duas janelas ($k=2$), ou seja, considerando os valores de até 2 horas antes da hora presente. O Gráfico 35 mostra os resultados da previsão *Day-Ahead* considerando a segunda análise. Ambos os gráficos contam com a inclusão de uma faixa de incerteza de ordem 2.

4.3. Conclusões parciais

Este capítulo se destinou a mostrar os resultados do estudo, revelando os valores obtidos para elementos relevantes na avaliação do desempenho e acurácia da rede, entre eles, as métricas RMSE, MAE, MAPE e UTHEEL. Os gráficos das previsões de acordo com os horizontes especificados foram também mostrados. A previsão da potência e a estimação de energia gerada também foram apresentadas e comparadas. Os resultados mostram que a rede tem melhor performance em previsões com horizonte reduzido; os resultados desenvolvidos neste capítulo serão, portanto, necessários para que sejam feitas as discussões presentes no próximo capítulo, que se destina à análise dos resultados e às conclusões do estudo.

5. CONCLUSÕES

Podemos observar que as previsões com horizonte de previsão de uma hora mostraram valores satisfatórios, com regressão alta de treinamento e validação, e coeficiente UTHEIL de 0,69, mostrando que a rede tem desempenho superior à previsão trivial. Além disso, é visível o bom ajuste da previsão aos dados reais medidos pela estação meteorológica. Apresentou um erro percentual de cerca de 10% nos casos, com RMSE de cerca de 0,6 a 0,7 (m/s). O Gráfico 30 mostra que múltiplos treinamentos dão forma a uma curva compatível com os dados reais. No entanto, à medida que o horizonte aumenta, as dificuldades da rede crescem, fazendo com que a incerteza da previsão se torne maior. Isso pode ser visto com o Gráfico 28, que mostra uma certa discrepância da curva em relação aos verdadeiros pontos de pico, que ocorreram por volta da hora 11. Além disso, o UTHEIL para o horizonte de 6h apresentou valor igual a 0,91, muito próximo a 1, o que indica que, apesar da previsão ainda ser superior à previsão trivial, ela apresenta maiores níveis de incerteza, com regressão total igual a 0,59. Também é possível observar a propagação cúbica dos erros da velocidade do vento; com pequenos desvios da velocidade prevista em relação à velocidade real, tem-se grandes desvios da potência prevista em relação à potência real e, portanto, maiores erros na estimação da energia gerada (e também na estimação do FC), conforme pode ser observado, por exemplo, na Tabela 5, onde a diferença entre as velocidades médias prevista e real é de 0,19 (m/s) e as potências médias prevista e real são, respectivamente, iguais a 0,42 e 0,52 kW. Nas análises adicionais, pode-se ver que o método sequencial não funciona bem na rede implementada, como pode ser visto no Gráfico 34, uma vez que os próprios erros das previsões são propagados para as previsões posteriores. A curva das medições reais não se enquadra bem dentro da faixa de incerteza prevista neste método. Já a segunda análise incluindo 2 janelas de dados passados melhora um pouco o desempenho da rede ao longo prazo, fazendo com que a faixa de incerteza envolva melhor os dados reais, mas ao mesmo tempo reduz a acurácia da rede nas horas iniciais, como pode ser visto no Gráfico 35. Não obstante, no curto prazo, foi possível perceber que o modelo proposto conseguiu representar razoavelmente o comportamento do vento na região do estudo, a partir de um número reduzido de dados de amostra.

5.1. Conclusões Finais

A energia eólica tem apresentado taxas de crescimento elevadas nos últimos anos, assim como algumas outras fontes de energia renovável como a energia solar. Isso revela uma tendência mundial de busca por fontes alternativas e renováveis de energia, contexto em que a energia eólica se destaca. Da mesma forma é no Brasil: essa forma de energia cresceu de forma exponencial nos últimos anos, com a construção de diversos parques eólicos em várias regiões do país, que aposta cada vez mais nas fontes renováveis em sua matriz energética. O investimento nos parques eólicos mostra que o Brasil está cada vez mais aproveitando todo o seu potencial eólico, principalmente na região Nordeste, onde os ventos nas partes litorânea e central possuem boas características para aproveitamento de energia.

Esse trabalho expôs alguns aspectos técnicos da energia eólica, além de modelagens matemáticas para esclarecimento do fenômeno. Seu contexto histórico e sua importância no planejamento energético e nos mercados de energia também foram elucidados, para que o objetivo deste estudo se tornasse claro em termos de aplicabilidade. Dessa maneira, discorreu-se sobre os impactos da natureza intermitente do vento na geração da energia elétrica e na operação de sistemas interligados. É importante frisar também que, no Brasil, essa forma de energia intercede não como uma fonte substitutiva, mas complementar à fonte hidráulica, que por sua vez é a base da matriz elétrica brasileira. Além disso, a complementaridade que existe entre essas duas formas de energia ao longo do ano torna favorável a cooperação entre elas.

Também se ponderou sobre os desafios que o futuro está reservando para o setor elétrico, que deverá lidar com a inserção de fontes alternativas nas redes e, portanto, com os problemas que dela incorrem. Por isso, contextualizou-se o cenário mundial quanto ao avanço da AI, com o desenvolvimento de novas técnicas de aprendizado de máquina, que serão a base da nova revolução digital e da chamada Indústria 4.0. Dentro dessa revolução, enquadram-se ideias como, por exemplo, condução automática de veículos, sistemas de reconhecimento inteligentes e, no setor elétrico, as redes inteligentes, ou *Smart Grids*. Em função dessa visão de futuro, as abordagens computacionais se tornam cada vez mais relevantes, entre elas, a implementação das redes neurais de DL, que terão plena utilidade nas mais variadas tarefas futuramente. Neste trabalho, uma RNA foi implementada para realizar a previsão da velocidade do vento na localidade de Natal, RN, para então fazer uma estimativa da energia elétrica que poderá ser gerada por uma turbina instalada no local, no horizonte de curto prazo. Demonstra-se, portanto, a aplicabilidade dessas técnicas na área de energia.

É evidente também que a tecnologia de ML é muito nova, e está passando por uma fase de acelerado desenvolvimento, com milhares de pesquisadores – na maioria das vezes, engenheiros de computação e cientistas de dados – se dedicando ao seu aprimoramento constantemente. O grande impulso dessa área surgiu junto com o aumento na geração de dados no contexto digital, que exigiu o aumento da nossa capacidade de processamento, dando origem ao conceito do *Big Data*. É, em vista disso, uma ciência em constante mudança, que se encontra na fronteira do conhecimento humano, cuja pesquisa se dá em meios mais específicos da ciência da computação. Além disso, o desafio da previsibilidade de fenômenos climáticos como o vento é objeto de estudo em todo o mundo há algum tempo, com modelos inteligentes cada vez mais complexos e sofisticados. Logo, este estudo consiste em uma introdução a esse mundo da AI, que será, e já é, muito útil para os sistemas de eletricidade; busca o aprendizado e a exemplificação dessas técnicas, trazendo-as para a área de geração de energia elétrica.

5.2. Desenvolvimentos Futuros

A ideia de continuar a proposta deste trabalho, construindo modelos cada vez mais precisos e eficientes para a previsão da potência eólica, se baseia no desenvolvimento de modelos mais sofisticados, com inserção de maior número de dados provindos de múltiplas estações, unindo a ciência de dados com a engenharia. Muitos dos modelos que oferecem maior precisão de séries temporais, representando adequadamente as características sazonais da velocidade do vento nas regiões estudadas, envolvem a combinação de métodos distintos, como, por exemplo, o método ARXAN, um modelo híbrido que combina os modelos RNA e o modelo Auto Regressivo Integrado de Médias Móveis com entradas de Variáveis Exógenas (ARIMAX); este último consiste em um modelo estatístico que oferece uma descrição de processos estocásticos em termos polinomiais. Logo, tal como o ARXAN, os modelos mais complexos podem gerar resultados mais precisos, que terão grande utilidade em áreas que demonstram interesse pela previsão eólica, como o próprio setor elétrico, o qual foi abordado neste estudo.

REFERÊNCIAS

ARTIPOLI, GIANLUCA & SCHIAVONE, FRANCESCO. Physical Modeling in Wind Energy Forecasting. DEWI Magazin. 44.10, 2014.

BARRY R, Chorley RJ. Atmosphere, weather and climate, 7th edition. Rouledge, London, 1998.

BERTRAND CORNÉLUSSE, Ph.D. How the European day-ahead electricity market Works. Lecture at ELEC0018-1 - Marché de l'énergie, Université de Liège, 2017.

CCEE - Câmara de Comercialização de Energia Elétrica – Com quem se relaciona. Disponível em <https://www.ccee.org.br/portal/> . Acesso em 10/01/2020.

CODEPROJECT, Disponível em <https://www.codeproject.com/>. Acesso em 10/01/2020.

CRADDEN L., WEYWADA P.L., ATCHESON M. The Offshore Environment. In: Cruz J., Atcheson M. (eds) Floating Offshore Wind Energy. Green Energy and Technology. Springer, Cham, 2016.

DIGITAL TRENDS, Disponível em <https://www.digitaltrends.com/>. Acesso em 10/01/2020.

Dr. FIRAS A. HADI. Diagnosis of the best method for wind speed extrapolation Department of Wind Energy, Ministry of Science and Technology, Baghdad, Iraq. International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 2015.

ELETROBRÁS CONSULPUC, Atlas do Levantamento Preliminar do Potencial Eólico Nacional. S.d. Convênio ECV-192/79.

EMPRESA DE PESQUISA ENERGÉTICA, BALANÇO Energético Nacional 2019 - Ano Base 2018. Brasília: DNDE Secretaria de Energia, Ministério de Minas e Energia, 2019.

F.R. MARTINS, R.A. GUARNIERI E E.B. PEREIRA. O aproveitamento da energia eólica. Instituto Nacional de Pesquisas Espaciais, Centro de Previsão do Tempo e Estudos Climáticos, São José dos Campos, SP, Brasil, 2007.

FAST AI, Making neural nets uncool again, Disponível em <https://www.fast.ai/>. Acesso em 10/01/2020.

FLTXNY MAGLEV e Wind turbine control systems and techniques, 2011.

GUARNIERI, RICARDO & PEREIRA, ENIO & CHOU, SIN CHAN & CHOU, Instituto & Nacional, & Espaciais, Pesquisas & José, São & Campos, Dos & Paulo, São & Brazil. Solar radiation forecast using artificial neural networks in south Brazil, 2006.

INTERNATIONAL ENERGY AGENCY, disponível em <https://www.iea.org/statistics/electricity/>. Acesso em 12/11/2019.

IOWA STATE UNIVERSITY, Iowa Environment Mesonet – Wind Roses. Disponível em https://mesonet.agron.iastate.edu/sites/windrose.phtml?station=SBNT&network=BR_ASOS. Acesso em 10/01/2020.

JANARDAN S. ROHATGI, VAUGHN NELSON. Wind Power, Alternative Energy Institute, West Texas A & M University, 1994.

KOLEV, VALENTIN, Forecasting the hourly power output of wind farms for day-ahead and intraday markets, Faculty of Electrical Engineering, Technical University of Sofia, Bulgaria, 2018.

MAIA, Thales Alexandre Carvalho. Projeto e Construção de um Gerador a Ímãs Permanentes de Fluxo Axial para Turbina Eólica de Pequena Potência, Universidade Federal de Minas Gerais, 2011.

MELO, Marcelo Silva de Matos. Energia Eólica: Aspectos Técnicos e Econômicos / Marcelo Silva de Matos Melo. - Rio de Janeiro: UFRJ/COPPE, 2012.

MERCADO IBÉRICO DE ELETRICIDADE. Disponível em <https://www.mibel.com/>. Acesso em 10/01/2020.

METEOBLUE WEATHER, disponível em <https://content.meteoblue.com/pt/especificacoes/fontes-de-dados/medicoes/vento>. Acesso em 10/01/2020.

MINISTÉRIO DE MINAS E ENERGIA, CMSE – Comitê de monitoramento do setor elétrico. Disponível em <http://www.mme.gov.br/web/guest/conselhos-e-comites/cmse>. Acesso em 10/01/2020.

NASCIMENTO CAMELO, Henrique do; LUCIO, Paulo Sérgio; LEAL JUNIOR, João Bosco Verçosa e CARVALHO, Paulo Cesar Marques de. Proposta para Previsão de Velocidade do Vento Através de Modelagem Híbrida Elaborada a Partir dos Modelos ARIMAX e RNA. Rev. bras. Meteorol, 2018.

ODILON A. CAMARGO DO AMARANTE, MICHAEL BROWER E JOHN ZACK. Atlas do Potencial Eólico Brasileiro. ANTONIO LEITE DE SÁ, 2001.

ONS. Sobre o ONS. Disponível em <http://www.ons.org.br/paginas/sobre-o-ons/o-que-e-ons>. Acesso em 10/01/2020.

PALUSZEK, MICHAEL and THOMAS, STEPHANIE. MATLAB Machine Learning, Apress, 2017.

POL OLIVELLA-ROSELL, GUILLEM VINALS-CANAL, ANDREAS SUMPER, ROBERTO VILLAFILA-ROBLES. Day-ahead micro-market design for distributed energy resources, Centre d'Innovació Tecnològica en Convertidors Estàtics i Accionaments (CITCEA-UPC), Departament d'Enginyeria Elèctrica. Universitat Politècnica de Catalunya, Barcelona, Spain, 2016.

QINWEI, DUAN. A Price-Based Demand Response Scheduling Model in Day-Ahead Electricity Market, Department of Electrical and Electronic Engineering. The University of Hong Kong, Hong Kong SAR, 2016.

RUI BO, Senior Member, IEEE, Jordan Bakke. Evaluating Impact of Wind Power Hourly Variability On Day-ahead Electricity Markets, 2014.

S&E INSTRUMENTOS – Soluções em medição, controle e automação industrial, disponível em <https://seinstrumentos.com.br/wp/index.php/outros-produtos-se/anemometros/medidor-velocidade-do-vento/>. Acesso em 10/01/2020.

SAS, Machine Learning: O que é e qual a sua importância? Disponível em https://www.sas.com/pt_br/insights/analytics/machine-learning.html. Acesso em 10/01/2020.

SAS, Redes Neurais: O que são e qual a sua importância? Disponível em https://www.sas.com/pt_br/insights/analytics/neural-networks.html. Acesso em 10/01/2020.

SONDA - SISTEMA DE ORGANIZAÇÃO NACIONAL DE DADOS AMBIENTAIS, Disponível em <http://sonda.ccst.inpe.br/>. Acesso em 10/01/2020.

STARTSE, Indústria 4.0: entenda o que é a quarta revolução industrial. Disponível em <https://www.startse.com/noticia/nova-economia/60414/industria-4-0-entenda-o-que-e-quarta-revolucao-industrial>. Acesso em 10/01/2020.

STUART RUSSELL AND PETER NORVIG, Artificial Intelligence: A Modern Approach, 3rd edition, 2009.

T. VAN ENGELEN, S. KANEV, in Wind Energy Systems, Wind turbine control systems and techniques, 2011.

TOWARDS DATA SCIENCE - MEDIUM, About Train, Validation and Test Sets in Machine Learning. Disponível em <https://towardsdatascience.com/train-validation-and-test-sets-72cb40cba9e7>. Acesso em 10/01/2020.

ANEXO – Especificações da Turbina Verne 555



VERNE 555



A **VERNE 555** é uma turbina eólica de eixo horizontal, desenvolvida para atender às necessidades de energia que superam o consumo individual. A depender da velocidade do vento no local de instalação, a turbina Verne pode gerar até 6 kW, sendo ideal para alimentar pequenos conjuntos residenciais, suprir de energia localidades isoladas como ilhas e zonas rurais e atender a demandas de agricultura e indústria de pequeno porte. A turbina conta com alternador de baixa rotação de ímãs permanentes, tecnologia PM DD (patente da Enersud PI 0202084-0). É construída com materiais resistentes à oxidação, o que a torna um equipamento de alta confiabilidade, permitindo a instalação em ambientes agressivos. Entre as diversas aplicações possíveis, as mais recorrentes são:

- Condomínios e Comunidades
- Residências de Médio Consumo
- Bombeamento d'água e compressão de ar
- Demandas rurais e industriais


Configuração

Parâmetro	Modelo 555
Diâmetro da hélice	5,55 m
Número de pás	3
Tipo de pás	Torcida (10 aerofólios)
Material das Pás	Composto de Fibra de Vidro
Vida útil de projeto	20 anos
Peso Total	200 kg
Proteção contra altas velocidades	Stall (Controle de Passo) – 17,5 m/s
Controle de velocidade	Active Stall
Sistema magnético	Neodímio (ímã permanente)
Caixa de Engrenagens	Não Possui (<i>Drive</i> direto)
Sistema elétrico	Sem Escovas e Trifásico - Saída AC
Tipo de Alternador Elétrico	Fluxo Axial (encapsulado em epóxi)
Materiais Anti Corrosão	Alumínio / Inox / Mat. Galvanizado
Balanceamento - Estático	Verificação pós-pintura
Conexão com a Torre	Flange Padrão ANSI DIN 6"

Desempenho

Parâmetro	Modelo 555
Potência Nominal	6000 W
Rotação Nominal	240 RPM
Torque de partida	0,3 Nm
Tensão de saída	120/240/400 volts
Velocidade Nominal	12,5 m/s
Velocidade de Partida	2,2 m/s
Velocidade Máxima	137 km/h
Temperatura de operação	-10 a 50 °C

Geração



Curva de Potência

