



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

FÁBIO HENRIQUE DE ANDRADE LIMA

**PREVISÃO DE GERAÇÃO EÓLICA A CURTO PRAZO EM TEMPO REAL
BASEADA EM DADOS OBSERVACIONAIS DAS CENTRAIS EÓLICAS E DA
PREVISÃO NUMÉRICA DO TEMPO**

Recife

2019

FÁBIO HENRIQUE DE ANDRADE LIMA

**PREVISÃO DE GERAÇÃO EÓLICA A CURTO PRAZO EM TEMPO REAL
BASEADA EM DADOS OBSERVACIONAIS DAS CENTRAIS EÓLICAS E DA
PREVISÃO NUMÉRICA DO TEMPO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Pernambuco como requisito parcial para obtenção do título de Mestre em Engenharia Mecânica.

Área de Concentração: Processos e Sistemas Térmicos.

Orientador: Prof. Dr. Alex Maurício Araújo.

Coorientador: Prof. Dr. Alexandre Carlos Araújo da Costa.

Recife

2019

Catálogo na fonte
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

- L732p Lima, Fábio Henrique de Andrade.
Previsão de geração eólica a curto prazo em tempo real baseada em dados observacionais das centrais eólicas e da previsão numérica do tempo / Fábio Henrique de Andrade Lima. - 2019.
109 folhas, il., tabs., abr., sigl., e símb.
- Orientador: Prof. Dr. Alex Maurício Araújo.
Coorientador: Prof. Dr. Alexandre Carlos Araújo da Costa.
- Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Mecânica, 2019.
Inclui Referências e Apêndice.
1. Engenharia Mecânica. 2. Energia eólica. 3. Previsão em tempo real. 4. Previsão numérica do tempo. 5. Redes neurais. I. Araújo, Alex Maurício (Orientador). II. Costa, Alexandre Carlos Araújo da (Coorientador). III. Título.

UFPE

621 CDD (22. ed.)

BCTG/2019-155

Fábio Henrique de Andrade Lima

**PREVISÃO DE GERAÇÃO EÓLICA DE CURTO PRAZO EM TEMPO REAL
BASEADA EM DADOS OBSERVACIONAIS DAS CENTRAIS EÓLICAS E DA
PREVISÃO NUMÉRICA DO TEMPO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Pernambuco como requisito parcial para obtenção do título de Mestre em Engenharia Mecânica.

Aprovada em: 07/02/2019

BANCA EXAMINADORA

Prof.^o Dr. Alex Maurício Araújo (Orientador)
Universidade Federal de Pernambuco

Prof.^o Dr. Alexandre Carlos Araújo Costa (Coorientador)
Universidade Federal de Pernambuco

Prof.^o Dr. Jorge Recarte Henríquez Guerrero (Examinador Interno)
Universidade Federal de Pernambuco

Prof.^o Dr. Thiago Luiz do Vale Silva (Examinador Externo)
Agência Pernambucana de Águas e Clima

AGRADECIMENTOS

Agradeço a Deus por me dar forças para superar as dificuldades.

À minha esposa Luara, por estar sempre ao meu lado, pelo apoio, compreensão, paciência e pelas palavras de incentivo nos momentos difíceis.

Aos meus filhos Davi e Maria Luiza, por compreenderem o sacrifício dos momentos de convívio.

Aos meus pais Luiz e Estela, por me tornarem a pessoa que sou.

Aos meus orientadores Prof. Dr. Alexandre Carlos Araújo da Costa e Prof. Dr. Alex Maurício Araújo pelo conhecimento adquirido e pela paciência nos momentos de correção de rumo.

Ao Operador Nacional do Sistema Elétrico (ONS), ao Programa de Pós-Graduação em Engenharia Mecânica (PPGEM-UFPE) e ao Centro de Energias Renováveis (CER-UFPE) pela oportunidade de crescimento e desenvolvimento.

A todos que me ajudaram direta ou indiretamente para realização desta dissertação.

RESUMO

Nos últimos anos, a operação do Sistema Interligado Nacional do Brasil foi bastante afetada pelo grande incremento de geração eólica. A crescente participação dessa modalidade intermitente de geração exige que a operação do sistema antecipe a tomada de decisões, de forma a agregar um maior controle de frequência, reserva e fluxos de intercâmbio, além de melhorar a segurança na operação do sistema interligado nesse novo contexto de fontes renováveis e intermitentes. Para permitir que esse controle seja feito de forma confiável, faz-se necessário o uso, por parte da operação, de modelos de previsão de curto prazo da geração eólica. Neste sentido, o objetivo deste trabalho é avaliar modelos de séries temporais de curto prazo para a previsão da potência de saída de centrais eólicas, empregando previsões numéricas do tempo como variáveis exógenas para horizontes de 3 e 6 horas à frente, escalas temporais onde é tomada a maior parte das decisões na operação em tempo real devidas a problemas decorrentes da variação da geração eólica. Para tanto, são utilizadas redes neurais tendo como entradas séries temporais observacionais de potência e estimativas da velocidade do vento oriundas de um modelo geral da circulação atmosférica (General Circulation Model, GCM). Para isto, são utilizados (em modelos de séries temporais de ajuste global) os dados observacionais de 15 centrais eólicas localizadas na região Nordeste do Brasil, monitoradas pelo Operador Nacional do Sistema Elétrico (ONS) e escolhidas em função das características do seu terreno. Realiza-se uma análise de sensibilidade do desempenho dos modelos utilizando informações como altitude, orografia e distância à costa de cada central. Também, verifica-se o comportamento dos modelos em função da arquitetura das redes neurais, do número e do intervalo entre variáveis regressoras de potência e do uso de diferentes pontos da malha do GCM. Conclui-se que o uso de 4 pontos de malha do GCM provoca uma melhora do desempenho dos modelos em centrais localizadas no interior, em orografia complexa e elevada altitude, com destaque para o horizonte de previsão de 6h (o que não ocorre com um modelo puramente estatístico). Também, observa-se uma melhora com o emprego de vetores de variáveis regressoras endógenas cuja distância temporal entre variáveis (time-lag) reproduz o comportamento cíclico diário do vento.

Palavras-chave: Energia eólica. Previsão em tempo real. Previsão numérica do tempo. Redes neurais.

ABSTRACT

In recent years, the Brazilian National Interconnected System operation has been greatly affected by the large increase in wind power generation. The increasing participation of this intermittent mode of generation requires the system operation to anticipate the decision making to aggregate a better control of frequency, reserve and exchange flows, besides improving the security of the interconnected system operation in this new context of renewable and intermittent sources. To allow this control to be done in a reliable way, it is necessary to use short-term forecast models of wind generation by the operation. In this sense, the objective of this work is to evaluate short-term time series models for predicting the output power of wind farms, using numerical weather predictions as exogenous variables for horizons of 3 and 6 hours ahead, temporal scales where it is taken most of the decisions in the real-time operation due to problems arising from the wind power variation. To do so, are used neural networks and as inputs, the observational time series of power and estimated wind velocity from a General Circulation Model (GCM). For this, are used (in time series models of global adjustment) the observational data of 15 wind farms located in the Northeast region of Brazil, monitored by the National Electric System Operator (ONS) and chosen according to the characteristics of their terrain. A sensitivity analysis of the performance of the models was performed using information such as altitude, orography, and distance to the coast of each wind farm. Also, the behavior of the models according to the neural network architecture, the number and interval between power regressors variables and the use of different points of the GCM grid are verified. It is concluded that the use of 4 grid points of the GCM causes an improvement of the performance of the models in wind farms located in the interior, in complex orography and high altitude, with highlight to the 6h forecast horizon (which does not occur with a purely statistical model). Also, it is observed improvement with the use of endogenous regressors variables vector, whose time-lag between variables reproduces the daily cyclical behavior of the wind.

Keywords: Wind energy. Real-time forecasting. Numerical weather forecasting. Neural networks.

LISTA DE FIGURAS

Figura 1 - Evolução da Capacidade Instalada no Brasil em MW	15
Figura 2 - Sistema Interligado Nacional.	16
Figura 3 - Fluxo em MW na LT 230 kV Banabuiú / Russas II.	20
Figura 4 - Diagrama unifilar da região elétrica do exemplo do dia 11/12/2018.....	20
Figura 5 - Frequência do sistema elétrico e geração eólica.	21
Figura 6 - Exemplo de um processo estocástico.....	25
Figura 7 - Esquema de um neurônio.	26
Figura 8 - Funções de ativação.	27
Figura 9 - MLP (Multilayer Perceptron).	27
Figura 10 - Esquema de malha e processos parametrizados em um NWP.....	29
Figura 11 - Mapa com os parques eólicos consideradas no estudo	34
Figura 12 - Diagrama dos pontos de malha do GFS e da posição da central eólica (Gn).	36
Figura 13 - Diagrama do modelo de Rede Neural Artificial tipo '1'	38
Figura 14 - Diagrama do modelo de Rede Neural Artificial tipo '3'	39
Figura 15 - Diagrama do modelo de Rede Neural Artificial tipo '5'	39
Figura 16 - Diagrama do modelo de Rede Neural Artificial tipo '2'	40
Figura 17 - Diagrama do modelo de Rede Neural Artificial tipo '4'	40
Figura 18 - Fluxograma dos processos de treinamento e validação dos modelos.	42
Figura 19 - Diagrama de Taylor	43
Figura 20 - Diagramas de Taylor para G1	46
Figura 21 - IOP em função dos subtipos para G1.....	46
Figura 22 - Desvio padrão em função dos subtipos para G1	47
Figura 23 - Diagramas de Taylor para G6	49
Figura 24 - IOP em função dos subtipos para G6.....	49
Figura 25 - Desvio padrão em função dos subtipos para G6.....	50
Figura 26 - RMSD em função da altitude para o horizonte de 3 h.	53
Figura 27 - RMSD em função da altitude para o horizonte de 6 h.	54
Figura 28 - RMSD em função da complexidade orográfica para horizonte de 3 h.	55
Figura 29 - RMSD em função da complexidade orográfica para horizonte de 6 h.	56
Figura 30 - RMSD em função dos Subtipos para horizonte de 3 h.	57
Figura 31 - RMSD em função dos Subtipos para horizonte de 6 h.	57
Figura 32 - RMSD em função dos números de Neurônios para horizonte de 3 h.	58

Figura 33 - RMSD em função dos números de Neurônios para horizonte de 6 h.	58
---	----

LISTA DE TABELAS

Tabela 1 - Características dos parques eólicos	35
Tabela 2 - Tipos de modelo de acordo com a entrada	41
Tabela 3 - Subtipos de modelos	41
Tabela 4 - Percentual de dados considerados de boa qualidade.	44
Tabela 5 - Resumo dos Resultados para o Horizonte de 3 h.	51
Tabela 6 - Resumo dos Resultados para o Horizonte de 6 h.	52

LISTA DE ABREVIATURAS E SIGLAS

ABEEÓLICA	Associação Brasileira de Energia Eólica
ANEEL	Agência Nacional de Energia Elétrica
CAG	Controle Automático de Geração
CER	Centro de Energias Renováveis
GDFNN	Generalized Dynamic Fuzzy Neural Network
GFS	Global Forecast System
HPC4E	High Performance Computing for Energy Project
Inf-FS	Infinite Feature Selection
IOP	Improvement of Persistence
LER	Leilão de Energia de Reserva
LFA	Leilão de Fontes Alternativas
LT	Linha de Transmissão
MLP	Multilayer Perceptron
MME	Ministério de Minas e Energia
NCEP	National Centers for Environmental Prediction
NE	Nordeste
NWP	Numerical Weather Prediction
ONS	Operador Nacional do Sistema Elétrico
PROINFA	Programa de Incentivo às Fontes Alternativas
RBf	Radial Base Function
RMSD	Root Mean Square Error
RMSE	Root Mean Square Difference
RNA	Redes Neurais Artificiais
SCADA	Supervisory Control and Data Acquisition
SIN	Sistema Interligado Nacional
SVM	Support Vector Machines
UFPE	Universidade Federal de Pernambuco
UTC	Universal Time Coordinated
WRF	Weather Research and Forecasting Model

LISTA DE SÍMBOLOS

d	Atraso ou time-lag
k	Horizonte futuro
n	Número de variáveis regressoras de potência (endógenas)
$nx - ey - hz$	Mnemônico representando o subtipo, com <i>n neurônios</i> , <i>y entradas</i> de variáveis regressoras de potência e <i>z horas</i> de time-lag.
p_t	Potência observada da geração eólica no instante atual t
$\hat{p}_{t+k}$	Previsão da potência de geração eólica em um horizonte k
p_{t-d}	Potência observada de geração eólica com atraso (time-lag) d
p_{t-nd}	Potência observada de geração eólica com atraso (time-lag) $n \times d$
Δt	Intervalo de tempo
t	Instante atual
$t + k$	Instante futuro, em um horizonte k
$\hat{v}_{t+k}$	Previsão da velocidade do vento em um horizonte k

SUMÁRIO

1	INTRODUÇÃO	14
1.1	EVOLUÇÃO DA CAPACIDADE INSTALADA DE GERAÇÃO EÓLICA NO BRASIL	14
1.2	O SIN E O ONS	15
1.3	PREVISÃO DE GERAÇÃO EÓLICA E A OPERAÇÃO DO SIN	18
1.4	EXEMPLOS DO IMPACTO DA GERAÇÃO EÓLICA NA OPERAÇÃO	19
1.5	OBJETIVOS GERAIS	22
1.6	OBJETIVOS ESPECÍFICOS	22
1.7	ESTRUTURA DA DISSERTAÇÃO	22
2	CONCEITOS PRELIMINARES	24
2.1	PREVISÃO DE GERAÇÃO EÓLICA E SÉRIES TEMPORAIS	24
2.2	REDES NEURAIS	26
2.3	NUMERICAL WEATHER PREDICTION (NWP)	28
3	REVISÃO BIBLIOGRÁFICA	30
4	METODOLOGIA E DESCRIÇÃO DOS MODELOS	34
4.1	METODOLOGIA	34
4.2	MODELOS DE REFERÊNCIA	37
4.2.1	Persistência	37
4.2.2	Rede Neural com Série de Potência (modelo tipo 1)	37
4.3	MODELOS PROPOSTOS	38
4.3.1	Rede Neural com Série de Vento (modelos tipo 3 e 5)	38
4.3.2	Modelos de Previsão com Redes Neurais Utilizando Séries de Potência e Vento Previsto (modelos tipo 2 e 4)	39
4.3.3	Resumo das Características dos Modelos	40
4.4	AVALIAÇÃO DO DESEMPENHO DOS MODELOS	42
5	ESTUDOS DE CASO E RESULTADOS	44
5.1	QUALIDADE DAS SÉRIES TEMPORAIS	44
5.2	ESTUDOS DE CASO	44
5.3	RESULTADOS GERAIS	50
6	CONCLUSÕES	60
7	PERSPECTIVAS DE TRABALHOS FUTUROS	61
	REFERÊNCIAS	62

APÊNDICE A – RESULTADOS DAS SIMULAÇÕES DE VALIDAÇÃO65

1 INTRODUÇÃO

Neste capítulo será feita uma introdução onde será abordada a situação da geração eólica no Brasil, como é feita a operação do Sistema Interligado Nacional (SIN) e as funções do Operador Nacional do Sistema Elétrico (ONS) no contexto de elevada capacidade instalada de geração eólica, bem como os objetivos desse trabalho.

1.1 EVOLUÇÃO DA CAPACIDADE INSTALADA DE GERAÇÃO EÓLICA NO BRASIL

O início da implantação da energia eólica no Brasil, em 1992, ocorreu no Arquipélago de Fernando de Noronha com um aerogerador de 75 kW que foi a primeira a entrar em operação comercial na América do Sul (ONS, 2018). Alguns anos após, houve pouca evolução da geração eólica no país devido à falta de políticas setoriais e, principalmente, devido ao alto custo.


Em 2001, a crise energética foi um fator que estimulou a implantação de novos parques eólicos, com a criação de programas de incentivo, sendo o principal deles o Programa de Incentivo às Fontes Alternativas (PROINFA), que além de incentivar o crescimento das fontes renováveis, abriu caminho para o desenvolvimento da indústria de componentes relacionados.

A partir de 2009, ocorreram diversos leilões com a contratação de energia eólica, sendo o 2º Leilão de Energia de Reserva (LER), o primeiro exclusivo para fonte eólica. Este leilão foi considerado um sucesso com a contratação de 1,8 GW. Em 2010, foi realizado o 3º LER e o Leilão de Fontes Alternativas (LFA) com a contratação de 2 GW de geração eólica. Esses leilões não foram exclusivamente de fonte eólica e provocaram uma competição entre as diversas fontes de energia renovável. Em 2013, foram contratados 4,71 GW de potência, sendo considerado um recorde do setor. Em 2014, foram contratados 2,25 GW e, em 2015, 1,2 GW (ONS, 2018).

Como consequência do sucesso desses leilões, observa-se na figura 1 que a taxa do incremento médio anual da capacidade instalada da geração eólica no Brasil nos últimos cinco anos tem sido superior a 50% e a maior concentração dessa capacidade instalada está localizada nas regiões Nordeste e Sul do Brasil, onde a região Nordeste possui cerca de 81% e a região Sul 19% dessa capacidade (ABEEÓLICA, 2018). Para os próximos anos, ainda é previsto crescimento dessa capacidade instalada, sendo esperados quase 18 GW para o ano de 2023. Um dos fatores que levaram a esse crescimento, sobretudo na região NE, foi o comportamento dos ventos dessa região, com baixa variabilidade e elevado fator de capacidade médio. Os valores

no gráfico da figura 1 representam a potência contratada nos leilões realizados até o momento. Essa capacidade instalada pode sofrer novos incrementos em função da realização de novos leilões.

Figura 1 - Evolução da Capacidade Instalada no Brasil em MW



Fonte: ABEEÓLICA - ASSOCIAÇÃO BRASILEIRA DE ENERGIA EÓLICA. BOLETIM ANUAL DE GERAÇÃO EÓLICA 2017.


1.2 O SIN E O ONS

O Sistema Interligado Nacional (SIN) compreende o conjunto de instalações responsáveis pelo suprimento de energia elétrica em todo o Brasil. O SIN é formado pela Rede de Operação e esta, por sua vez, é composta pela Rede Básica, Rede Complementar e as Usinas despachadas centralizadamente, conforme critérios definidos pela Agência Nacional de Energia Elétrica (Aneel). O SIN é dividido em subsistemas, sendo eles Sul, Sudeste/Centro-Oeste, Norte e Nordeste, e opera de forma interligada através das linhas de interligação, permitindo o intercâmbio de energia, trazendo ganhos de segurança e redução de custos, ao explorar a diversidade dos regimes hidrológicos das bacias e o potencial eólico em diferentes regiões e complementando com as fontes tradicionais (ONS, 2018). A figura 2 mostra a rede básica, que

é composta pelas linhas de transmissão e instalações com nível de tensão acima de 230 kV e algumas instalações com nível de tensão inferior, mas que têm influência na operação do SIN.

O órgão responsável pela coordenação e controle da operação das instalações do SIN e pelo planejamento da operação dos sistemas isolados do país é o Operador Nacional do Sistema Elétrico (ONS), sob fiscalização e regulação da Aneel. O ONS foi instituído como uma pessoa jurídica de direito privado, sob a forma de associação civil sem fins lucrativos, e foi criado em 26 de agosto de 1998, pela Lei nº 9.648, com as alterações introduzidas pela Lei nº 10.848/2004 e regulamentado pelo Decreto nº 5.081/2004 (ONS, 2018).

Figura 2 - Sistema Interligado Nacional.



Fonte: ONS – Operador Nacional do Sistema Elétrico.

Dentre as principais atividades realizadas pelo ONS relacionadas com a operação do sistema em tempo real, estão: o controle de tensão dos barramentos, o controle de carregamento dos equipamentos de transmissão e o controle da geração das usinas despachadas centralizadamente, que fazem parte da rede de operação do SIN. A operação do sistema pode ser definida como o conjunto de pessoas e atividades realizadas de forma ininterrupta, em tempo real nos centros de operação do ONS.

Para a atividade de controle de tensão, o ONS deve monitorar a tensão dos barramentos da rede de operação, mantendo os valores dentro dos limites máximo e mínimo. Caso o valor de tensão esteja fora dos limites, a operação do sistema deve atuar nos recursos disponíveis, manobrando banco de capacitores, reatores, modificando a potência de compensadores e, em último caso, manobrando linhas de transmissão que não sejam necessárias para conduzir a energia em um momento de baixo fluxo e carga (ONS, 2016).

Para a atividade de controle de carregamento, o ONS deve monitorar o fluxo de potência em equipamentos de transmissão, como linhas de transmissão e transformadores, mantendo os valores dos fluxos dentro dos limites máximos. Para realização desse controle, a operação do sistema deve atuar nos recursos de: elevação ou redução da geração nas usinas, gerenciamento da carga, controle de tensão e alteração da configuração do sistema de forma a redistribuir o fluxo (ONS, 2016).

Para a atividade de controle de geração, o ONS deve monitorar a frequência elétrica do SIN dentro dos limites estabelecidos, em torno do valor nominal de 60 Hz. Também, deve monitorar os limites de fluxos das linhas de interligação entre regiões. Para realização desse controle, a operação do sistema deve atuar no despacho das usinas seguindo o programa diário de produção, que é o documento que estabelece a cada 30 minutos os valores programados de geração, fluxos de intercâmbio e previsão de carga para cada região.

Caso haja um desequilíbrio entre carga e geração, provocando um desvio da frequência em relação ao valor de 60 Hz, a operação deve fazer um ajuste na geração. Vale a pena observar que uma elevação da geração, ou redução na carga, provoca uma elevação na exportação de energia em uma região através das linhas de interligação. O inverso também ocorre: se houver uma redução de geração na região, ou elevação da carga, provoca-se uma elevação na importação de energia entre regiões. Nesses casos, devem ser observados os limites das linhas de interligação. Também, pode-se observar que na realização desse controle existe a influência de dois grandes fatores de incerteza. O primeiro são os desvios da previsão de carga que são fortemente influenciados por fatores sociais, econômicos e associados ao tempo, como por exemplo, a ocorrência de tempo quente aumentando o consumo de equipamentos de

refrigeração, eventos como greves, copa do mundo e recessão econômica. O segundo são os desvios de geração eólica, cuja natureza intermitente da fonte de energia primária, impossibilita que os seus valores de geração sejam programados (ONS, 2018).

Adicionalmente, para auxiliar o operador no controle da frequência e do intercâmbio, existe o Controle Automático de Geração (CAG), que é um sistema automático que monitora a frequência e o intercâmbio e que, baseado no desvio dessas grandezas, efetua a correção necessária de geração rapidamente. Na região NE, as correções são feitas em duas usinas hidráulicas localizadas no rio São Francisco e, dessa forma, o operador deve ficar monitorando constantemente a reserva de geração dessas usinas, para em caso de esgotamento recompor a mesma através do despacho em outras usinas, sejam hidráulicas ou térmicas. Quando em condições hidrológicas desfavoráveis, quando não é possível manter essa reserva devido à minimização de geração e da defluência, o CAG permanece desativado. Nesse caso, o controle de frequência fica a cargo de outra região e as variações são compensadas no fluxo das linhas de intercâmbio. Como essas linhas possuem limites operativos, de forma análoga, a margem de operação relativa a esses limites também deve ser recomposta através do despacho de outras usinas na região NE (ONS, 2018).

1.3 PREVISÃO DE GERAÇÃO EÓLICA E A OPERAÇÃO DO SIN

Uma das necessidades da operação do SIN são as previsões de geração eólica. Para isso, faz-se necessário o uso de modelos que geralmente utilizam dados históricos e produzem as previsões para um horizonte estabelecido conforme a necessidade. De acordo com estudos sobre o desempenho dos modelos de previsão de geração eólica, de uma forma geral, quanto menor o horizonte de previsão, melhor será a acurácia da resposta do modelo (COSTA et al., 2008).

Um dos principais fatores da intermitência da fonte eólica são as turbulências, que podem ser causadas por instabilidades dinâmicas (cisalhamento do vento) devido à rugosidade dos terrenos em ambientes complexos e pelas instabilidades térmicas que são causadas pelas diferenças de absorção térmicas das superfícies terrestres (criando fluxos de ar por convecção). Estes são fatores de microescala que são mais difíceis de prever através dos modelos de previsão do tempo que conseguem reproduzir, predominantemente, processos atmosféricos de mesoescala e escala global (GALLEGO, 2013). Essa característica de intermitência pode causar situações indesejadas na operação do SIN, considerando a elevada capacidade instalada da geração eólica. Variações de geração eólica em uma região podem ocasionar variações de

potência nas linhas de transmissão e transformadores, podendo levar à violação dos limites operativos. Essas variações também podem provocar a violação dos limites de tensão nos barramentos do sistema.


Em eventos que envolvem variações abruptas de geração eólica, não há tempo hábil de compensar em outras usinas térmicas ou hidráulicas, de forma que estas são absorvidas pelas usinas ligadas ao CAG em um primeiro momento mantendo o equilíbrio entre carga e geração, ficando, para após o evento, o despacho de outras fontes para recompor a reserva de geração. Dentro desse ponto de vista, é de grande importância para o operador dispor de uma previsão de boa qualidade, para além de recompor a reserva de geração, também aprimorar o despacho de outras fontes para as próximas horas.

1.4 EXEMPLOS DO IMPACTO DA GERAÇÃO EÓLICA NA OPERAÇÃO

A seguir, são apresentados exemplos onde a geração eólica causou impactos na operação do sistema elétrico, ressaltando a importância da previsão de geração.


No dia 11/12/2018, houve uma ação para controle de carregamento. Às 20h05min, inicia-se uma sobrecarga na linha de transmissão (LT) 230 kV Banabuiú / Russas II (BNB/RSD), conforme figura 3. Essa LT tem um limite operativo de aproximadamente 173,8 MW. Após verificar a tendência de elevação no carregamento da linha, a operação em tempo real determinou a redução de 54 MW de geração dos parques eólicos de Aracati II (ARD) e Pitombeiras (PTM), reduzindo o carregamento da LT para abaixo do limite operativo. O diagrama unifilar da figura 4 mostra a região elétrica em questão destacando a LT como uma das possibilidades de escoamento da geração dos parques eólicos. Uma previsão acurada de geração pode evitar que a linha entre em sobrecarga, caso o operador antecipe a redução nos parques eólicos mencionados.

Figura 3 - Fluxo em MW na LT 230 kV Banabuiú / Russas II.



Fonte: Adaptado de ONS (2018)


Figura 4 - Diagrama unifilar da região elétrica do exemplo do dia 11/12/2018.



Fonte: ONS (2018)

No dia 06/08/2017, no período das 06h50min às 07h37min, ocorreu um sobrefrequência no sistema elétrico interligado, cuja causa foi o excesso de geração em um dia de domingo quando a carga geralmente é baixa, conforme figura 5. A ação adotada pela operação do sistema foi a redução de geração eólica em alguns parques eólicos predeterminados no montante de 200 MW, restabelecendo o equilíbrio entre carga e geração. Com isso, a frequência retornou ao valor nominal de 60 Hz. Uma previsão de geração eólica acurada permitiria o despacho em um montante adequado para o atendimento à carga e uma redução dos custos e recursos. Note-se que não seria possível a redução de geração hidráulica devido à operação com geração mínima em função das condições hidrológicas desfavoráveis, bem como não caberia a redução de geração térmica devido às restrições de tempo de parada e partida das usinas e a questões contratuais relacionadas ao custo de geração.

Figura 5 - Frequência do sistema elétrico e geração eólica.



Fonte: Adaptado de ONS (2018)

1.5 OBJETIVOS GERAIS

O objetivo deste trabalho é avaliar modelos de séries temporais de curto prazo para a previsão da potência de saída de centrais eólicas, empregando previsões numéricas do tempo como variáveis exógenas para horizontes de 3 e 6 horas à frente. Para tanto, são utilizadas redes neurais tendo como entradas séries temporais observacionais de potência e estimativas da velocidade do vento oriundas de um modelo geral da circulação atmosférica (General Circulation Model, GCM). Para isto, são utilizados (em modelos de séries temporais de ajuste global) os dados observacionais de 15 centrais eólicas localizadas na região Nordeste do Brasil, e escolhidas em função das características do seu terreno. Realiza-se uma análise de sensibilidade do desempenho dos modelos utilizando informações como altitude, orografia e distância à costa de cada central. Também, verifica-se o comportamento dos modelos em função da arquitetura das redes neurais, do número e do intervalo entre variáveis regressoras de potência e do uso de diferentes pontos da malha do GCM.

1.6 OBJETIVOS ESPECÍFICOS

- Propor modelos de previsão de geração eólica de curto prazo para uso da operação em tempo real do SIN utilizando como variável exógena, a velocidade do vento previsto por um modelo de previsão numérica do tempo (NWP), como método de melhorar a qualidade da previsão.
- Avaliar o desempenho dos modelos propostos em relação a modelos de referência.
- Efetuar um estudo de sensibilidade de características bem definidas da localização de cada parque eólico, como distância à costa, orografia e altitude sobre o desempenho dos modelos propostos.
- Efetuar um estudo de sensibilidade de diferentes arquiteturas de redes neurais, número de variáveis regressoras exógenas e endógenas e o intervalo de tempo entre elas (*time-lag*) no desempenho dos modelos, bem como a relação com as características dos parques eólicos.

1.7 ESTRUTURA DA DISSERTAÇÃO

Os capítulos seguintes apresentam as ideias fundamentais quanto ao procedimento proposto, estando organizados da seguinte forma: o Capítulo 2 apresenta os conceitos

preliminares e as definições de alguns termos empregados neste trabalho com a finalidade de auxiliar a compreensão do leitor no que diz respeito ao resto do documento; no Capítulo 3, é realizada uma revisão bibliográfica sobre a evolução dos modelos de previsão, o uso de técnicas combinando variáveis endógenas e exógenas e o uso de redes neurais. No Capítulo 4, é apresentada a metodologia de avaliação do desempenho e descrição dos modelos propostos. No Capítulo 5, são apresentados os resultados de forma consolidada e uma discussão sobre os mesmos. No Capítulo 6, são apresentadas as conclusões em função dos resultados apresentados e, no Capítulo 7, sugerem-se temas para trabalhos futuros.

2 CONCEITOS PRELIMINARES

Neste capítulo serão abordados os conceitos preliminares necessários à compreensão e ferramentas para o desenvolvimento desse trabalho, que são: previsão de geração eólica e séries temporais, redes neurais e *numerical weather prediction* (NWP).

2.1 PREVISÃO DE GERAÇÃO EÓLICA E SÉRIES TEMPORAIS

A Previsão de geração eólica compreende um conjunto de técnicas direcionadas a fornecer informações a respeito da variação da geração (potência) de um parque eólico. Essa potência pode ser representada por um sinal contínuo (p_t) convertido em uma série temporal discreta $\{p_t\}$, a partir da amostragem do sinal contínuo e posterior cálculo da média móvel a cada intervalo de tempo ou *time-step* (Δt).

Quando se utilizam dados históricos (tempo passado) de séries temporais como entradas (variáveis regressoras) aos modelos, entre cada uma pode ser definido um atraso denominado *time-lag*. Necessariamente, o *time-lag* é um múltiplo do *time-step*, que por sua vez é uma característica da série temporal utilizada, enquanto que o *time-lag* faz parte da estratégia de utilização dos dados da série temporal, pelo modelo de previsão.

Outro conceito importante é o horizonte de previsão, que diz respeito ao tempo futuro para o qual uma variável é estimada em relação ao instante de referência (instante t , que é o instante atual) e pode ser definido como o instante futuro ($t + k$) classificando a previsão da seguinte forma (GALLEGO, 2013):

- Previsão de curtíssimo prazo: para previsões com horizontes entre alguns segundos e poucas horas.
- Previsão de curto prazo: Para horizontes de horas a dias.
- Previsão de médio / longo prazo: Para horizontes de dias a semanas.

Para o escopo deste trabalho, tratam-se apenas as previsões de curto prazo.


Com relação à natureza do modelo, de uma forma geral, as previsões de geração eólica podem ser classificadas pela abordagem estatística ou dinâmica (COSTA et al., 2008).

Os modelos baseados na abordagem dinâmica são fortemente influenciados por informações oriundas de um NWP, que basicamente é um modelo determinístico cujas equações diferenciais (que modelam as leis físicas de conservação) fornecem o estado das

variáveis que descrevem o comportamento da atmosfera, a partir de suas condições iniciais e de contorno (LO et al., 2008)

A abordagem estatística é baseada em uma modelagem de relações empíricas entre variáveis utilizando informações sobre a potência no passado, com vistas a estimar o comportamento futuro dessa mesma variável: $p_{t+k} = f_u(p_t, p_{t-1}, \dots) + \varepsilon_{t+k}$, onde p_i indica o valor da variável p observado no i -ésimo instante de tempo; f_u indica a relação empírica, ε_i indica o erro de previsão. Uma variável estocástica pode ser definida como uma sequência ordenada ou realizações de variáveis aleatórias. Nesse sentido, considera-se aqui a série temporal como apenas uma realização de um processo estocástico ordenado no tempo discreto, estando todo o processo caracterizado por uma função de densidade de probabilidade conjunta, conforme figura 6 (processo estocástico com duas realizações e três variáveis aleatórias). Assume-se a hipótese de um processo estocástico estacionário e ergódico.

Figura 6 - Exemplo de um processo estocástico.



Fonte: Gallego (2013).

De uma forma geral, a previsão de geração eólica consiste em um modelo representado por uma função, conforme equação 1, onde $\hat{p}_{t+k|t}$ corresponde ao valor previsto da variável p_t no horizonte k . Essa função pode ter como entrada: os dados observados oriundos de sistemas de supervisão SCADA, representados por séries temporais de potência; dados de modelos de previsão numérica do tempo (NWP), como por exemplo, previsões de velocidade e direção do vento, temperatura e pressão; e um conjunto de parâmetros Θ , normalmente aproximados através de técnicas de aprendizado ou regressão. (GALLLEGO, 2013)

$$\hat{p}_{t+k|t} = f(SCADA|_t, NWP|_t, \Theta) \quad (1)$$


2.2 REDES NEURAIS

As Redes Neurais Artificiais (RNA) são modelos matemáticos que funcionam de forma semelhante ao cérebro humano, com capacidade de aprendizado através de experiência e de generalização. Um modelo baseado em RNA processa as informações de forma não-linear e paralela e é capaz de executar tarefas de reconhecimento de padrões ou outras aplicações que seriam difíceis de modelar tal como técnicas autorregressivas não-lineares.

A figura 7 mostra um neurônio, que é a unidade básica de processamento de informação de uma rede neural e é constituído pelos seguintes elementos (Haykin, 1994):

- Um conjunto de pesos sinápticos que recebem as informações das entradas um peso sináptico que multiplica o valor de cada entrada.
- Um somador, onde os sinais de entrada ponderados são somados.
- Uma entrada externa de bias, que possui o efeito de aumentar ou diminuir o nível médio do sinal aplicado à função de ativação.
- Função de ativação, que pode limitar ou suavizar as transições do sinal de saída da rede neural.


Figura 7 - Esquema de um neurônio.



Fonte: Gallego (2013)

Algumas funções de ativação podem ser visualizadas na figura 8 como a sigmóide, degrau, linear, tangente hiperbólica e podem ser escolhidas conforme a aplicação da rede. As funções de ativação interferem na limitação da amplitude do sinal de saída do neurônio e se a rede neural é diferenciável ou não, como por exemplo, para as funções sigmoide e degrau respectivamente.


Figura 8 - Funções de ativação.



Fonte: Gallego (2013)

Uma arquitetura comumente usada em problemas de regressão (Haykin, 1994; Marugán et al, 2018) consiste no agrupamento de vários neurônios em camadas de forma que os neurônios de uma dada camada estejam totalmente conectados com os neurônios das camadas vizinhas, conforme figura 9. Dessa forma, a arquitetura fica dividida em camada de entrada (com a quantidade de nós conforme o número de entradas); a camada de saída (tipicamente possui um nó); e as camadas ocultas (entre as camadas de entrada e de saída). Essa arquitetura descrita é chamada de Multilayer Perceptron (MLP).

Figura 9 - MLP (Multilayer Perceptron).



Fonte: Gallego (2013)

2.3 NUMERICAL WEATHER PREDICTION (NWP)


A previsão numérica do tempo é realizada por meio de modelos numéricos que estimam a evolução dos estados da atmosfera resolvendo equações correspondentes a leis físicas de conservação tais como, por exemplo, conservação da massa e da energia. Neste trabalho, o interesse nas informações oriundas de um NWP para a previsão de geração eólica diz respeito à velocidade e direção do vento como variáveis exógenas a serem empregadas como entradas a um modelo estatístico para previsão de séries temporais da potência de saída da central eólica. Entretanto, historicamente, observou-se (Lynch 2008, Aravéquia e Quadro 2003) que os resultados podem ser diferentes dos observados, principalmente devido à falta de dados para as condições iniciais, ou seja, de medidas desse estado da atmosfera em níveis acima da superfície, como também devido a efeitos gravitacionais e de ondas de som que atuam como ruídos e são amplificados no processo de integração da previsão, inutilizando os resultados. Algumas simplificações como aproximação hidrostática e geostrófica, e do fluido barotrópico e incompressível, podem ser feitas eliminando a dependência vertical e ruídos e modos de oscilação que não são importantes do ponto de vista meteorológico. Portanto um modelo operacional pode ser obtido a partir vários sistemas de equações para cada altitude em camadas.

Outro problema é relacionado à solução, pois fazem parte do modelo as equações de Navier-Stokes, cuja a solução analítica é impossível ou improvável sem que sejam introduzidas simplificações que retiram a robustez desses modelos. Por outro lado, é inviável descrever de forma completa as condições iniciais da atmosfera para inicialização do modelo. Por esses motivos são utilizadas técnicas de solução numéricas baseadas em métodos computacionais. Ainda assim o custo computacional para a solução numérica direta é bastante elevado devido ao pequeno time-step requerido, limitando os resultados a domínios espaciais e temporais baixos. Para contornar esse problema, admite-se que as variáveis dos fluidos (como velocidade do vento, por exemplo) se comportem como um processo estocástico permitindo que as equações sejam decompostas em média e flutuações (*ensemble*). Dessa forma para o cálculo da média, o time-step para o processo numérico fica maior, permitindo um maior alcance temporal e espacial. Em contrapartida a parte das flutuações (normalmente associada às turbulências) necessitam serem modeladas para permitir uma aproximação dos resultados (Gallego 2013).

Um esquema simplificado do modelo NWP pode ser visto na figura 10, onde todo o globo terrestre é dividido horizontalmente em pontos de malha e verticalmente em camadas que correspondem a níveis de pressão. Para cada ponto de malha e nível de pressão, as equações do modelo apresentam soluções para cada uma das grandezas atmosféricas de interesse. Alguns

processos físicos, como formação de pequenas nuvens e efeitos da radiação solar, que ocorrem em escala menor que a resolução do modelo não são incluídos explicitamente e passam por um procedimento de parametrização para representar esses processos.

Figura 10 - Esquema de malha e processos parametrizados em um NWP.



Fonte: NOAA (2019).

3 REVISÃO BIBLIOGRÁFICA

De uma forma geral, variações abruptas no gradiente local das séries temporais de vento e potência têm sido tratadas como rampas. Muitas das abordagens de modelos de curto prazo focam no conceito de rampas, que também podem ser vistas como eventos extremos que podem ser causados por fenômenos meteorológicos diversos ou por fenômenos relacionados ao processo de conversão de energia. Nesse sentido, Gallego (2013) apresentou um trabalho direcionado para avaliar vários modelos de previsão de rampas, diferenciando as abordagens estatísticas e físicas e destacando que os horizontes de melhor desempenho (tanto para os modelos puramente estatísticos, até 5 horas, quanto para os modelos puramente físicos, de 5 a 8 horas) são de interesse dos operadores para determinação da reserva a curto prazo. Um dos aspectos abordados foi a busca por uma relação entre os processos meteorológicos de diferentes escalas e a ocorrência de rampas. O trabalho sugere o uso de variáveis exógenas, bem como o uso de modelos combinando as abordagens estatísticas e físicas com o objetivo de otimizar as previsões de geração eólica. Em Gallego et al. (2011), no contexto de curto prazo (previsões de minutos a poucos dias), foi proposto um modelo de chaveamento de regime baseado em redes neurais. Os autores sugerem a inclusão de outras variáveis explicativas (saídas de NWP, medidas locais) pode melhorar a previsão para horizontes maiores.

As metodologias de previsão de rampas costumam focar em horizontes de até 3 time-steps à frente, escalas temporais nas quais os modelos de séries temporais de ajuste global costumam apresentar dificuldade para superar a persistência (Ver seção 4.2.1) (CLEMENTE, 2018). Portanto, esse horizonte de 3 time-steps se situa no limite entre os domínios de aplicação dos modelos de ajuste global e dos modelos de ajuste local (para previsão de rampas).

Desde os anos 80, a previsão de geração eólica vem sendo tratada a partir de duas abordagens principais (COSTA et al., 2008): modelos de previsão de séries temporais (BOSSANYI, 1985) e modelos baseados em previsão numérica do tempo (BAILEY E STEWART, 1987; TROEN E LANDBERG, 1990). Alguns autores concluíram que, para o curto prazo, as séries temporais de potência por si só não trazem informação suficiente para que os modelos de previsão atinjam resultados satisfatórios (BEYER et al, 1994). Portanto, a busca de uma integração entre modelos matemáticos / estatísticos e físicos / meteorológicos, de modo que o modelo final tire proveito da acurácia de modelos baseados em séries temporais e do maior horizonte de previsão dos modelos físicos, também foi uma constatação, para que se consiga melhor capturar os fenômenos locais (COSTA et al, 2008). Nesse sentido, a incorporação de variáveis exógenas (dados NWP, velocidade do vento previsto), além da

variável endógena (potência eólica), a um modelo de previsão, pode ser de duas formas. Pode-se apenas integrar a variável exógena ao modelo de previsão único (forecast integration) ou combinar diferentes modelos que façam a previsão das variáveis exógenas separadamente (forecast combination). A ideia da combinação é melhorar a acurácia de previsão, mantendo as vantagens de cada abordagem. Porém, nem sempre a combinação de modelos apresenta um desempenho superior (JUNG e BROADWATER, 2014; HIBOU e EVGENIOU, 2005).

Sobre a abordagem de forecast integration, Zhao et al. (2012) apresentou um modelo que utiliza dados de vento do modelo global GFS e do modelo regional WRF, corrigidos por um filtro de Kalman e interpolados para a altura do cubo do aerogerador, juntamente com outras variáveis exógenas como direção do vento, pressão, temperatura e umidade, além dos dados de potência originados de um sistema de supervisão, como entrada de uma rede neural para prever a potência de cada aerogerador. Como resultado, uma melhora da acurácia é atribuída ao tratamento dos dados NWP em comparação aos dados brutos.

Em Sideratos e Hatzigiorgiou (2007), é apresentado um modelo baseado em uso de técnicas estatísticas e informações de NWP, onde foi feita uma previsão da potência eólica utilizando uma rede Radial Base Function (RBF) e em seguida uma estimação da qualidade dessa previsão utilizando regras fuzzy. Isso permitiu melhorar o desempenho da previsão com subsequentes aplicações da RBF. Os resultados apresentados mostraram um ganho em torno de 10% sobre a persistência para horizontes de 10 até 48 horas, sendo o modelo aplicável para uso em planejamento de sistemas com elevada capacidade eólica instalada.

De forma semelhante, um modelo que utiliza os dados de NWP, como velocidade e direção do vento, apresentou um melhor resultado do que outro modelo que usou apenas a velocidade do vento. Essa informação do vento foi representada como um número complexo e foi utilizada como entrada de uma rede neural MLP com 3 camadas para, em seguida, ser feita a conversão para potência eólica prevista de forma determinística a partir da curva de potência (KITAJIMA e YASUNO, 2010)

Seguindo a abordagem forecast combination, uma previsão de geração eólica final foi feita através de uma combinação linear adaptativa de previsões intermediárias, através de pesos atribuídos para cada modelo, em função do desempenho de previsão. Para a combinação, foram considerados nove modelos de séries temporais variando os seus parâmetros. Essa combinação proposta mostrou melhor performance que as previsões individuais de cada modelo (SANCHEZ, 2006).

Em De Giorgi (2011), foi feita uma comparação entre um modelo puramente estatístico (adotado como referência) de séries temporais baseado em redes neurais recorrentes (do tipo

Elman networks) e diversos modelos utilizando variáveis exógenas oriundas de NWP como velocidade do vento, pressão, temperatura e umidade relativa. De uma forma geral, os dados de NWP e os dados observacionais de potência entram em redes de Elman independentes e as saídas das redes de Elman entram em uma rede neural tipo MLP tendo como saída a potência eólica prevista em horizontes de 1 a 24 horas. Também, foram feitos testes utilizando decomposição em Wavelet. Os modelos que utilizaram técnicas de combinação obtiveram uma melhora considerável no desempenho em relação a um modelo utilizando uma rede neural simples.

Foi verificada uma recente tendência no uso de modelos híbridos como forma de superar o desempenho de modelos simples, que aplicam apenas um método. O uso de redes neurais artificiais (RNA) como métodos de combinação de diferentes modelos e integração de variáveis exógenas vem sendo frequentemente observado (MA et al, 2017; MARUGÁN et al, 2018).

Peng et al. (2016) apresentaram uma abordagem de previsão de geração eólica de curto prazo utilizando informações de previsão numérica do tempo (NWP). A partir da análise estatística da densidade de probabilidade do erro produzido pela previsão feita por redes neurais artificiais (RNA) e por Support Vector Machine (SVM), é feita uma estimativa e correção do erro do modelo. O erro é avaliado em duas componentes, uma contínua e outra de flutuação. O desempenho dos modelos foi avaliado comparando os resultados sem a correção do erro. Foi obtida melhora de até 0,99% no RMSE.

Em Ma et al. (2017) foi apresentado um algoritmo híbrido para previsão de geração eólica de curto prazo, baseado em redes neurais artificiais (RNA) e uma evolução da lógica fuzzy chamada generalized dynamic fuzzy neural network (GDFNN) onde a estrutura da rede neural é incrementada dinamicamente durante a fase de aprendizado. Os resultados apresentaram um melhor desempenho sobre os modelos de referência.

Em Zameer et al. (2017) foi utilizado um ensemble inteligente de redes neurais artificiais (RNA) através de uma série de preditores escolhidos através de programação genética. Esta técnica permite uma modelagem efetiva das relações entre características meteorológicas verificadas e a variável alvo de potência eólica, através do desenvolvimento de um espaço decisório não-linear. Os estudos comparativos relataram melhora sobre modelos anteriores.

Em Higashiyama (2018) foi feita previsão de geração utilizando Redes Neurais Artificiais (RNA) convolucionais, em uma técnica de extração de características relevantes de um modelo NWP regional (WRF) nas escalas espaciais e temporais, permitindo a redução das dimensões com foco no local da usina. Em uma segunda etapa, foi feita a previsão de potência,

agregando dados de geração verificados e melhorando a acurácia em curto prazo. Foi verificado que houve ganho de performance de previsão em horizontes de até 20 horas.

Shao et al. (2018) apresentou um método de previsão de geração eólica de curto prazo baseado em seleção de características Inf-FS (infinite feature selection) e redes neurais (RNA). No primeiro passo, o modelo emprega o quociente Lipschitz para estimar o time-lag entre os dados históricos de potência e velocidade do vento. Em seguida, é aplicado o Inf-FS para classificar e selecionar as características que tenham impacto significativo na acurácia da previsão. Com essas características definidas, é aplicado um aprendizado baseado em RNA. Os resultados confirmaram um desempenho superior aos modelos existentes.

A revisão bibliográfica aqui apresentada permite concluir que o amplo uso das redes neurais se deve à sua habilidade para capturar a relação não-linear envolvida na estimação de valores futuros na série de potência. Portanto, neste trabalho adotam-se as redes neurais como modelo preditivo. A revisão também deixa em evidência a melhora obtida com a integração de previsões numéricas do tempo (como variáveis exógenas) em um modelo de previsão de séries temporais. Contudo, percebe-se uma carência de informação sobre a sensibilidade dos modelos em relação a, por exemplo: característica do terreno onde se localiza o parque eólico; arquitetura da rede neural com relação ao número de neurônios; configuração do vetor de variáveis regressoras com relação ao número de variáveis endógenas e o time-lag entre elas; o número de pontos de malha do NWP utilizados como variáveis exógenas. Portanto, este trabalho busca contribuir no sentido de mitigar essa carência de informação.

4 METODOLOGIA E DESCRIÇÃO DOS MODELOS


Neste capítulo será apresentada a metodologia adotada, origem e forma de tratamento dos dados utilizados nas simulações e validações, tipos de modelos adotados, detalhamento do processo de simulação e validação dos modelos e método de avaliação do desempenho dos mesmos.

4.1 METODOLOGIA

Neste trabalho, foram utilizadas séries temporais de potência como variáveis regressoras endógenas que representam a geração de parques eólicos selecionados de acordo com as características da sua localização (complexidade orográfica, distância à costa e altitude). Por sua vez, os dados de velocidade de vento previstos foram utilizados como variáveis exógenas. O período utilizado nas séries para as simulações foi de 27/07/2015 a 31/01/2018.

Os dados de potência foram obtidos da base de dados histórica do ONS e os nomes dos parques eólicos e suas potências nominais foram omitidos por questões de sigilo. Assim, esses dados foram normalizados pela potência nominal de cada parque. Ao todo, foram considerados 15 parques denominados de G1 a G15. No mapa da figura 11, estão as localizações aproximadas. As características de cada parque eólico, como localização aproximada, orografia e altitude, são apresentadas na tabela 1.

Figura 11 - Mapa com os parques eólicos considerados no estudo



Fonte: Projeto High Performance Computing for Energy.

Tabela 1 - Características dos parques eólicos

Parque	Latitude	Longitude	Altitude (m)		Orografia	Localização
G1	-5,0	-36,0	130	Baixa	Simples	Litoral
G2	-14,0	-42,5	1000	Alta	Complexa	Interior
G3	-12,2	-42,3	1200	Alta	Complexa	Interior
G4	-2,9	-39,9	22	Baixa	Simples	Litoral
G5	-7,5	-40,7	770	Média	Complexa	Interior
G6	-3,3	-39,2	72	Baixa	Simples	Litoral
G7	-9,0	-38,1	770	Média	Complexa	Interior
G8	-5,3	-35,9	200	Baixa	Simples	Litoral
G9	-10,6	-40,6	900	Alta	Complexa	Interior
G10	-8,9	-36,7	800	Média	Complexa	Interior
G11	-5,5	-35,4	77	Baixa	Simples	Litoral
G12	-9,8	-41,1	700	Média	Complexa	Interior
G13	-4,5	-37,7	25	Baixa	Simples	Litoral
G14	-6,0	-36,5	687	Média	Complexa	Interior
G15	-11,0	-42,6	859	Média	Complexa	Interior


Fonte: Projeto High Performance Computing for Energy.

A seleção dos parques eólicos em função das suas características foi feita no âmbito do projeto High Performance Computing for Energy Project (HPC4E), que foi um trabalho de pesquisa e desenvolvimento orientado para computação de alto desempenho com início em 2015 e conclusão em 2018 e formado por um consórcio europeu e um consórcio brasileiro, com a participação do Centro de Energias Renováveis (CER) da UFPE e do ONS como parceiro observador. Nesse projeto, foram desenvolvidas novas abordagens de previsão de geração eólica de curto prazo e em tempo real e este trabalho contribui nesse sentido (HPC4E, 2018).

Os dados de velocidade do vento previsto são oriundos do modelo GFS, que é um modelo NWP de cobertura global produzido pelo NCEP, que disponibiliza diversas variáveis atmosféricas como temperatura, velocidade do vento, pressão, umidade entre outras. Esses dados são calculados para todo o globo terrestre e têm resolução de 0,5 grau de latitude e longitude para cada ponto de malha. O uso dessas informações dependerá da variante de modelo proposta neste trabalho, podendo ser utilizada a velocidade do vento de apenas um ponto de malha (mais próximo da coordenada do parque eólico) ou as velocidades dos quatro pontos de malha próximos da localização do parque, conforme figura 12. Realizou-se uma análise preliminar de sensibilidade com o intuito de verificar o nível vertical de pressão que proporciona os melhores resultados para cada central eólica individualmente. Neste trabalho,

os modelos foram, portanto, alimentados com dados do GCM relativos ao melhor nível no caso de cada central.

Figura 12 - Diagrama dos pontos de malha do GFS e da posição da central eólica (Gn).



Fonte: O Autor (2018).

O modelo GFS emite previsões nos horários 00UTC, 06UTC, 12UTC e 18UTC diariamente, ou seja, com lançamentos a cada 6 horas. A cada lançamento, são liberadas as previsões para diversos horizontes com *time-step* de 3 horas, sendo utilizados neste trabalho os horizontes de 3 e 6 horas. Adicionalmente, foi necessário fazer uma sincronização entre os dados do GFS que estão referenciados a UTC-0, com os dados de potência do histórico do ONS que possuem uma referência de fuso horário em UTC-3 no horário normal ou UTC-2 quando o Brasil está em horário de verão.

As simulações foram feitas no cluster denominado Papalégua do Centro de Energias Renováveis (CER) da Universidade Federal de Pernambuco (UFPE), que possui um headnode (que roda o sistema operacional) com 32 cores AMD e 64 GB de RAM e 10 nós de processamento (cada um com 32 cores e 32 GB de RAM). A conexão entre os nós é feita a partir de uma rede infiniband de alta velocidade. O cluster possui 4 TB de armazenamento para o sistema (headnode) e mais 124 TB de armazenamento em geral.

Essas simulações foram divididas em duas etapas. A primeira, de treinamento, foi feita com os 2/3 iniciais das séries temporais, onde os parâmetros das redes neurais foram ajustados de forma iterativa pelo algoritmo Levenberg-Marquardt baseado em aprendizagem supervisionada.

A segunda etapa, de validação, utilizou o 1/3 restante da série, onde foram aplicadas as entradas (potência e/ou velocidade do vento previsto) nas redes neurais já calibradas e feitas as comparações dos resultados de saída com os dados observados. Os resultados são apresentados no capítulo 5.

O ambiente de simulação foi desenvolvido utilizando o Octave. Adotaram-se 200 inicializações e 1000 épocas para a etapa de treinamento. A arquitetura utilizada foi a MLP com uma camada oculta de 3, 4 ou 5 neurônios, de acordo com o caso de estudo, com funções de ativação do tipo tangente hiperbólica. A camada de saída possui apenas um neurônio e função de ativação do tipo linear.

4.2 MODELOS DE REFERÊNCIA

Os modelos de referência são apresentados com o objetivo de obter uma referência de desempenho para possibilitar uma avaliação dos modelos propostos.

4.2.1 Persistência

O modelo de persistência é comumente utilizado como um modelo de referência. O valor previsto para o instante futuro da geração eólica é o mesmo valor verificado no instante atual, conforme equação 2.

$$\hat{p}_{t+k} = p_t \quad (2)$$


Este modelo, embora de formulação simples, possui uma boa acurácia para previsão de curtíssimo prazo, devido à característica quasi-estacionária da atmosfera, cujas variações são lentas (NIELSEN et al., 1998). Portanto, espera-se que os modelos propostos superem o desempenho de um modelo simples como o de persistência, de forma que seja válido um esforço computacional adicional empregado em um modelo mais sofisticado.

4.2.2 Rede Neural com Série de Potência (modelo tipo 1)

Para servir como referência adicional, foi considerada uma rede neural que utiliza como entrada apenas as variáveis regressoras de potência, com $n+1$ dados observacionais e um atraso (*time-lag*) de d entre cada uma dessas entradas. Dessa forma, o modelo pode prever a potência

gerada no horizonte $t+k$. O treinamento é feito de forma a minimizar uma função do erro global sobre toda a série temporal. A figura 13 exemplifica o modelo.

Figura 13 - Diagrama do modelo de Rede Neural Artificial tipo '1'



Fonte: O Autor (2018).

4.3 MODELOS PROPOSTOS

Os modelos propostos serão utilizados no estudo de sensibilidade descrito na metodologia e seu desempenho será comparado com os modelos de referência.

4.3.1 Rede Neural com Série de Vento (modelos tipo 3 e 5)

Essa rede neural utiliza como entradas apenas as séries de velocidade de vento previsto do modelo GFS obtendo como saída as potências de geração eólica prevista. Portanto, com relação ao instante de referência t , para obter a previsão de geração no instante $t+k$, a rede utiliza a velocidade de vento prevista em $t+k$, conforme o diagrama da figura 14. Um dos objetivos desse modelo é avaliar o grau de contribuição da velocidade do vento sobre a melhora da previsão de geração.


Figura 14 - Diagrama do modelo de Rede Neural Artificial tipo '3'



Fonte: O Autor (2018).

Como uma variante, foi proposto um modelo que utiliza a velocidade do vento dos quatro pontos de malha do GFS mais próximos à posição do parque eólico. De forma semelhante, esse modelo permite avaliar a contribuição das previsões adicionais de vento sobre a melhora da previsão de geração. A figura 15 mostra o diagrama desse modelo.

Figura 15 - Diagrama do modelo de Rede Neural Artificial tipo '5'




Fonte: O Autor (2018).

4.3.2 Modelos de Previsão com Redes Neurais Utilizando Séries de Potência e Vento Previsto (modelos tipo 2 e 4)

O objetivo desse modelo é efetuar uma previsão de geração eólica no horizonte $t+k$, utilizando como entradas $n+1$ variáveis regressoras de potência com um *time-lag* d e a velocidade do vento previsto para o mesmo horizonte $t+k$, de apenas um ponto de malha do GFS. A figura 16 mostra o diagrama deste modelo.


Figura 16 - Diagrama do modelo de Rede Neural Artificial tipo '2'



Fonte: O Autor (2018).

De forma análoga, foi proposto um modelo com o objetivo de efetuar uma previsão de geração eólica para o horizonte $t+k$, utilizando como entradas $n+1$ variáveis regressoras de potência com *time-lag* d e a velocidade do vento previsto para o mesmo horizonte $t+k$, de quatro pontos de malha do GFS. A figura 17 mostra o diagrama desse modelo.

Figura 17 - Diagrama do modelo de Rede Neural Artificial tipo '4'



Fonte: O Autor (2018).

4.3.3 Resumo das Características dos Modelos

Neste trabalho, os modelos avaliados são classificados em tipo e subtipo, dependendo de suas características. O tipo se classifica de acordo com a utilização de dados de potência e velocidade do vento, conforme descrito anteriormente e mostrado na tabela 2.

Tabela 2 - Tipos de modelo de acordo com a entrada

Tipo	Variáveis regressoras na entrada
1 ●	Apenas potência
2 ●	Potência + vento (1 ponto de malha)
3 ●	Apenas vento (1 ponto de malha)
4 ●	Potência + Vento (4 pontos de malha)
5 ●	Apenas vento (4 pontos de malha)

Fonte: O Autor (2018).

Com relação ao subtipo, o mesmo será descrito através de um código mnemônico composto por 3 partes, sendo que a primeira representa o número de neurônios da RNA na camada oculta, a segunda representa o número de variáveis regressoras de potência e a terceira representa o time-lag em horas entre essas entradas na rede neural.

Tabela 3 - Subtipos de modelos

Subtipos	Arquitetura da RNA
n4	1 camada com 4 neurônios
n5	1 camada com 5 neurônios
n6	1 camada com 6 neurônios
Subtipos	Número de variáveis regressoras (potência)
e2	2 entradas
e3	3 entradas
e4	4 entradas
Subtipos	time-lag
h1	1 hora
h2	2 horas
h3	3 horas
h6	6 horas


Fonte: O Autor (2018).

Como exemplo, um modelo do subtipo n5-e3-h6 significa que a rede neural possui 5 neurônios, 3 variáveis regressoras de potência e com um time-lag de 6 horas, extraídas da série temporal que possui um time-step de 1 hora.

Na figura 18, pode-se visualizar toda a metodologia descrita. Na primeira etapa, é feito o treinamento das redes neurais, onde são apresentadas as séries das variáveis endógenas e exógenas nas entradas e apenas a variável endógena na saída de forma que o aprendizado resulte em um conjunto de parâmetros internos ajustados (rede neural calibrada) de forma que se tenha uma função que relacione os dados de entrada com a saída. Na segunda etapa, são apresentadas, às redes neurais já calibradas, as variáveis endógenas e exógenas na entrada para que se obtenha

a previsão de potência. Esse valor é comparado com a potência da série histórica e é calculado o erro de previsão (RMSD) e traçados os diagramas de Taylor.

Figura 18 - Fluxograma dos processos de treinamento e validação dos modelos.



Fonte: O Autor (2018).

4.4 AVALIAÇÃO DO DESEMPENHO DOS MODELOS


Um dos métodos de avaliar o desempenho de modelos é a comparação com o modelo de persistência. A avaliação comparativa é feita através da melhora sobre a persistência ou *improvement of persistence* (IOP) e é calculada através da equação 3 (MADSEN et al, 2005).

$$IOP = \frac{RMSD_{persistência} - RMSD_{modelo}}{RMSD_{persistência}} \quad (3)$$

Uma outra forma de avaliação foi feita através de um diagrama de Taylor para cada parque eólico e cada horizonte de previsão. Este diagrama é adotado como uma ferramenta para comparação entre modelos e permite a avaliação da capacidade do mesmo em reproduzir: i. a amplitude da variação das observações (avaliada por meio do desvio padrão de saída do modelo); ii. estrutura de frequência / fase das observações (avaliada por meio de correlação com as observações). Além disso, o desempenho geral do modelo é avaliado por meio do erro médio quadrático centrado ou *centered pattern root mean square difference* (RMSD) de acordo

com a equação 4, onde y e $\hat{y}$ representam observações e saídas do modelo respectivamente a barra acima da variável indica a média aritmética. A relação entre os estatísticos apresentados no diagrama tem como fundamento geométrico a lei dos cossenos, conforme equação 5 (TAYLOR, 2001). Visualmente, essa comparação pode ser feita pela proximidade do ponto de teste com o ponto de referência, quanto mais próximo maior a correlação, menor o RMSD e mais próximo do desvio padrão, conforme figura 19.

Figura 19 - Diagrama de Taylor



Fonte: Taylor (2001).

$$RMSD = \sqrt{\frac{1}{N} \sum_{i=1}^N [(y_i - \bar{y}) - (\hat{y}_i - \bar{\hat{y}})]^2} \quad (4)$$

$$E'^2 = \sigma_r^2 + \sigma_t^2 + 2\sigma_r\sigma_t\rho \quad (5)$$

5 ESTUDOS DE CASO E RESULTADOS

Neste capítulo são apresentados os resultados obtidos na etapa de validação dos modelos, conforme descrito na metodologia. O desempenho de cada modelo é avaliado em função das características dos próprios modelos e da localização dos parques eólicos.

5.1 QUALIDADE DAS SÉRIES TEMPORAIS

As séries temporais dos 15 parques eólicos passaram por testes de garantia de qualidade cujo objetivo foi o de avaliar eventuais anomalias ocorridas durante o processo de aquisição e registro dos dados observacionais (MORAES, 2015). Os testes, organizados em sequência, avaliaram aspectos tais como, por exemplo, a quantidade de dados ausentes (dados esperados e que não foram registrados pelo *datalogger*), a magnitude do sinal observado, a magnitude da derivada local de primeira ordem e as sequências de valores repetidos. Após os testes foram obtidos os percentuais de dados considerados de boa qualidade de acordo com a tabela 4.

Tabela 4 - Percentual de dados considerados de boa qualidade.

Usina	Dados bons (%)
G1	94,5
G2	96,0
G3	93,0
G4	93,6
G5	91,9
G6	88,4
G7	71,5
G8	99,0
G9	72,7
G10	84,7
G11	98,4
G12	96,8
G13	84,1
G14	72,3
G15	62,1

Fonte: O Autor(2018).

5.2 ESTUDOS DE CASO

As figuras e tabelas a seguir apresentam os resultados da simulação durante a fase de validação (após o treinamento das redes neurais, de acordo com a figura 18). Nos diagramas de Taylor e gráficos de pontos, as legendas de cores identificam os tipos de modelo (de acordo

com a tabela 2) conforme o uso dos dados de potência observados como variáveis regressoras endógenas e das previsões da velocidade do vento como variáveis regressoras exógenas.

Em geral, os resultados para os parques eólicos podem ser classificados em dois grandes grupos: aqueles parques para os quais os modelos tipo 2 e 4 obtiveram o melhor desempenho (aqui representados pelo parque eólico G1); aqueles parques para os quais o modelo tipo 1 obteve o melhor desempenho (aqui representados pelo parque eólico G6). O grupo mais numeroso é aquele aqui representado pelo parque eólico G1, onde o modelo tipo 4 apresenta em geral melhores resultados que o tipo 2 tanto em relação à capacidade de reproduzir a estrutura de frequência e fase do sinal observado (apresentando alta correlação) quanto em relação à capacidade de reproduzir a amplitude de variação do sinal observado (apresentando um desvio padrão próximo ao dos dados observacionais).


Nos diagramas de Taylor da figura 20 são apresentados os resultados para a simulação de G1 nos horizontes de 3 e 6 horas adiante onde se pode observar que o modelo tipo 4 apresenta o melhor resultado, seguido pelos modelos tipo 2 e tipo 1. Já, o modelo tipo 5 apresenta melhor resultado que o tipo 3, de forma análoga aos resultados dos tipos 4 e 2, respectivamente, já que utilizam as mesmas variáveis exógenas como entrada. A figura 21 apresenta o desempenho em termos do IOP em função dos subtipos (conforme tabela 3). Para ambos os horizontes, o modelo tipo 4 obteve o maior IOP, seguido pelo tipo 2 e 1. Foram observados picos no IOP para os subtipos e4-h6 que possuem 4 variáveis regressoras com 6 horas de *time-lag*. Para estes subtipos, os tipos 1, 2 e 4 apresentaram picos de magnitude semelhante.

No sentido de buscar explicar a ocorrência dos picos na IOP acima citados, deve-se ter em mente que, durante o treinamento, as redes neurais ajustam seus parâmetros para se aproximar da função (ou conjunto de funções) que relaciona a saída do modelo (previsão de geração eólica) com suas entradas (séries temporais observacionais de potência e previsões de velocidade do vento). Se o comportamento dos dados de entrada for consistente com o dos dados de saída, o modelo fará uma boa aproximação. Nesse caso, os parâmetros da RNA serão ajustados para dar pesos sinápticos maiores às entradas com comportamento mais consistente. Caso contrário, pesos menores são atribuídos para as entradas que não são consistentes com o comportamento da saída. Esse comportamento foi observado através dos parâmetros da RNA após a fase de treinamento.

Os picos de IOP observados nos subtipos e4-h6 podem estar associados ao ciclo diário de vento, sendo atribuídos maiores pesos sinápticos às entradas deste subtipo. Nos modelos tipos 2 e 4, devido ao comportamento da velocidade do vento previsto ser mais consistente com os dados de saída, foram verificados maiores pesos sinápticos atribuídos às entradas,


melhorando a aproximação entre entrada e saída da rede e, consequentemente, obtendo-se um maior valor do IOP.

Figura 20 - Diagramas de Taylor para G1



Fonte: O Autor (2018).


Figura 21 - IOP em função dos subtipos para G1



Fonte: O Autor (2018).

A Figura 22 mostra a variabilidade dos modelos em termos do desvio padrão dos resultados em função dos subtipos. O modelo tipo 4 apresenta um desvio padrão mais próximo daquele dos dados observados, seguido pelo tipo 2 e tipo 1. Observou-se, nas simulações dos 15 parques eólicos, que a variabilidade das previsões do modelo diminui à medida que o horizonte de previsão aumenta tal como se espera. Tal diminuição do desvio padrão com o aumento do horizonte de previsão nota-se particularmente no caso do tipo 1. Observou-se que a inclusão de uma ou mais variáveis exógenas (tipo 2 ou 4) proporciona um desvio padrão mais próximo daquele dos dados observados. O uso de variáveis endógenas com características do subtipo e4-h6 também pode contribuir da mesma forma, como observado nos picos de desvio padrão do tipo 1.

Figura 22 - Desvio padrão em função dos subtipos para G1



Fonte: O Autor (2018).


Os diagramas de Taylor da figura 23 mostram a simulação de G6 para horizontes de 3h e 6h onde se pode observar que os modelos tipos 1, 2 e 4 apresentam coeficientes de correlação semelhantes e os tipos 2 e 4 não conseguem superar o desempenho da persistência em termos do RMSD. Os tipos 3 e 5 apresentam o pior desempenho, pois seus pontos no diagrama são os mais distantes dos dados observados. Além disso, é possível observar uma alta correlação do modelo de persistência com os dados observados em ambos os horizontes (fazendo a comparação com G1), mostrando que a série temporal de G6 é mais persistente que a de G1, o

que torna mais difícil que um modelo de previsão supere a persistência para obter um IOP mais alto e um menor RMSD. A Figura 24 apresenta o desempenho do modelo em termos do IOP em função dos subtipos. Para ambos os horizontes, o tipo 1 apresenta melhor desempenho que os modelos tipo 4 e tipo 2, ratificando o que foi verificado no diagrama de Taylor.

A Figura 25 mostra o desvio padrão dos resultados em função dos subtipos. No horizonte de 3 horas, o tipo 4 superestima o desvio padrão dos dados observados. No horizonte de 6 horas, o desvio padrão do tipo 4 fica próximo ao dos dados observados. Não foram observados os picos associados ao subtipo e4-h6. O fato desta série temporal ser mais persistente pode explicar a ausência desses picos, pois isso pode estar associado a uma menor variação da potência relacionada ao ciclo diário do vento. O aumento do desvio padrão observado nos modelos tipo 4 pode ser uma correção de amplitude de variação induzida pelo uso da velocidade do vento prevista nos modelos, uma vez que o resultado se aproxima do desvio padrão dos dados observados.


Como discutido anteriormente sobre o treinamento das redes neurais, foi verificado que, em G6 os pesos sinápticos atribuídos às entradas de velocidade do vento foram baixos, indicando que esses dados não puderam refletir bem o comportamento dos dados observados e melhorar o resultado da previsão, como aconteceu com G1. Reforçando essa conclusão, tem-se o baixo desempenho dos tipos 3 e 5 observado no diagrama de Taylor, já que estes modelos usam apenas velocidade do vento previsto como entradas. Este pode ser um dos motivos para o baixo IOP obtido pelos tipos 2 e 4.

Figura 23 - Diagramas de Taylor para G6




Fonte: O Autor (2018).

Figura 24 - IOP em função dos subtipos para G6



Fonte: O Autor (2018).

Figura 25 - Desvio padrão em função dos subtipos para G6



Fonte: O Autor (2018).

5.3 RESULTADOS GERAIS

Os resultados apresentados nesta seção se referem às simulações realizadas com todos os parques eólicos. Os diagramas de Taylor e os gráficos de IOP e desvio padrão das simulações individualizadas estão no Apêndice.

As tabelas 6 e 7 apresentam um resumo dos resultados para todos os parques eólicos e os horizontes de 3 h e 6 h, com o melhor tipo, além dos tipos e subtipos que figuram entre os 20 melhores, tudo em termos do IOP. Também, apresenta-se o nível de correção do desvio padrão dos tipos 2 e 4 com referência aos dados observados. Os parques estão agrupados conforme as características mencionadas anteriormente na tabela 1.

As principais constatações são:

- O modelo tipo 4 aparece com o melhor resultado na maioria dos parques eólicos. Também, aparece com a maior ocorrência entre os 20 melhores tipos na maioria dos parques eólicos. O fato do tipo 4 ocupar a melhor posição nos dois rankings anteriormente mencionados faz, deste tipo, o melhor modelo de forma geral. Segundo

tais critérios, o tipo 2 aparece em segundo lugar. Apenas para o G6 e G13, o melhor resultado foi alcançado pelo tipo 1;

- Para o IOP no horizonte de 3 h, o modelo tipo 4 obteve valores de 21,94% a 52,99% e o tipo 2 obteve valores de 19,12% a 36,11%. Para o horizonte de 6 h, o tipo 4 obteve valores de 33,01% a 70,11% e o tipo 2 obteve valores de 45,85% a 55,99%;
- O subtipo e4-h6 aparece com o melhor resultado na maioria dos parques;
- O desvio padrão dos tipos 2 e 4 foi melhor para o horizonte de 6 horas.

Portanto, observando todos os resultados, é possível confirmar que a introdução de variáveis exógenas nos modelos traz uma melhora no desempenho de previsão e do desvio padrão, principalmente para o horizonte de 6 h e com o uso de 4 pontos de malha. O comportamento cíclico diário do vento pode ser evidenciado pelo número de casos em que aparece o subtipo e4-h6 com melhor desempenho, inclusive em G6 e G13, casos nos quais o melhor modelo foi o tipo 1.

Tabela 5 - Resumo dos Resultados para o Horizonte de 3 h.

3h	Desempenho (IOP)					Correção do desvio padrão		Altitude	Orografia	Localização	Observação
	Melhor			Maior ocorrência entre os 20 melhores		Tipo 2	Tipo 4				
	Tipo	Subtipo	IOP(%)	Tipo	Subtipo						
G4	2	n5-e4-h6	23,49	4	e4-h6	baixo	alto	Baixa	Simples	Litoral	Litoral do Ceará
G6	1	n4-e4-h6	6,07	1	-	baixo	baixo	Baixa	Simples	Litoral	Litoral do Ceará
G13	1	n6-e4-h6	16,23	1	e4-h6	alto	alto	Baixa	Simples	Litoral	Litoral do Ceará
G1	4	n5-e4-h6	30,43	4	e4-h6	baixo	alto	Baixa	Simples	Litoral	Litoral do Rio Grande do Norte
G8	2	n4-e4-h6	19,12	4	e4-h6	baixo	baixo	Baixa	Simples	Litoral	Litoral do Rio Grande do Norte
G11	2	n4-e4-h6	36,11	4	e4-h6	baixo	baixo	Baixa	Simples	Litoral	Litoral do Rio Grande do Norte
G2	4	n5-e2-h6	21,94	4	-	alto	alto	Alta	Complexa	Interior	Interior da Bahia
G3	4	n4-e4-h3	44,10	4	-	baixo	alto	Alta	Complexa	Interior	Interior da Bahia
G9	2	n4-e3-h3	22,11	2	-	baixo	baixo	Alta	Complexa	Interior	Interior da Bahia
G5	4	n4-e4-h6	29,43	2	e4-h6	alto	alto	Média	Complexa	Interior	Interior do Piauí
G7	4	n6-e4-h3	41,34	4	-	alto	alto	Média	Complexa	Interior	Interior de Pernambuco
G10	4	n5-e4-h6	26,13	2	e4-h6	alto	alto	Média	Complexa	Interior	Interior de Pernambuco
G12	4	n6-e4-h6	30,42	4	h6	baixo	baixo	Média	Complexa	Interior	Interior da Bahia
G14	4	n4-e4-h6	30,19	4	-	alto	alto	Média	Complexa	Interior	Interior do Rio Grande do Norte
G15	4	n5-e2-h2	52,99	4	-	baixo	baixo	Média	Complexa	Interior	Interior da Bahia

Fonte: O Autor (2018).

Tabela 6 - Resumo dos Resultados para o Horizonte de 6 h.

6h	Desempenho (IOP)					Correção do desvio padrão		Altitude	Orografia	Localização	Observação
	Melhor			Maior ocorrência entre os 20 melhores		Tipo 2	Tipo 4				
	Tipo	Subtipo	IOP(%)	Tipo	Subtipo						
G4	2	n6-e4-h6	55,99	4	e4-h6	baixo	alto	Baixa	Simples	Litoral	Litoral do Ceará
G6	1	n4-e4-h6	13,75	1	e4-h6	baixo	alto	Baixa	Simples	Litoral	Litoral do Ceará
G13	1	n4-e4-h6	30,46	2	e4-h6	alto	alto	Baixa	Simples	Litoral	Litoral do Ceará
G1	4	n6-e4-h6	49,03	4	e4-h6	baixo	alto	Baixa	Simples	Litoral	Litoral do Rio Grande do Norte
G8	4	n5-e4-h6	41,26	4	e4-h6	baixo	alto	Baixa	Simples	Litoral	Litoral do Rio Grande do Norte
G11	2	n4-e4-h6	51,84	2	e4-h6	alto	alto	Baixa	Simples	Litoral	Litoral do Rio Grande do Norte
G2	4	n6-e3-h6	37,45	4	-	alto	alto	Alta	Complexa	Interior	Interior da Bahia
G3	4	n5-e4-h3	54,00	4	-	alto	alto	Alta	Complexa	Interior	Interior da Bahia
G9	4	n5-e4-h3	48,82	2	-	alto	alto	Alta	Complexa	Interior	Interior da Bahia
G5	4	n4-e4-h6	43,55	4	h6	alto	alto	Média	Complexa	Interior	Interior do Piauí
G7	4	n5-e3-h1	49,78	4	-	alto	alto	Média	Complexa	Interior	Interior de Pernambuco
G10	4	n5-e4-h6	33,01	4	e4-h6	alto	alto	Média	Complexa	Interior	Interior de Pernambuco
G12	4	n4-e4-h6	46,57	4	-	alto	alto	Média	Complexa	Interior	Interior da Bahia
G14	2	n5-e4-h6	45,85	2	-	alto	alto	Média	Complexa	Interior	Interior do Rio Grande do Norte
G15	4	n4-e3-h3	70,11	2	h3	alto	alto	Média	Complexa	Interior	Interior da Bahia

Fonte: O Autor (2018).

A seguir, são apresentados resultados em forma de gráficos de box-whisker para os horizontes de 3 h e 6 h, com o resultado do desempenho dos modelos de todos os parques eólicos expressos em termos do RMSD e em função das características da localização. Vale ressaltar que os diagramas estão dispostos da seguinte maneira: à esquerda, agrupam-se os tipos 1, 2 e 4, que fazem uso de dados de potência; à direita agrupam-se os tipos 3 e 5, que não fazem uso dos dados de potência.

As figuras 26 e 27 mostram o RMSD para cada tipo de modelo em função da altitude dos parques eólicos. Para o horizonte de 3 h, pode-se observar que:

- Os modelos tipo 2 e 4 apresentaram um RMSD menor do que o tipo 1 para todas as condições de altitude, especialmente para média e alta altitude;
- Os modelos tipo 1, 2 e 4 apresentaram uma tendência de aumento do RMSD com o aumento da altitude, sendo menor essa tendência nos tipos 2 e 4;
- Os modelos tipo 3 e 5 apresentaram uma tendência de redução do RMSD com o aumento da altitude.


Por sua vez, para o horizonte de 6 h, observa-se que:

- Os modelos tipo 2 e 4 apresentaram um RMSD menor do que o tipo 1 para todas as condições de altitude, especialmente para média e alta altitude;

- Apenas o modelo tipo 1 apresentou uma tendência de aumento do RMSD com o aumento da altitude;
- Os modelos tipo 2 e 4 e tipo 3 e 5 apresentaram uma tendência de redução do RMSD com o aumento da altitude.


Portanto, com base nos resultados obtidos, foi observado que o modelo tipo 1 de séries temporais que utiliza apenas variáveis endógenas apresentou um maior erro de previsão em médias e altas altitudes. A adição de variáveis exógenas aos modelos trouxe uma melhora na qualidade da previsão devido ao menor valor do RMSD para os modelos tipo 2 e 4. No entanto observou-se uma tendência de redução do RMSD com a altitude nos modelos tipo 3 e 5 que apenas utilizam a variável exógena. Tal comportamento merece um estudo mais aprofundado que venha a permitir um maior desacoplamento entre o efeito da altitude e o efeito da orografia. A base de dados com o qual se desenvolveu este trabalho está composta por parques eólicos correspondentes a três classes de altitudes e duas classes de complexidades orográficas, não havendo nenhuma central localizada, por exemplo, em zona de orografia simples e altitude de média ou elevada.

Figura 26 - RMSD em função da altitude para o horizonte de 3 h.



Fonte: O Autor(2018).

Figura 27 - RMSD em função da altitude para o horizonte de 6 h.



Fonte: O Autor (2018).

As Figuras 28 e 29 mostram o RMSD para cada modelo em função da orografia e da localização dos parques eólicos. Observa-se, para o horizonte de 3 h, o seguinte:


- Os modelos tipo 2 e 4 apresentaram valores menores de RMSD que o tipo 1 para orografia complexa (interior) e valores de RMSD próximos ao do tipo 1 para orografia simples (litoral);
- A tendência dos modelos tipo 1, 2 e 4 foi a de um aumento do RMSD à medida em que a orografia se torna mais complexa, sendo essa tendência menos acentuada para os tipos 2 e 4;
- Porém, a tendência dos modelos tipo 3 e 5 é a de uma redução do RMSD à medida em que a orografia se torna mais complexa.

Por sua vez, para o horizonte de 6 h, observa-se que:

- Além das mesmas observações para o horizonte de 3 h, a tendência dos modelos tipo 2 e 4 é de uma leve redução do RMSD à medida em que a orografia se torna mais complexa.


De forma geral, o comportamento da potência se mostra menos previsível em terrenos com orografia complexa (GIEBEL et al, 2006). Uma elevação na intensidade da turbulência associada à ocorrência de zonas de desprendimento da camada limite e, eventualmente, brisas de vale-montanha (ventos anabáticos/catabáticos) tornam menos persistente o comportamento do vento dificultando, portanto, a previsão em séries temporais de potência eólica. Nos estudos de casos aqui apresentados, a inclusão de variáveis exógenas trouxe uma melhora na qualidade da previsão, observada no menor RMSD para os modelos tipo 2 e 4. Esta melhora também pôde ser verificada com a tendência de redução do RMSD com a altitude nos modelos tipo 3 e 5 que apenas utilizaram a variável exógena.

Figura 28 - RMSD em função da complexidade orográfica para horizonte de 3 h.



Fonte: O Autor (2018).


Figura 29 - RMSD em função da complexidade orográfica para horizonte de 6 h.



Fonte: O Autor (2018).


As figuras 30 e 31 mostram a avaliação do RMSD para cada modelo em função do subtipo. Menores valores do RMSD foram observados quando utilizado o subtipo e4-h6. Também, foi observada uma pequena redução no RMSD nos subtipos e3-h6, e4-h2 e e4-h3, principalmente no modelo tipo 1, apesar dos melhores resultados gerais dos tipos 2 e 4. Isso pode ter sido causado pelo ciclo diário de aquecimento e resfriamento das superfícies terrestre e oceânica. Como tal ciclo corresponde a cada 24 horas, os modelos que usam uma combinação de um número de variáveis regressoras endógenas e um time-lag que sejam múltiplos desse período podem capturar melhor esse comportamento através das séries temporais.

Figura 30 - RMSD em função dos Subtipos para horizonte de 3 h.



Fonte: O Autor (2018).

Figura 31 - RMSD em função dos Subtipos para horizonte de 6 h.




Fonte: O Autor (2018).

As figuras 32 e 33 mostram o RMSD para cada modelo em função dos números de neurônios na camada oculta das RNAs. Avaliando apenas o número de neurônios, não foi observada diferença no desempenho dos modelos. O número de neurônios utilizados nas


simulações foi suficiente para capturar os fenômenos não-lineares presentes nas séries temporais (tanto de variáveis endógenas como de variáveis exógenas), já que foram observadas reduções significativas do RMSD em função de alguns subtipos.

Figura 32 - RMSD em função dos números de Neurônios para horizonte de 3 h.



Fonte: O Autor (2018).

Figura 33 - RMSD em função dos números de Neurônios para horizonte de 6 h.



Fonte: O Autor (2018).

Portanto, pode-se observar que os resultados indicam um desempenho superior na previsão de geração eólica efetuada pelo modelo tipo 4 na maioria dos casos estudados, com destaque para os casos em que, comparativamente, o modelo de referência tipo 1 obteve um desempenho inferior, como para os parques eólicos localizados em elevada altitude, orografia complexa e no interior. Em situações nas quais as usinas estão submetidas a um regime de vento mais complexo e que exige maior capacidade de reconhecimento desses padrões, a inclusão de uma variável exógena trouxe, na maior parte dos casos, uma redução no erro de previsão.

Paralelamente, a forma de uso das variáveis regressoras endógenas também interfere no desempenho dos modelos. Como observado nos resultados, o uso do subtipo e4-h6 torna o modelo mais hábil para reconhecer os regimes de vento aos quais o parque eólico está submetido.

6 CONCLUSÕES

Este trabalho proporcionou um importante avanço à disciplina de Previsão Eólica, particularmente no que diz respeito a modelagem de séries temporais. Demonstrou-se, claramente, o potencial da previsão numérica do vento (como variável exógena) no processo de estimação da potência de saída das centrais eólicas em horizontes de previsão de 3 h e 6 h, escalas temporais que despertam particular interesse nos operadores dos sistemas elétricos. Em tais horizontes, ocorre a maior parte das ações operativas sobre o sistema elétrico.

Conforme observado nos resultados, a inclusão de uma variável exógena de um único ponto de malha do GCM provocou, na maior parte das centrais eólicas estudadas, uma redução do RMSD e consequente aumento do IOP. Ainda maior foi o desempenho dos modelos com a inclusão de 4 pontos de malha do GCM. Esta última configuração, denominada tipo 4 (com variáveis endógenas e os 4 pontos da malha do GCM como variáveis exógenas), apresentou os melhores resultados para o caso particular do subtipo e4-h6, em que o vetor de variáveis endógenas está formado por 4 variáveis com time-lag (entre variáveis) de 6 horas.

Com relação à análise de sensibilidade sobre as características de localização dos parques eólicos, foi observado, do ponto de vista puramente estatístico, que o uso da variável exógena trouxe um melhor desempenho dos modelos em localidades com altitude média ou elevada e orografia complexa. Destaca-se o bom desempenho dos modelos tipo 2 e 4, superando o tipo 1. Para os modelos tipo 3 e 5 (que utilizam apenas a variável exógena), foi evidenciada uma tendência de redução do erro de previsão, ratificando o comportamento observado nos modelos tipo 2 e 4.

Também, foi feita uma análise em relação ao número de neurônios utilizados nas redes neurais tipo MLP. Para os casos em questão, verificou-se a pouca influência dessa característica sobre o desempenho dos modelos.

Espera-se que os resultados deste trabalho venham a contribuir efetivamente para o aumento do grau de confiança nas tomadas de decisão durante a operação em tempo real do sistema elétrico.

7 PERSPECTIVAS DE TRABALHOS FUTUROS

Como proposta de trabalhos futuros, tem-se o seguinte:

- Avaliar o comportamento dos modelos com a integração de outras variáveis exógenas, bem como para diferentes níveis verticais de pressão do modelo GFS;
- Buscar uma relação entre a melhora obtida com a integração de dados de vento e a incidência de rampas através de uma ou mais técnicas de identificação de rampas nas séries de potência;
- Efetuar uma avaliação espectral no domínio da frequência nas séries temporais para identificar componentes compatíveis com o bom desempenho observado com o uso de 4 variáveis regressoras de potência com time-lag de 6 horas;
- Buscar demonstrar as tendências apresentadas nos diagramas de box-whisker, onde se verificou um menor erro de previsão em determinadas características de localização dos parques eólicos.

Vale enfatizar que o enfoque deste trabalho foi essencialmente estatístico, tendo como um dos objetivos principais a avaliação do desempenho dos modelos preditivos em função da inclusão das previsões numéricas de vento como variáveis exógenas. Portanto, caberá buscar apoio na física por trás dos processos atmosféricos de maneira a que se possa explicar detalhadamente os comportamentos observados em vários dos gráficos apresentados nesse trabalho.

REFERÊNCIAS

ABEEÓLICA, ASSOCIAÇÃO BRASILEIRA DE ENERGIA EÓLICA. Energia Eólica – O Setor. Disponível em: <http://www.abeeolica.org.br/energia-eolica-o-setor/>. Acessado em abril de 2018.

ABEEÓLICA, ASSOCIAÇÃO BRASILEIRA DE ENERGIA EÓLICA. BOLETIM ANUAL DE GERAÇÃO EÓLICA 2017. Disponível em: <http://abeeolica.org.br/wp-content/uploads/2018/04/Boletim-Anual-de-Geracao-2017.pdf>. Acessado em dezembro de 2018.

ARAVÉQUIA, José Antonio; DE QUADRO, Mário Francisco Leal. Aspectos gerais da previsão numérica de tempo e clima. Cachoeira Paulista: CPTEC, 2003.

BAILEY, B.; STEWART, R. Wind forecasting for wind power stations. Proceedings of the ninth British wind, 1987.

BEYER, H. G. et al. Short-term prediction of wind speed and power output of a wind turbine with neural networks. In: Proceedings of the EWEC. 1994. p. 349-352.

CLEMENTE, J. O. Previsão de rampas em séries temporais de potência de saída de centrais eólicas. Dissertação de Mestrado. Universidade Federal de Pernambuco, 2018.

COSTA, Alexandre et al. A review on the young history of the wind power short-term prediction. Renewable and Sustainable Energy Reviews, v. 12, n. 6, p. 1725-1744, 2008.

DE GIORGI, Maria Grazia; FICARELLA, Antonio; TARANTINO, Marco. Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods. Energy, v. 36, n. 7, p. 3968-3978, 2011.

GALLEGO, C. Statistical models for short-term wind power ramp forecasting. Doctoral Thesis. Universidad Politécnica de Madrid, 2013.

GALLEGO, C.; COSTA, A.; CUERVA, A. Improving short-term forecasting during ramp events by means of regime-switching artificial neural networks. Advances in Science and Research, v. 6, n. 1, p. 55-58, 2011.

GIEBEL, G. et al. Shortterm forecasting using advanced physical modelling-the results of the anemos project. In: Proceedings of the European Wind Energy Conference. 2006.

HAYKIN, Simon. Neural networks: a comprehensive foundation. Prentice Hall PTR, 1994.

HIBON, Michele; EVGENIOU, Theodoros. To combine or not to combine: selecting among forecasts and their combinations. International Journal of Forecasting, v. 21, n. 1, p. 15-24, 2005.

HIGASHIYAMA, Kazutoshi; FUJIMOTO, Yu; HAYASHI, Yasuhiro. Feature Extraction of NWP Data for Wind Power Forecasting Using 3D-Convolutional Neural Networks. Energy Procedia, v. 155, p. 350-358, 2018.

HPC4E, High Performance Computing for Energy (<https://hpc4e.eu/the-project/work-plan/wp4>). Acessado em dezembro/2018

JUNG, Jaesung; BROADWATER, Robert P. Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews*, v. 31, p. 762-777, 2014.

KITAJIMA, Takahiro; YASUNO, Takashi. Output prediction of wind power generation system using complex-valued neural network. In: *SICE Annual Conference 2010, Proceedings of. IEEE*, 2010. p. 3610-3613.

LO, Jeff Chun-Fung; YANG, Zong-Liang; PIELKE, Roger A. Assessment of three dynamical climate downscaling methods using the Weather Research and Forecasting (WRF) model. *Journal of Geophysical Research: Atmospheres*, v. 113, n. D9, 2008.

LYNCH, Peter. The origins of computer weather prediction and climate modeling. *Journal of Computational Physics*, v. 227, n. 7, p. 3431-3444, 2008.

MA, Xuejiao; JIN, Yu; DONG, Qingli. A generalized dynamic fuzzy neural network based on singular spectrum analysis optimized by brain storm optimization for short-term wind speed forecasting. *Applied Soft Computing*, v. 54, p. 296-312, 2017.

MADSEN, Henrik et al. Standardizing the performance evaluation of short-term wind power prediction models. *Wind Engineering*, v. 29, n. 6, p. 475-489, 2005.

MARUGÁN, Alberto Pliego et al. A survey of artificial neural network in wind energy systems. *Applied energy*, v. 228, p. 1822-1836, 2018.

MME - MINISTÉRIO DE MINAS E ENERGIA. Energia Eólica no Brasil e no Mundo – Ano de Referência 2016. Disponível em <http://www.mme.gov.br/documents/10584/3580498/15+-+Energia+E%C3%B3lica+-+Brasil+e+Mundo+-+ano+ref.+2016+%28PDF%29+-+NOVO/f63a15ea-9d2c-4d27-9400-5d7c3fd97b22?version%20=%201.4>. Acessado em novembro / 2018

MORAES, C. F. W. C. B. Objective quality assurance procedure to assess local surface wind observational data in the coast of Rio Grande do Norte. MSc Thesis (in Portuguese). Universidade Federal de Pernambuco (UFPE), 2015.

NIELSEN, Torben Skov et al. A new reference for wind power forecasting. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, v. 1, n. 1, p. 29-34, 1998.

NOAA, National Oceanic and Atmospheric Administration, Climate Model, Disponível em https://celebrating200years.noaa.gov/breakthroughs/climate_model/. Acessado em janeiro de 2019.

ONS, Operador Nacional do Sistema Elétrico. Disponível em <<http://www.ons.org.br>>. Acessado em abril de 2018.

ONS, Procedimentos de Rede. Submódulo 10.7 – Controle da Transmissão, rev. 2016.12

ONS, Procedimentos de Rede. Submódulo 10.6 – Controle da Geração, rev. 2018.08

PENG, Xiaosheng et al. A very short-term wind power forecasting approach based on numerical weather prediction and error correction method. In: *Electricity Distribution (CICED), 2016 China International Conference on. IEEE*, 2016. p. 1-4.

SANCHEZ, Ismael. Short-term prediction of wind energy production. *International Journal of Forecasting*, v. 22, n. 1, p. 43-56, 2006.

SIDERATOS, George; HATZIARGYRIOU, Nikos D. An advanced statistical method for wind power forecasting. *IEEE Transactions on power systems*, v. 22, n. 1, p. 258-265, 2007.

SHAO, Haijian; DENG, Xing; JIANG, Yingtao. A novel deep learning approach for short-term wind power forecasting based on infinite feature selection and recurrent neural network. *Journal of Renewable and Sustainable Energy*, v. 10, n. 4, p. 043303, 2018.

TAYLOR, Karl E. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, v. 106, n. D7, p. 7183-7192, 2001.

TROEN, I.; LANDBERG, L. Short term prediction of local wind conditions. In: 1990 European Community Wind Energy Conference. HS Stephens and Associates, 1990. p. 76-78.

ZAMEER, Aneela et al. Intelligent and robust prediction of short term wind power using genetic programming based ensemble of neural networks. *Energy conversion and management*, v. 134, p. 361-372, 2017.


ZHAO, Pan et al. Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China. *Renewable Energy*, v. 43, p. 234-241, 2012.

APÊNDICE A – RESULTADOS DAS SIMULAÇÕES DE VALIDAÇÃO

Aqui são apresentados todos os resultados das simulações de validação de G1 a G15, com os respectivos diagramas de Taylor, gráficos da melhora sobre a persistência e desvio padrão para cada um dos horizontes de 3h e 6h.


Simulação com G1

Figura 34 - Diagrama de Taylor para G1




Fonte: O Autor (2018).

Figura 35 - Melhora sobre a persistência para G1



Fonte: O Autor (2018).


Figura 36 - Desvio Padrão para G1



Fonte: O Autor (2018).


Simulação com G2

Figura 37 - Diagrama de Taylor para G2




Fonte: O Autor (2018).

Figura 38 - Melhora sobre a persistência para G2



Fonte: O Autor (2018).


Figura 39 - Desvio Padrão para G2



Fonte: O Autor (2018).


Simulação com G3

Figura 40 - Diagrama de Taylor para G3




Fonte: O Autor (2018).

Figura 41 - Melhora sobre a persistência para G3



Fonte: O Autor (2018).


Figura 42 - Desvio Padrão para G3



Fonte: O Autor (2018).


Simulação com G4

Figura 43 - Diagrama de Taylor para G4




Fonte: O Autor (2018).

Figura 44 - Melhora sobre a persistência para G4



Fonte: O Autor (2018).


Figura 45 - Desvio Padrão para G4



Fonte: O Autor (2018).


Simulação com G5

Figura 46 - Diagrama de Taylor para G5




Fonte: O Autor (2018).

Figura 47 - Melhora sobre a persistência para G5



Fonte: O Autor (2018).


Figura 48 - Desvio Padrão para G5



Fonte: O Autor (2018).

Simulação com G6

Figura 49 - Diagrama de Taylor para G6



Fonte: O Autor (2018).

Figura 50 - Melhora sobre a persistência para G6






Figura 51 - Desvio Padrão para G6



Fonte: O Autor (2018).


Simulação com G7

Figura 52 - Diagrama de Taylor para G7




Fonte: O Autor (2018).

Figura 53 - Melhora sobre a persistência para G7



Fonte: O Autor (2018).


Figura 54 - Desvio Padrão para G7



Fonte: O Autor (2018).


Simulação com G8

Figura 55 - Diagrama de Taylor para G8




Fonte: O Autor (2018).

Figura 56 - Melhora sobre a persistência para G8



Fonte: O Autor (2018).


Figura 57 - Desvio Padrão para G8



Fonte: O Autor (2018).


Simulação com G9

Figura 58 - Diagrama de Taylor para G9




Fonte: O Autor (2018).

Figura 59 - Melhora sobre a persistência para G9



Fonte: O Autor (2018).


Figura 60 - Desvio Padrão para G9



Fonte: O Autor (2018).


Simulação com G10

Figura 61 - Diagrama de Taylor para G10




Fonte: O Autor (2018).

Figura 62 - Melhora sobre a persistência para G10



Fonte: O Autor (2018).


Figura 63 - Desvio Padrão para G10



Fonte: O Autor (2018).


Simulação com G11

Figura 64 - Diagrama de Taylor para G11




Fonte: O Autor (2018).

Figura 65 - Melhora sobre a persistência para G11



Fonte: O Autor (2018).


Figura 66 - Desvio Padrão para G11



Fonte: O Autor (2018).


Simulação com G12

Figura 67 - Diagrama de Taylor para G12




Fonte: O Autor (2018).

Figura 68 - Melhora sobre a persistência para G12



Fonte: O Autor (2018).


Figura 69 - Desvio Padrão para G12



Fonte: O Autor (2018).


Simulação com G13

Figura 70 - Diagrama de Taylor para G13




Fonte: O Autor (2018).

Figura 71 - Melhora sobre a persistência para G13



Fonte: O Autor (2018).


Figura 72 - Desvio Padrão para G13



Fonte: O Autor (2018).


Simulação com G14

Figura 73 - Diagrama de Taylor para G14




Fonte: O Autor (2018).

Figura 74 - Melhora sobre a persistência para G14



Fonte: O Autor (2018).


Figura 75 - Desvio Padrão para G14



Fonte: O Autor (2018).

Simulação com G15


Figura 76 - Diagrama de Taylor para G15



O Autor(2018).


Fonte:

Figura 77 - Melhora sobre a persistência para G15



Fonte: O Autor (2018).

Figura 78 - Desvio Padrão para G15



Fonte: O Autor (2018).