



**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIAS E GEOCIÊNCIAS
DEPARTAMENTO DE ENERGIA NUCLEAR**

**COMISSÃO NACIONAL DE ENERGIA NUCLEAR
CENTRO REGIONAL DE CIÊNCIAS NUCLEARES DO NORDESTE**

**PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS ENERGÉTICAS E
NUCLEARES**

JULLYA DE OLIVEIRA CLEMENTE

**PREVISÃO DE RAMPAS EM SÉRIES TEMPORAIS DE POTÊNCIA
DE SAÍDA DE CENTRAIS EÓLICAS**

Recife
2018

JULLYA DE OLIVEIRA CLEMENTE

**PREVISÃO DE RAMPAS EM SÉRIES TEMPORAIS DE POTÊNCIA DE SAÍDA DE
CENTRAIS EÓLICAS**

Dissertação submetida ao Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares para obtenção do título de Mestre em Ciências.

Área de Concentração: Fontes Renováveis de Energia.

Orientador: Profa. Dra. Olga de Castro Vilela

Coorientador: Prof. Dr. Alexandre Carlos Araújo da Costa

Recife

2018

Catálogo na fonte
Bibliotecário Carlos Moura, CRB-4 / 1502

C626p

Clemente, Jullya de Oliveira.

Previsão de rampas em séries temporais de potência de saída de centrais eólicas. / Jullya de Oliveira Clemente. - Recife, 2018.
125 f. : il., figs., gráfs., tabs.

Orientadora: Profa. Dra. Olga de Castro Vilela.

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

Dissertação (mestrado) – Universidade Federal de Pernambuco.
CTG. Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares, 2018.

Inclui referências e apêndices.

1. Engenharia nuclear. 2. Energia eólica. 3. Previsão de rampas.
4. Previsão em tempo real. 5. Redes neurais. 6. Redes Bayesianas.
I. Vilela, Olga de Castro, orientadora. II. Costa, Alexandre Carlos Araújo da, coorientador. III. Título.

CDD 621.48 (22. ed.)

UFPE
BDEN/2019-04

JULLYA DE OLIVEIRA CLEMENTE

**PREVISÃO DE RAMPAS EM SÉRIES TEMPORAIS DE POTÊNCIA DE SAÍDA DE
CENTRAIS EÓLICAS**

Dissertação submetida ao Programa de
Pós-Graduação em Tecnologias
Energéticas e Nucleares para obtenção do
título de Mestre em Ciências.

Aprovada em: 23/08/2018.

BANCA EXAMINADORA

Prof. Dr. Fernando Roberto de Andrade Lima (Examinador Externo)
CNEN/CRCN-NE

Prof. Dr. André Maciel Netto (Examinador Interno)
UFPE/DEN

Prof. Dr. Tsang Ing Ren (Examinador Interno)
UFPE/CIN

AGRADECIMENTOS

Agradeço a todas as pessoas que contribuíram direta e indiretamente para a execução deste trabalho de mestrado;

Agradeço aos meus orientadores, Profa. Dra. Olga Vilela e Prof. Dr. Alexandre Costa, não só pela oportunidade e por todo o conhecimento adquirido durante esse tempo, mas também pela paciência e compreensão frente aos problemas enfrentados;

Agradeço aos colegas do Centro de Energias Renováveis (CER) que me auxiliaram durante toda a pesquisa;

Agradeço ao Programa de Pós-graduação em Tecnologias Energéticas e Nucleares (PROTEN) pela oportunidade;

Agradeço ao Operador Nacional do Sistema Elétrico (ONS) pelos dados fornecidos;

Agradeço às seguintes entidades cujo apoio financeiro se deu durante a realização da Graduação e/ou Mestrado: à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio por meio de bolsa de estudo, à Rede Nacional de Ensino e Pesquisa (RNP) pelo apoio no âmbito do projeto High Performance Computing for Energy (HPC4E, <https://hpc4e.eu/the-project/work-plan/wp4>) e ao Centro de Tecnologia do Gás e Energias Renováveis (CTGAS-ER/PETROBRAS) pelo apoio no âmbito do projeto Aprimoramento de Aerogerador de 2 MW para Adequação às Condições Eólicas Brasileiras (Programa de P&D Tecnológico do Setor de Energia Elétrica da Agência Nacional de Energia Elétrica - ANEEL).

RESUMO

A grande penetração da energia eólica dentro da matriz elétrica brasileira torna o controle do sistema elétrico ainda mais complexo, principalmente em eventos de rampas, os quais podem ocasionar, de forma muito rápida, elevadas variações de potência. Faz-se, então, necessária a utilização de técnicas de previsão especializadas para este tipo de regime. Neste sentido, o trabalho em questão busca desenvolver modelos capazes de realizar previsões acuradas, a curtíssimo prazo, de rampas em séries de potência de saída de centrais eólicas, de forma a auxiliar o controle do sistema elétrico brasileiro. Para tanto, dados observacionais, com escala temporal de 10 minutos, de 8 centrais eólicas localizadas no Nordeste brasileiro são empregados em modelos de ajuste global ou local, baseados em Redes Neurais Artificiais. A identificação do tipo de regime é realizada através de um mecanismo baseado no gradiente local do sinal, o qual, em alguns casos, é aliado à inferência estatística proveniente de uma Rede Bayesiana, possibilitando a introdução de informações com respeito a centrais eólicas localizadas a barlavento do local de interesse. De acordo com os resultados obtidos, verifica-se que, de maneira geral, os modelos desenvolvidos conseguem realizar previsões satisfatórias, superando a persistência em todos os horizontes. Verificou-se, ainda, que um modelo de ajuste global é suficiente para entregar previsões acuradas no terceiro horizonte, tornando dispensável o treinamento de modelos locais neste horizonte. Faz-se necessário, porém, um estudo aprofundado quanto ao comportamento e às características das rampas, com atenção especial às rampas de descida.

Palavras-chave: Energia Eólica. Previsão de rampas. Previsão em tempo real. Redes Neurais. Redes Bayesianas.

ABSTRACT

The large penetration of wind energy into the Brazilian electricity matrix makes the control of the electric system even more complex, especially in ramp events, which can cause large and fast variations in power. Hence, it is necessary to use specialized forecasting techniques for this type of regime. In this sense, the work in question aims the development of models capable of accurately predict, in very short term, ramps in series of power output from wind power plants, in order to help control the Brazilian electricity system. For this, observational data, with a 10-minute time-step, from 8 wind farms located in the Brazilian Northeast Region are used in global or local adjustment models, based on Artificial Neural Networks. The regime identification is performed through a mechanism based on the local signal gradient, which in some cases is allied to statistical inference from a Bayesian network, allowing the introduction of information regarding wind farms located in the windward of the place of interest. According to the obtained results, it is verified that, in a general way, the developed models can carry out satisfactory predictions, overcoming the persistence in all horizons. It was also verified that a global adjustment model is sufficient to deliver accurate forecasts in the third horizon, making local models unnecessary for this horizon. However, an in-depth study of the behavior and characteristics of ramps is necessary, with particular attention to ramp-down events.

Keywords: Wind Energy. Ramp forecasting. Real-time forecasting. Artificial Neural Networks. Bayesian Networks.

LISTA DE FIGURAS

Figura 1 - Modelo de neurônio artificial	20
Figura 2 - Exemplos de função de ativação	21
Figura 3 - Estrutura de uma rede neural do tipo MLP	22
Figura 4 - Exemplo de estrutura de rede bayesiana	23
Figura 5 - Mapa contendo as centrais eólicas utilizadas.....	35
Figura 6 - Diagrama representando o modelo B1	40
Figura 7- Diagrama representando o modelo B2	41
Figura 8 - Diagrama representando o modelo B3	41
Figura 9 - Diagrama representando o modelo B4	42
Figura 10 - Diagrama representando o modelo B5.....	43
Figura 11 – Exemplo de séries de: (a) potência; (b) gradiente local.....	45
Figura 12 – Exemplos de diagramas de caixa utilizados por IR para determinação do limiar.....	45
Figura 13 - Diagrama representando o modelo L1	46
Figura 14 - Diagrama representando o modelo L2	47
Figura 15 - Diagrama representando o modelo L3	48
Figura 16 - Diagrama representando o modelo L4	49
Figura 17 - Diagrama representando o modelo L5	50
Figura 18 - Diagrama representando o modelo L6	51
Figura 19 - Diagrama representando os modelos L7 e L8	52
Figura 20 - Rosa dos ventos a partir dos dados de direção observados em G6	55
Figura 21 – Correlação entre as centrais G4 e G6 para diferentes <i>delays</i>	56
Figura 22 – Taxa de rampa-rampa entre G4 e G6 para diferentes <i>delays</i>	56
Figura 23 – Rosa dos ventos a partir dos dados de direção observados em G1	58
Figura 24 – Correlação entre as centrais G13 e G1 para diferentes <i>delays</i>	58
Figura 25 - Taxa de rampa-rampa entre G13 e G1 para diferentes <i>delays</i>	59
Figura 26 – Rosa dos ventos a partir dos dados de direção observados em G8	60
Figura 27 – Rosa dos ventos a partir dos dados de direção observados em G11	60
Figura 28 – Correlação entre as centrais G8 e G11 para diferentes <i>delays</i>	61
Figura 29 – Taxa de rampa-rampa entre G8 e G11 para diferentes <i>delays</i>	61
Figura 30 – Rosa dos ventos a partir dos dados de direção observados em G10	62
Figura 31 - Correlação entre as centrais G7 e G10 para diferentes <i>delays</i>	63

Figura 32 - Taxa de rampa-rampa entre G7 e G10 para diferentes <i>delays</i>	63
Figura 33 - Melhora sobre a persistência sobre as rampas de subida de G4.....	65
Figura 34 - Melhora sobre a persistência sobre as rampas de subida de G13.....	67
Figura 35 - Melhora sobre a persistência sobre as rampas de subida de G8.....	67
Figura 36 - Melhora sobre a persistência sobre as rampas de subida de G7.....	68
Figura 37 – Diagrama de Taylor sobre as rampas de subida de G4.....	70
Figura 38 - Diagrama de Taylor sobre as rampas de subida de G13.....	71
Figura 39 - Diagrama de Taylor sobre as rampas de subida de G8.....	72
Figura 40 – Diagrama de Taylor sobre as rampas de subida de G7.....	73
Figura 41 - Melhora sobre a persistência sobre as rampas de descida de G4.....	76
Figura 42 - Melhora sobre a persistência sobre as rampas de descida de G13.....	76
Figura 43 - Melhora sobre a persistência sobre as rampas de descida de G8.....	77
Figura 44 - Melhora sobre a persistência sobre as rampas de descida de G7.....	77
Figura 45 – Diagrama de Taylor sobre as rampas de descida de G4.....	79
Figura 46 - Diagrama de Taylor sobre as rampas de descida de G13.....	80
Figura 47 - Diagrama de Taylor sobre as rampas de descida de G8.....	81
Figura 48 – Diagrama de Taylor sobre as rampas de descida de G7.....	82
Figura 49 – Série temporal de G4.....	95
Figura 50 – Série temporal de G6.....	96
Figura 51 – Série temporal de G13.....	97
Figura 52 – Série temporal de G1.....	98
Figura 53 – Série temporal de G8.....	99
Figura 54 – Série temporal de G11.....	100
Figura 55 – Série temporal de G7.....	101
Figura 56 – Série temporal e G10.....	102
Figura 57 – Evolução do <i>bias</i> sobre as rampas de subida de G4.....	104
Figura 58 – Evolução do <i>bias</i> sobre as rampas de descida de G4.....	104
Figura 59 – Evolução do <i>bias</i> sobre as rampas de subida de G13.....	105
Figura 60 – Evolução do <i>bias</i> sobre as rampas de descida de G13.....	105
Figura 61 – Evolução do <i>bias</i> sobre as rampas de subida de G8.....	106
Figura 62 – Evolução do <i>bias</i> sobre as rampas de descida de G8.....	106
Figura 63 – Evolução do <i>bias</i> sobre as rampas de subida de G7.....	107
Figura 64 – Evolução do <i>bias</i> sobre as rampas de descida de G7.....	107
Figura 65 - Diagrama de Taylor sobre as rampas de subida de G4.....	109

Figura 66 - Diagrama de Taylor sobre as rampas de descida de G4	110
Figura 67 - Diagrama de Taylor sobre as rampas de subida de G13	111
Figura 68 - Diagrama de Taylor sobre as rampas de descida de G13	112
Figura 69 - Diagrama de Taylor sobre as rampas de subida de G8	113
Figura 70 - Diagrama de Taylor sobre as rampas de descida de G8	114
Figura 71 - Diagrama de Taylor sobre as rampas de subida de G7	115
Figura 72 - Diagrama de Taylor sobre as rampas de descida de G7	116

LISTA DE ABREVIATURAS E SIGLAS

BN	Rede Bayesiana (<i>Bayesian Network</i>)
BoM	Agência de Meteorologia Australiana (<i>Australian Bureau of Meteorology</i>)
FA	Acurácia de Previsão (<i>Forecast Accuracy</i>)
FN	Falso Negativo (<i>False Negative</i>)
FP	Falso Positivo (<i>False Positive</i>)
HPC4E	Projeto <i>High Performance Computing for Energy</i>
IoP	Melhora sobre a Persistência (<i>Improvement over Persistence</i>)
IR	Mecanismo Identificador de Regime
MLP	Perceptron Multicamadas (<i>Multilayer Perceptron</i>)
MPCE	Erro Médio de Classificação Percentual (<i>Mean Percentage Classification Error</i>)
MSE	Erro Médio Quadrático (<i>Mean Squared Error</i>)
NN	Rede Neural (<i>Neural Network</i>)
NWP	Previsão Numérica do Tempo (<i>Numerical Weather Prediction</i>)
ONS	Operador Nacional do Sistema Elétrico
PDF	Função Densidade de Probabilidade (<i>Probability Density Function</i>)
PSS	<i>Skill Score</i> de Peirce
RC	Captura de Rampa (<i>Ramp Capture</i>)
RMSD	Raiz do Erro Médio Quadrático das Anomalias (<i>Root Mean Squared Deviation</i>)
RMSE	Raiz do Erro Médio Quadrático (<i>Root Mean Squared Error</i>)
RR	<i>Hits</i> Rampa-Rampa
SIN	Sistema Interligado Nacional
SS4	<i>Skill Score</i> de Taylor
SVM	Máquinas de Vetores de Suporte (<i>Support Vector Machines</i>)

TN	Verdadeiro Negativo (<i>True Negative</i>)
TP	Verdadeiro Positivo (<i>True Positive</i>)
TSBM	Modelos Baseados em Séries Temporais (<i>Time Series Based Models</i>)
WPPT	Ferramenta de Previsão de Potência Eólica (<i>Wind Power Prediction Tool</i>)
WRF	Modelo de Pesquisa e Previsão do Tempo (<i>Weather Research and Forecasting</i>)

SUMÁRIO

1	INTRODUÇÃO	14
1.1	<i>Objetivo geral.....</i>	15
1.2	<i>Objetivos específicos.....</i>	15
2	CONCEITOS PRELIMINARES	16
2.1	<i>Séries Temporais.....</i>	16
2.2	<i>Previsão.....</i>	17
2.3	<i>Redes Neurais.....</i>	19
2.4	<i>Redes Bayesianas</i>	23
3	REVISÃO DE LITERATURA.....	25
3.1	<i>Definição de Rampa</i>	26
3.2	<i>Métodos de Previsão de Rampa.....</i>	30
4	MATERIAL E MÉTODOS.....	35
4.1	<i>Modelos de Referência</i>	39
4.1.1	<i>Persistência.....</i>	39
4.1.2	<i>Rede Neural de Ajuste Global.....</i>	39
4.1.3	<i>Rede Neural de Ajuste Global com dados da central a barlavento.....</i>	40
4.2	<i>Modelos locais.....</i>	43
4.2.1	<i>Mecanismo identificador de regime (IR)</i>	44
4.2.2	<i>Modelo I.....</i>	46
4.2.3	<i>Modelo II.....</i>	47
4.2.4	<i>Modelo III.....</i>	49
4.2.5	<i>Modelo IV.....</i>	50
4.2.6	<i>Modelo V.....</i>	51
5	RESULTADOS E DISCUSSÃO.....	53
5.1	<i>Determinação do delay entre as centrais.....</i>	54
5.1.1	<i>Grupo A.....</i>	54
5.1.2	<i>Grupo B.....</i>	57
5.1.3	<i>Grupo C.....</i>	59
5.1.4	<i>Grupo D.....</i>	62
5.2	<i>Rampas de Subida.....</i>	64
5.3	<i>Rampas de Descida.....</i>	74

6	CONCLUSÃO.....	84
7	PERSPECTIVAS.....	86
	REFERÊNCIAS.....	87
	APÊNDICE A - SÉRIES TEMPORAIS.....	94
	APÊNDICE B - EVOLUÇÃO DO <i>BIAS</i>.....	103
	APÊNDICE C - DIAGRAMAS DE TAYLOR.....	108
	APÊNDICE D - RESULTADOS ESTATÍSTICOS.....	117

1 INTRODUÇÃO

Ao longo dos últimos anos, a energia eólica vem apresentando um importante crescimento dentro da matriz elétrica brasileira. A potência instalada referente a centrais eólicas apresentou um crescimento de 56% entre os anos de 2014 e 2015 e de 33% entre 2015 e 2016. (BEN, 2016; BEN, 2017). No início de fevereiro de 2018, a capacidade eólica instalada no Brasil chegou a 12,95 GW, alcançando uma participação na matriz elétrica nacional de 8,3% (ABEEOLICA, 2018).

Apesar dos vários benefícios associados à fonte eólica, este crescimento torna o controle do sistema elétrico ainda mais complexo, pois a saída das centrais eólicas está associada a uma fonte intermitente, não regulável e profundamente dependente das condições ambientais, ou seja, há bastante incerteza quanto à evolução temporal (em diferentes escalas temporais) da potência de saída de uma central eólica. Mesmo com tal componente estocástica, é possível estimar em certa medida, com o auxílio de técnicas preditivas, o comportamento da potência de saída das centrais eólicas, de forma a viabilizar a tomada de decisão por parte do Operador Nacional do Sistema Elétrico (ONS) quanto ao arranque e parada de outras fontes como, por exemplo, as centrais térmicas.

Entretanto, a grande maioria das técnicas de previsão utilizadas no Setor Eólico foca sua atenção na minimização do erro global sobre um grande período de tempo e acaba desprezando os regimes de variações abruptas (GALLEGO, 2013), o que pode acarretar em erros locais excessivamente altos nas séries temporais. Dentre as variações abruptas, são de particular interesse para a Eólica as chamadas rampas (CUTLER et al., 2007; GALLEGO et al., 2011a), eventos nos quais o gradiente local da série temporal, mantido durante um intervalo de tempo suficientemente longo, apresenta valores elevados. Neste contexto, aplicam-se as técnicas de previsão de rampa (*ramp forecasting*), as quais procuram minimizar o erro das estimativas feitas para esses eventos locais específicos.

Regimes de rampa podem ocasionar, de forma muito rápida, elevados acréscimos (rampas de subida) ou decréscimos (rampas de descida) de potência, resultando em uma necessidade, por parte do operador, de limitar a potência injetada na rede, em casos de rampa de subida, ou solicitar potência da reserva girante (PEREIRA et al., 2017), em casos de rampa de descida, para manter a estabilidade

do sistema. Este último caso apresenta uma problemática ainda maior, tendo em vista que o acionamento de centrais de potência regulável requer uma inércia de partida muitas vezes maior que o desejado por parte do operador. Sendo assim, é imprescindível que o operador do sistema tenha o conhecimento *a priori* sobre tais eventos para que possa planejar com antecedência as medidas necessárias para lidar com essas situações. Apesar disso, o ONS não dispõe, atualmente, de modelos especializados em previsão de rampas.

1.1 Objetivo geral

O trabalho em questão busca desenvolver modelos capazes de realizar uma previsão acurada, a curtíssimo prazo, de rampas em séries de potência de saída de centrais eólicas, de forma a auxiliar o ONS no controle do sistema elétrico brasileiro.

1.2 Objetivos específicos

1. Desenvolver modelos baseados em séries temporais para realizar a previsão, a curtíssimo prazo (da ordem de 10 min a 1h), da potência de saída de centrais eólicas;
2. Desenvolver um mecanismo capaz de identificar regimes de rampas em tempo real;
3. Introduzir informação de centrais a barlavento da central de interesse e avaliar sua contribuição na previsão de rampas;
4. Previsão de rampas em tempo real em séries de potência de saída de centrais eólicas.

2 CONCEITOS PRELIMINARES

Nesta seção, são apresentados alguns conceitos importantes que facilitam a compreensão do documento em apreço.

2.1 Séries Temporais

Uma série temporal é um conjunto de observações organizadas sequencialmente ao longo do tempo. Uma série é dita contínua quando estas observações são feitas continuamente no tempo (e.g., medidas em anemógrafos baseados em *chart recorders* eletromecânicos) e é dita discreta quando as observações são tomadas apenas em intervalos de tempo específicos (e.g., medidas em anemômetros digitais). Geralmente, amostras vizinhas são dependentes, o que torna possível a previsão dos valores futuros fazendo-se uso de amostras do presente e do passado. Caso uma série temporal possa ser prevista de forma absolutamente acurada, ela é dita determinística. Entretanto, a grande maioria das séries é estocástica, tendo em vista que os valores de suas amostras futuras são apenas parcialmente determinados por valores de suas amostras presente e passadas (PEREIRA et al., 1986; CHATFIELD, 1996; WEI, 2006). Para os propósitos deste trabalho, considera-se a série temporal como um conjunto discreto de amostras da saída de um sistema dinâmico (dados observacionais da potência de saída de uma central eólica) tomadas em intervalos de tempo regulares.

Entendendo-se um processo estocástico como um conjunto de variáveis aleatórias ordenadas no tempo (sendo representado por $\{X_t\}$, onde t indica o instante em que a variável foi observada), pode-se admitir uma série temporal como uma realização de um processo estocástico. Comumente, a caracterização de um processo estocástico se dá através de seus primeiro e segundo momentos estatísticos, os quais são, respectivamente, a média e a variância definidos por $\mu_t = E[X_t]$ e $\sigma_t^2 = Var[X_t]$, respectivamente (CHATFIELD, 2000):

Entretanto, tratando-se de uma série temporal, a variância sozinha não é suficiente para caracterizar o comportamento de segunda ordem. Sendo assim, define-se a função de autocovariância, a qual é a covariância entre X_{t_1} e X_{t_2} : $\gamma_{t_1,t_2} = E\{[X_{t_1} - \mu_{t_1}][X_{t_2} - \mu_{t_2}]\}$.

Diferente do que ocorre com outros problemas estatísticos, aqui apenas uma realização do processo estocástico é possível, isto é, não se pode repetir o experimento. Sendo assim, de forma a simplificar o problema e tornar a previsão factível, assumem-se algumas hipóteses. A primeira é a de que o processo estocástico é estacionário. Mais precisamente, estacionário de segunda ordem. Isso significa que a série temporal oriunda desse processo estocástico se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável (MORETTIN E TOLOI, 1981). Um processo é chamado estacionário de segunda ordem se os valores da média e da variância são constantes e se a função de autocovariância depende exclusivamente da defasagem (*time lag*) τ , de forma que $\mu_t = \mu$, $\sigma_t^2 = \sigma^2$ e $\gamma_{t,t+\tau} = \gamma(\tau)$, $\tau \in N$.

A segunda hipótese que se deve assumir é a de que o processo é ergódico, ou seja, sua média, variância e função de autocovariância podem ser estimadas usando somente uma realização de X_t (PEREIRA et al., 1986).

2.2 Previsão

A previsão da potência eólica consiste no emprego de um conjunto de técnicas orientadas a prover informações sobre o comportamento da potência de saída de um aerogerador (ou central eólica) em um futuro determinado (COSTA et al., 2008; GALLEGRO, 2013). Neste sentido, pode-se realizar a previsão eólica a partir de uma abordagem físico-numérica, a qual utiliza modelos de previsão numérica do tempo, os chamados *NWP models (Numerical Weather Prediction)* (LOUKA et al. 2008, SOMAN et al., 2010; FOLEY et al., 2012), ou a partir de uma abordagem estatística de séries temporais, baseada na modelagem de processos estocásticos (POTTER e NEGNEVITSKY, 2006; WU e HONG, 2007). Sabe-se que os modelos de NWP possuem maior acurácia em previsões de médio e longo prazo e que os modelos baseados em séries temporais são mais recomendados para previsões de curtíssimo prazo (COSTA, 2005; NEGNEVITSKY e JOHNSON, 2008; GIEBEL et al., 2011). Como aqui o foco do estudo é a previsão a curtíssimo prazo, utilizam-se os modelos estatísticos de séries temporais.

Assumindo que as séries de potência eólica são realizações de processos estacionários e ergódicos, podem-se analisar as características comportamentais sistemáticas destas séries a fim de construir modelos capazes de descrever as observações passadas e prever seus valores futuros. A previsão eólica pode ser realizada a partir de (CHATFIELD, 2000):

- *Métodos univariados*, nos quais a previsão depende exclusivamente do comportamento histórico (passado e presente) da série temporal em questão;
- *Métodos multivariados*, os quais consideram, além do histórico da série temporal de interesse, outras variáveis exógenas para realizar a previsão.

A saída de potência de uma central eólica é aqui considerada um sinal discreto produzido por uma amostragem em alta frequência (tipicamente, 1 Hz) e posterior integração com vistas ao cálculo das médias (y_t) em um determinado intervalo de integração (dt), o qual pode variar desde alguns minutos até alguns dias, a depender da aplicação da previsão. O quão no futuro será realizada a estimativa irá depender tanto do intervalo dt quanto do horizonte de previsão k , o qual determina o número de passos à frente com que será feita a previsão, aqui referida como $\hat{y}_t(k)$. Por exemplo, assumindo que $dt = 30$ min, um horizonte de previsão de $k = 2$ indica que a estimativa será realizada para 1 hora à frente. Deve-se ter em mente que a confiabilidade da previsão tende a diminuir conforme o horizonte de previsão aumenta (CUTLER et al., 2007).

A previsão pode, ainda, ser realizada para obtenção de um valor único (*single-value forecasting*) (ALEXIADIS et al., 1999; POTTER e NEGNEVITSKY, 2006; KUSIAK et al., 2009) ou para obtenção de uma densidade de probabilidade associada a cada valor esperado (*probabilistic forecasting*) (PINSON e KARINIOTAKIS, 2004; ZHU E GENTON, 2012).

De acordo com o horizonte de previsão k e o intervalo de integração Δt , pode-se classificar a previsão eólica em:

- *Previsão de curtíssimo prazo*, com horizontes de previsão de segundos até algumas horas, tendo como aplicações principais o sistema de controle dos aerogeradores e os mercados intradiários de energia;

- *Previsão de curto prazo*, com horizontes de previsão de horas a alguns dias, tendo como aplicações principais o mercado diário (*spot market*) e o despacho da energia eólica junto ao operador do sistema elétrico;
- *Previsão de médio e longo prazos*, com horizontes de previsão de dias, semanas ou até meses, tendo como aplicações principais a estimativa da produção de centrais eólicas (*cash flow*) e a reprogramação das tarefas de manutenção dos aerogeradores.

2.3 Redes Neurais

Uma Rede Neural (NN – *Neural Network*) é uma estrutura projetada para modelar a maneira em que o cérebro processa informações rapidamente, de forma não linear e paralela. Haykin (2001) define rede neural como:

Um processador maciça e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro humano em dois aspectos:

1. *O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;*
2. *Forças de conexão entre os neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.*

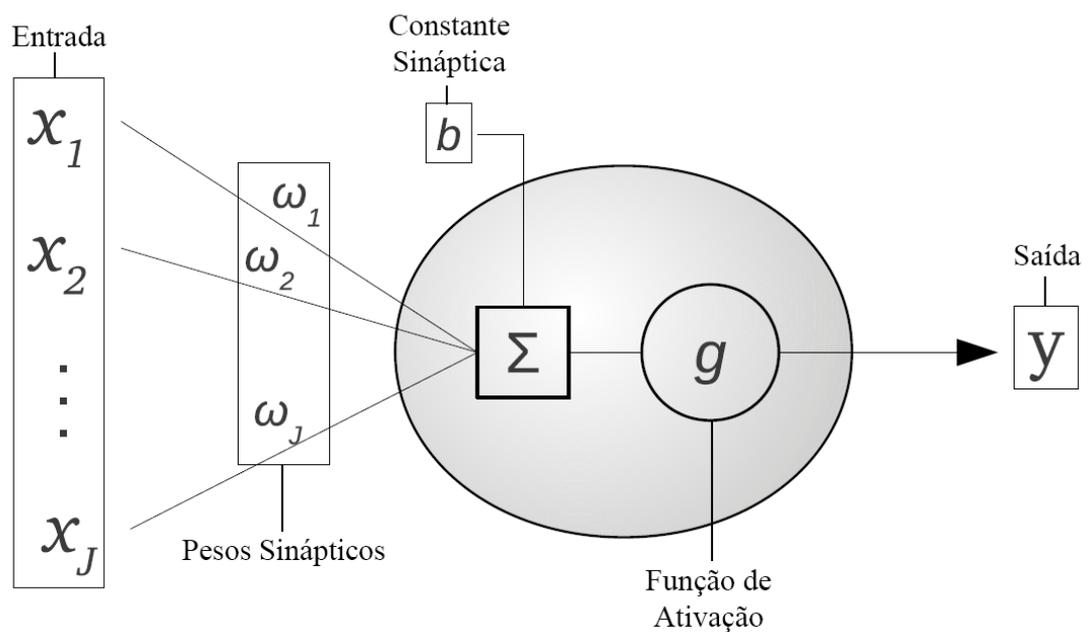
O neurônio é a unidade básica de processamento de uma rede neural. De acordo com o modelo criado por Widrow e Hoff (1960), o neurônio recebe os sinais de entrada x_i e os multiplica por seus respectivos pesos sinápticos ω_i . Os resultados dessa multiplicação são somados e introduzidos, junto com a constante sináptica, ou *bias*, b , em uma função de ativação g , gerando a saída y , de acordo com a Equação 1 e a Figura 1. A função de ativação deve ser escolhida de acordo com a aplicação da rede e não é necessariamente a mesma para todas as camadas. Alguns exemplos são as funções sigmóide, degrau, linear e tangente hiperbólica, como demonstrado na Figura 2. Por fim, os pesos sinápticos são ajustados através de um processo de aprendizagem (treinamento), o qual pode ocorrer de forma supervisionada (quando as saídas desejadas para cada entrada são apresentadas à rede, de modo a minimizar

o erro) ou sem supervisão (quando apenas os dados de entrada são informados) (HAYKIN, 2001).

$$y = g \left(b + \sum_{i=1}^N \omega_i x_i \right) \quad (1)$$

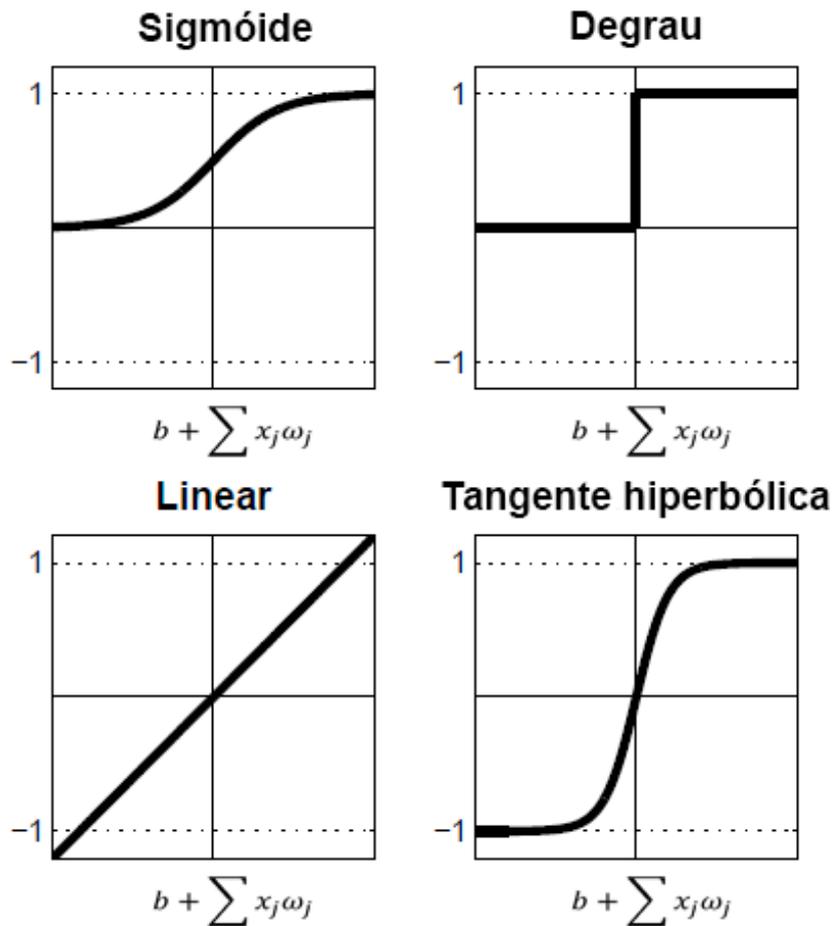
Também, podem-se classificar as NNs em redes *feedforward* (nas quais as saídas dependem exclusivamente das entradas) e redes recursivas (as quais possuem conexões de *feedback*, ou seja, as saídas de neurônios em camadas posteriores podem alimentar neurônios de camadas anteriores).

Figura 1 - Modelo de neurônio artificial



Fonte: GALLEGO (2013) – adaptado.

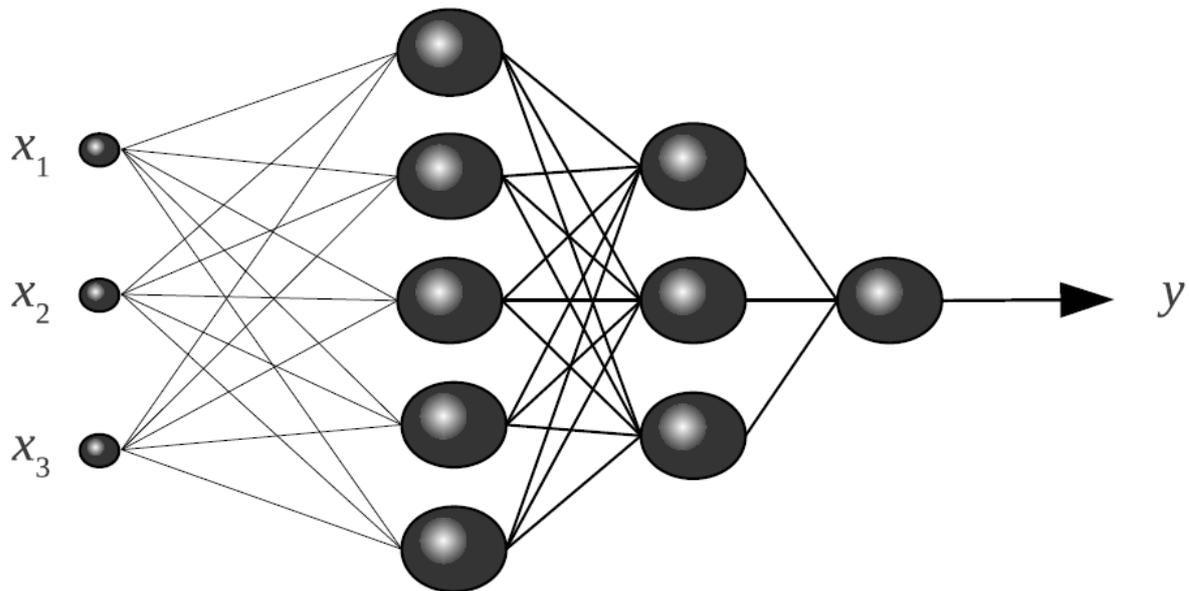
Figura 2 - Exemplos de função de ativação



Fonte: GALLEGO (2013) – adaptado.

Um tipo de rede comumente utilizado em previsão eólica é a Perceptron Multicamadas (MLP – *Multilayer Perceptron*), a qual consiste em uma camada de entrada, que recebe as informações do meio, uma camada de saída, cujo comportamento é diretamente especificado pelos alvos, de forma que sua saída se aproxime ao máximo dos valores esperados, e, entre essas duas camadas, uma ou mais camadas ocultas. No caso das camadas ocultas, os alvos não influenciam diretamente seu comportamento, sendo este ajustado a partir da função de treinamento. Ainda, as redes do tipo MLP são totalmente conectadas, ou seja, um neurônio de uma camada qualquer i está conectado a todos os neurônios da camada posterior $i + 1$ (GOODFELLOW et al., 2016). Tal estrutura encontra-se ilustrada na Figura 3.

Figura 3 - Estrutura de uma rede neural do tipo MLP



Fonte: GALLEGO (2013).

Uma característica importante da Perceptron Multicamadas é que cada neurônio das camadas ocultas inclui uma função de ativação não-linear, o que impede que a relação de entrada-saída da rede seja reduzida àquela de um perceptron de uma única camada. Uma forma normalmente utilizada é a não-linearidade sigmóide da função logística, dada pela Equação 2, a qual varia de forma suave entre 0 e 1 (HAYKIN, 2001).

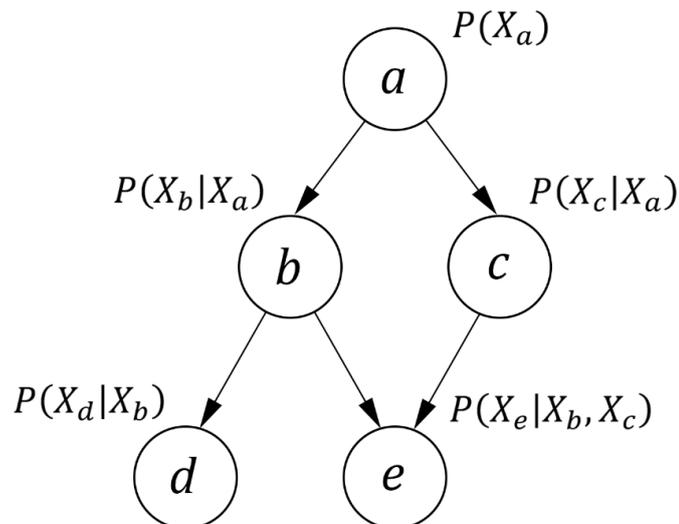
$$y(v) = \frac{1}{1 + e^{-v}} \quad (2)$$

As MLPs utilizam, em seu treinamento, algoritmos baseados na retropropagação de erro (*error backpropagation*), cuja aprendizagem consiste em comparar a saída da rede com o alvo esperado e, de acordo com o erro obtido, ajustar os pesos sinápticos (ω_{ij}) e o *bias* (b) de forma a minimizar tal erro. Essa operação de “vai e vem” sobre a rede (da camada de entrada à de saída e vice-versa) se repete até que seja encontrada a combinação de ω_{ij} e b que forneça um mínimo do erro sobre toda a série temporal (HAYKIN, 2001). Para aumentar a probabilidade de se encontrar o mínimo global do erro (e não, um mínimo local), são realizadas diversas inicializações com pesos sinápticos distribuídos aleatoriamente sobre toda a rede.

2.4 Redes Bayesianas

Uma rede bayesiana pode ser vista como um modelo gráfico que representa as inter-relações probabilísticas associadas a um conjunto de variáveis e realiza inferência entre elas (JENSEN, 2001). As dependências condicionais entre estas variáveis são representadas por um grafo acíclico dirigido $G = \{X, E\}$, cujos nós representam um conjunto de variáveis (X) com um número finito de estados mutuamente excludentes e os arcos (E), as dependências diretas entre estas variáveis. As probabilidades condicionais locais de cada variável com respeito aos possíveis estados de seus predecessores são armazenadas em θ . Sendo assim, podemos denotar um rede bayesiana como $BN = \{G, \theta\}$ (WILLIAMSON, 2005). Tal estrutura é exemplificada na Figura 4.

Figura 4 - Exemplo de estrutura de rede bayesiana



Fonte: Própria.

Observa-se, por exemplo, que as variáveis dos nós b e c influenciam diretamente o comportamento da variável do nó e . Diz-se, então, que b e c são os “pais” de e , de modo que a probabilidade de ocorrência de um determinado estado X_e é descrito a seguir na Equação 3.

$$P(X_e) = P(X_e|pa(X_e)) \quad (3)$$

em que, $pa(X_e) = \{X_b, X_c\}$ representa os pais da variável X_e . Dessa forma, a partir das distribuições condicionais locais, pode-se determinar a distribuição de probabilidade conjunta global de acordo com a regra da cadeia, dada pela Equação 4.

$$P(X_1, X_2, \dots, X_n) = \prod_{e=1}^n P(X_e | pa(X_e)) \quad (4)$$

Um conjunto inicial θ , contendo as distribuições condicionais locais, é definido *a priori*, podendo ser determinado a partir de conhecimento prévio, hipóteses ou, simplesmente, distribuições genéricas. As informações obtidas a partir das evidências (dados observacionais) são propagadas através da rede bayesiana, atualizando, *a posteriori*, as distribuições de probabilidade contidas em θ . Através da regra de Bayes, dada pela Equação 5, as relações de probabilidade podem ser calculadas no sentido inverso, desde as variáveis dependentes até seus predecessores (KOSKI E NOBLE, 2009). Os parâmetros destas distribuições podem ser atualizados, por exemplo, através da máxima verossimilhança.

$$P(X_d | X_e) = \frac{P(X_e | X_d)P(X_d)}{P(X_e)} \quad (5)$$

3 REVISÃO DE LITERATURA

Um dos aspectos mais importantes a serem observados durante a operação do Sistema Interligado Nacional (SIN) é a manutenção do adequado balanço entre a demanda e a geração de energia. Nesse sentido, a antecipação com respeito ao comportamento da potência de saída das centrais eólicas é uma ferramenta de fundamental importância em um sistema com alta penetração de Eólica. Entretanto, as ferramentas de previsão eólica de curto prazo são normalmente ajustadas de forma a minimizar o erro global, sobre toda a série temporal observada, de forma que os impactos de eventos extremos são normalmente subestimados (POTTER et al., 2009). Dentre os eventos extremos em séries temporais, são de particular interesse para a energia eólica as chamadas rampas (FERREIRA et al., 2011; GALLEGO et al., 2015), as quais são variações grandes e abruptas na potência de saída de uma central eólica, o que pode dificultar bastante o controle do SIN por parte do ONS (BRADFORD et al., 2010). Tais eventos ocorrem, geralmente, por conta de processos meteorológicos específicos como passagens de frentes e mudanças rápidas na direção do vento, podendo estar relacionados a processos desde a escala sinótica até a microescala (GALLEGO et al., 2011b). Durante uma rampa de descida, por exemplo, o operador deve compensar rapidamente o decréscimo na potência eólica aumentando a potência de saída de algum gerador regulável tal como, por exemplo, uma central térmica, a qual costuma apresentar uma inércia de partida relativamente alta, o que dificulta bastante a ação do operador do sistema elétrico (ELA e KEMPER, 2009; CUTLER et al., 2009b).

Com o intuito de melhorar a acurácia das estimativas durante eventos extremos como as rampas, os modelos locais de previsão passaram a despertar o interesse de estudiosos em todo o mundo na última década, que vêm explorando tanto abordagens estatísticas (ZHENG e KUSIAK, 2009; KAMATH, 2010; GALLEGO et al., 2011a, 2011b) quanto abordagens físicas (GREAVES et al., 2009; ZACK et al., 2010; BOSSAVY et al., 2013), tendo em vista que, por ser um tema relativamente novo, os métodos de previsão de regimes de rampa ainda não foram bem estabelecidos.

Embora a ideia de rampa seja bastante intuitiva, não há uma definição universal para este tipo de evento, tendo em vista que as características e impactos das rampas podem variar bastante a depender do local de interesse, o que conduz a diversas

abordagens quanto à definição e identificação de rampas por parte dos autores (PEASE, 2009; POTTER et al., 2009; COLLIER et al., 2010; GALLEGO et al., 2013).

Dessa forma, faz-se necessária uma revisão tanto da literatura a respeito das diferentes definições de rampa já propostas quanto a respeito das metodologias já desenvolvidas para a previsão de regimes de rampa.

3.1 Definição de Rampa

Na grande maioria dos trabalhos, as rampas são caracterizadas de acordo com (GALLEGO, 2013):

- *Magnitude* (Δy): Determina a variação relativa de potência durante a ocorrência da rampa;
- *Duração* (Δt): Determina o período de tempo durante o qual a rampa é observada;
- *Direção*: Determina se a rampa representa um aumento (rampa de subida) ou uma diminuição (rampa de descida) de potência;
- *Timing* (t_0): Determina o instante relativo à ocorrência de uma rampa.

Entre os parâmetros supracitados, destacam-se Δy e Δt , cujos valores podem ser definidos tanto *a priori* (nos casos em que o usuário das previsões tenha uma definição clara sobre os níveis de rampa que lhe tornem complicada sua operação) quanto *a posteriori* (buscando-se a combinação de Δy e Δt que venha a contribuir a uma minimização do erro global, sobre toda a série temporal). Ainda, a definição dos valores de tais parâmetros tanto pode ocorrer de forma subjetiva (por exemplo, através de uma inspeção visual da série temporal) quanto de forma objetiva (por exemplo, fazendo-se uso de limiares pré-definidos para classificar a série temporal de forma binária, tal como na Equação 6).

$$I_t = \begin{cases} 1, & \text{se } S_t \geq S_0 \\ 0, & \text{se } S_t < S_0 \end{cases} \quad (6)$$

em que S_t representa o critério de avaliação no instante t ; S_0 , um limiar acima do qual um evento é considerado rampa, ou seja, $I_t = 1$. Normalmente, o critério S_t é baseado na variação de potência durante um período de tempo Δt , de acordo com a Equação

7, e o critério S_0 é determinado a partir de uma porcentagem da potência nominal (P_N) da central eólica (o que não pode ser aplicado à velocidade do vento, por exemplo) (HECKENBERGEROVA et al., 2014).

$$S_t = |\Delta y| = |y_{t+\Delta t} - y_t| \quad (7)$$

Neste caso, o sinal da variação determina a direção da rampa, a qual é de subida se $\Delta y > S_0$ ou de descida se $\Delta y < -S_0$.

Entretanto, a definição acima utiliza os valores inicial e final de potência dentro de um determinado intervalo de tempo, o que pode gerar uma identificação inadequada em casos de rampas consecutivas. A fim de evitar esse problema, Kamath (2010) propôs um critério alternativo, levando em consideração os valores máximo e mínimo da potência observada durante um determinado intervalo de tempo, como mostra a Equação 8. Esta definição, entretanto, não é capaz de determinar a direção ou a inclinação da rampa.

$$S_t = \max([y_t, y_{t+\Delta t}]) - \min([y_t, y_{t+\Delta t}]) \quad (8)$$

Uma rampa também pode ser definida considerando sua intensidade de crescimento ou decrescimento em um determinado período de tempo, a chamada taxa de rampa (*ramp rate* – RR), dada pela Equação 9 (ZHENG e KUSIAK, 2009).

$$S_t = |RR| = \left| \frac{\Delta y}{\Delta t} \right| \quad (9)$$

Bossavy et al. (2010) e Girard et al. (2011) utilizaram um sinal filtrado y_t^f para determinar uma rampa, onde y_t^f pode ser definido pela Equação 10. Neste caso, o intervalo temporal utilizado foi $\Delta t = 5$ horas e o limite para determinação de rampa foi $S_0 = 25\%$ da potência nominal da central eólica.

$$y_t^f = \frac{1}{\Delta t} \sum_{h=1}^{\Delta t} y_{t+h} - \frac{1}{\Delta t} \sum_{h=0}^{\Delta t-1} y_{t+h-\Delta t} \quad (10)$$

Cutler et al. (2007) utilizaram duas definições para rampa: a primeira foi utilizada em séries com intervalo de integração de 1 hora e caracterizada por uma variação de 75% da potência nominal em um período de 3 horas; já a segunda, utilizada em uma série com intervalo de integração de 10 minutos, descrevendo uma rampa bem mais abrupta, com uma variação de 65% de P_N dentro de 1 hora. Tais parâmetros foram determinados através da análise do número de ocorrências de

rampa para valores de S_0 variando de 40 a 90% da potência nominal. Em Ela e Kemper (2009), foram utilizadas classificações de rampa com variações (na potência de saída da central eólica) acima de 25%, 33%, 40% e 50% de P_N em um período de 1 hora e variações de 25% de P_N em um período de 30 minutos. Ela e Kemper (2009) observaram que, no local de estudo, o número de rampas de subida é, normalmente, maior que o número de rampas de descida e que este comportamento é intensificado conforme o limiar S_0 aumenta.

Potter et al. (2009) determinam que uma variação de 10% da potência nominal dentro de um período de 1 hora caracteriza uma rampa. Para Greaves et al. (2009), Collier et al. (2010) e Pinson e Otterson (2012), esta variação deve corresponder a 50% de P_N e durar, no máximo, 4 horas. Heckenbergerova et al. (2014), também acreditam que uma variação de 50% na potência nominal caracteriza um evento de rampa, porém afirmam que esta variação deve ocorrer em um período de 5 horas. Utilizando dados de uma central eólica em Alberta, Canadá, Heckenbergerova et al. (2014) realizaram uma análise dos eventos da série temporal que precedem eventos de rampa, identificando padrões no comportamento da média e do desvio padrão e chegando à conclusão de que, em geral, a potência decresce antes de uma rampa de subida e aumenta antes de uma rampa de descida. Ainda, concluíram que a variância costuma diminuir e, então, aumentar cerca de 4 horas antes do evento, tanto para rampas de subida quanto de descida.

O relatório da AWS Truewind (2008) sugere que uma rampa de descida ocorre apenas se a variação (em um período de 1 hora) de potência (S_t) é de, no mínimo, 15% de P_N . Também, sugere que uma rampa de subida ocorre apenas se tal variação é de 20% de P_N . Baseando-se neste relatório, Zack et al. (2010) realizaram a previsão de rampas até 6 horas à frente utilizando uma metodologia baseada na previsão das probabilidades de ocorrência de diversas taxas de rampa para diferentes períodos de tempo. Uma definição semelhante foi utilizada em Bradford et al. (2010), na qual o limiar $S_0 = 20\%$ da potência nominal foi utilizado para determinar rampas em ambas as direções dentro de um intervalo de $\Delta t = 1 \text{ hora}$.

Apesar de ser geralmente expresso como uma porcentagem da potência nominal, alguns trabalhos consideram S_0 como um limite absoluto. Segundo Kamath (2010), esta abordagem é mais adequada, tendo em vista que, caso a capacidade instalada da central eólica aumente, esta definição não deverá classificar de forma

diferente o mesmo evento, fato que ocorre com definições que utilizam S_0 como uma porcentagem de P_N . Entretanto, o mesmo autor expressou diferente opinião um ano mais tarde, alegando que ao se utilizar um limite absoluto, mais eventos serão classificados como rampas à medida em que a capacidade instalada de uma central eólica aumente (KAMATH, 2011). Para Freedman et al. (2008), uma rampa ocorre, em seu estudo, quando a variação de potência ultrapassa 200 MW em um período de 20 minutos. Zareipour et al. (2011) realizaram um estudo considerando variações de 50 MW em um período de 10 minutos e propuseram uma metodologia que organiza, através de Máquinas de Vetores de Suporte (*Support Vector Machines* - SVM), os eventos de rampa em classes dentro de um conjunto ordenado de limiares $S_{min} < S_1 < \dots < S_{n-1} < S_{max}$, possibilitando o ajuste de modelos distintos para cada classe de rampa.

Outros autores, no entanto, utilizam diferentes critérios para a definição de S_t . Gallego et al. (2011a) propuseram uma definição de rampa baseada no gradiente local do sinal, o qual pode ser definido como a variação entre observações consecutivas na série normalizada pelo *time-step*. Como o *time-step* é unitário, o gradiente local será uma diferença de primeira ordem, conforme demonstrado na Equação 11.

$$S_t = |g_t| = |y_t - y_{t-1}| \quad (11)$$

O limiar S_0 é dado pela Equação 12, onde $\hat{\sigma}_g$ é uma estimativa do desvio padrão de g_t obtido através de dados históricos e h é um fator escalar que determina o quão rigorosa será a definição de rampa, o qual deverá ser determinado durante o processo de ajuste do modelo.

$$S_0 = h \cdot \hat{\sigma}_g \quad (12)$$

Grandes valores de h entregam um número reduzido de eventos de rampa de grande magnitude, enquanto valores menores de h , proporcionam a classificação de um número maior de eventos, porém de menor magnitude. No trabalho em questão, o autor encontrou valores ótimos de $h = 1$ e $\hat{\sigma}_g = 10,08\%$.

Em Fernández et al. (2013), o valor de S_t é determinado de forma que os eventos de rampa correspondam a 5% do total. Gallego et al. (2013) propuseram uma definição baseada na transformada discreta de *wavelet*, possibilitando a identificação de rampas de diferentes intensidades em diferentes escalas temporais. Em Florita et

al. (2013), Zhang et al. (2014) e Cui et al. (2015), os autores utilizaram o algoritmo *swinging door* (BRISTOL, 1990) para extrair rampas de séries de potência eólica e solar, identificando os pontos iniciais e finais de cada rampa.

Para realizar a identificação de eventos de rampa, Das (2015) utilizou uma nova série (m) criada a partir da razão entre valores de potência da série original, espaçados em intervalos de tempo iguais, de modo que, pela Equação 13:

$$m_t = \frac{y_{t+\Delta t}}{y_t} \quad (13)$$

para $t = 1, 2, 3 \dots T - \Delta t$, sendo T o tamanho da série temporal original. Por esta definição, quando $m_t > 1$, teremos uma rampa de subida, e quando $m_t < 1$, será observada uma rampa de descida.

3.2 Métodos de Previsão de Rampa

A previsão de eventos de rampa em séries de potência de saída de centrais eólicas pode ser realizada a partir de uma abordagem puramente estatística, utilizando dados observacionais da própria série de potência, a partir de uma abordagem físico-numérica, fazendo uso da saída de modelos de NWP, ou combinando essas duas abordagens. Zack et al. (2010) e Negnevitsky e Johnson (2008) observaram que a técnica de previsão a ser utilizada deve ser escolhida de acordo com a natureza da série temporal. Para séries estáveis, com pequenas variações aleatórias, um modelo de persistência seria apropriado para previsões de curtíssimo prazo. Já para séries voláteis ou com muita variação, um modelo não linear seria mais efetivo.

Cutler et al. (2007) avaliaram a performance de um modelo ajustado para minimizar o erro global de previsão aplicado em períodos com regime de rampa. A previsão se deu através do modelo de previsão *Wind Power Prediction Tool* (WPPT), o qual é um modelo estatístico que combina as observações em tempo real da potência de saída da central com as previsões de velocidade e direção do vento do modelo de NWP MesoLAPS, desenvolvido pela agência de meteorologia australiana (*Australian Bureau of Meteorology – BoM*). Observou-se que os erros de previsão dos eventos de rampa eram semelhantes aos cometidos pela média climatológica (modelo

de referência utilizado), a qual afirma que a previsão para qualquer horizonte é a média da potência de saída calculada a partir de um longo conjunto de dados históricos (ver Equação 14). Cutler et al. (2007) concluíram que esse resultado se deve, principalmente, à baixa precisão do modelo MesoLAPS em previsões de rampa e salientou que erros de *timing*, previsão de rampas com um atraso de algumas horas, são severamente penalizados pela utilização da raiz do erro médio quadrático (*Root Mean Square Error* - RMSE) como medida de performance.

$$\hat{y}_{t+k} = \bar{y}_t \quad (14)$$

De acordo com o relatório da AWS Truewind (2008), o projeto piloto de Alberta empregou as saídas de diversos modelos de NWP num modelo estatístico, de forma a realizar a previsão de um valor único (*single-value forecasting*). Contudo, AWS Truewind (2008) reportou que o uso do critério global para realizar esse ajuste implica em uma baixa precisão na previsão da taxa de rampa. Focken e Lange (2008) observaram que os modelos devem ser ajustados para minimizar um critério global ou para maximizar a performance durante eventos de rampa, mas ambos os critérios não podem ser atendidos ao mesmo tempo.

Greaves et al. (2009) investigaram metodologias para prever eventos de rampa, bem como as incertezas associadas a esses eventos. Para tanto, os autores utilizam o GH Forecaster, ferramenta de previsão desenvolvida pela Garrad Hassan. O modelo utiliza como entrada, dados de um modelo de NWP e observações da própria central, os quais passam por um processo estatístico e por modelos de curva de potência para realizar a previsão.

Neste caso, a análise da acurácia da previsão de rampas foi realizada com base na classificação binária de rampa, levando a três possíveis saídas:

- *Verdadeiro positivo (TP)*: Um evento de rampa é observado e previsto dentro de um intervalo de tempo específico.
- *Falso positivo (FP)*: Um evento de rampa é previsto, mas não é observado.
- *Falso negativo (FN)*: Um evento de rampa é observado, mas não é previsto.

A partir daí, Greaves et al. (2009) avaliaram a performance do seu modelo através da acurácia de previsão (*forecast accuracy* - FA), de acordo com a Equação 15, e da captura de rampa (*ramp capture* - RC), como mostra a Equação 16:

$$FA = \frac{TP}{TP + FP} \quad (15)$$

$$RC = \frac{TP}{TP + FN} \quad (16)$$

Os autores observaram que, ao combinar as diferentes saídas dos modelos de NWP, a capacidade de identificação de rampa diminuiu, visto que obteve um índice de captura de rampa menor que o obtido utilizando apenas um dos modelos. Ainda, salientaram que a definição binária de rampa dificulta a avaliação da performance de previsão de rampas, já que falsos negativos podem ocorrer quando a rampa é prevista corretamente no tempo, mas com amplitude um pouco menor que o limite empregado na definição de rampa.

Zheng e Kusiak (2009) utilizaram uma abordagem de mineração de dados para desenvolver modelos multivariados de séries temporais a fim de prever taxas de rampa de potência. A série utilizada foi obtida através da diferença entre observações consecutivas da série de potência (ver Equação 11). Foram desenvolvidos cinco modelos para previsão da taxa de rampa para horizontes variando de 1 a 6 passos à frente: Perceptron Multicamadas (*Multilayer Perceptron* (MLP)), Máquinas de Vetores de Suporte (*Support Vector Machines* - SVM), *Random Forest*, Árvores de Classificação e Regressão (*Classification and Regression Trees*) e *Pace Regression*. O modelo SVM superou os demais fornecendo previsões razoáveis até o quarto horizonte.

Bradford et al. (2010) utilizaram saídas de alta resolução (3 km) do modelo WRF (*Weather Research and Forecasting*) como entrada para um modelo de curva de potência a fim de prever a ocorrência de rampas a partir de uma definição binária. Para avaliar a acurácia do modelo, foram utilizados o índice de captura de rampa RC (Equação 14) e o *Skill Score* de Peirce (PSS), definido a seguir pela Equação 17.

$$PSS = \frac{(TP \cdot TN) - (FP \cdot FN)}{(TP + FN) \cdot (FP + TN)} \quad (17)$$

em que TN significa Verdadeiro Negativo, quando um evento de rampa não é previsto e não é observado. Tanto RC quanto PSS indicam uma baixa performance do modelo na identificação de rampas, o que foi atribuído a limitações específicas da metodologia.

Bossavy et al. (2010) propuseram um modelo de previsão probabilística (*probabilistic forecasting*) baseado na identificação de rampa a partir de um sinal filtrado y_t^f , definido previamente na Equação 10, e nas saídas de um modelo de NWP. Diferentes saídas de NWP são obtidas através da introdução de perturbações no estado inicial ou diferentes parametrizações do modelo. O modelo de Bossavy et al. (2010) estima o *timing* das rampas e define intervalos de confiança baseados nas diferentes saídas do modelo de NWP, obtendo melhores resultados que aqueles obtidos através da média climatológica. Bossavy et al. (2013) continuaram os estudos baseados nessa metodologia e concluíram que este modelo fornece uma captura de rampa mais confiável que a realizada com apenas uma saída de modelos de NWP.

Zack et al. (2010) utilizaram uma ferramenta desenvolvida por AWS Truewind (2008) para prever rampas em curtíssimo prazo. A ferramenta é capaz de prever a taxa de rampa e sua distribuição de probabilidade para horizontes de 15 min a 6 h à frente, bem como previsões de um único valor com intervalos de confiança de até 80%. Para tanto, a ferramenta utiliza, como entrada, dados de análise atmosférica e saídas de um modelo NWP de alta resolução. Os autores afirmaram que, através dessa ferramenta, conseguiram resultados até 25% melhores que os apresentados pela média climatológica.

Collier et al. (2010) desenvolveram um modelo que, além de utilizar dados de NWP e dados observacionais da central de interesse, utiliza dados observacionais do vento a barlavento para realizar a previsão de rampa em curtíssimo prazo (horizontes de 0 a 6 h). Os autores obtiveram melhora na previsão da taxa de rampa e concluíram que o uso do erro de previsão observado nos locais a barlavento fornecia melhores resultados que os obtidos utilizando os dados brutos.

Gallego et al. (2011a) propuseram um modelo puramente estatístico, baseado em redes neurais, diferenciando regimes de rampa do regime normal da série. A diferenciação dos regimes se baseou na observação mais recente do gradiente do sinal (Equação 11) em comparação com o limiar S_0 , definido pela Equação 12. Gallego et al. (2011a) utilizaram, como métrica de avaliação de acurácia, a melhora sobre a persistência (*Improvement over Persistence – IoP%*), definida a seguir pela Equação 18.

$$IoP\% = 100 \cdot \frac{RMSE_p - RMSE_m}{RMSE_p} \quad (18)$$

em que $RMSE_p$ e $RMSE_m$ representam a raiz do erro médio quadrático da persistência e do modelo, respectivamente. Os autores observaram, para o primeiro horizonte, uma melhora sobre a persistência de 4,65%, para as rampas de subida, e de 1%, para as rampas de descida, maior que as IoPs obtidas pelo modelo de referência empregado, o qual utiliza uma única NN de ajuste global. Para horizontes maiores (até 5 passos à frente), os resultados do modelo proposto foram similares aos do modelo de referência.

Zareipour et al. (2011) propuseram uma metodologia para, ao invés de realizar a previsão do valor exato da potência de saída das centrais, prever as classes em que se encontram os eventos de rampa. Tanto a previsão quanto a classificação, como citado anteriormente, são realizadas com o auxílio de Máquinas de Vetores de Suporte (SVM). A avaliação da performance do modelo foi realizada através do erro médio de classificação percentual (*mean percentage classification error* – MPCE), descrito na Equação 19.

$$MPCE (\%) = \frac{n_e}{n_t} \cdot 100 \quad (19)$$

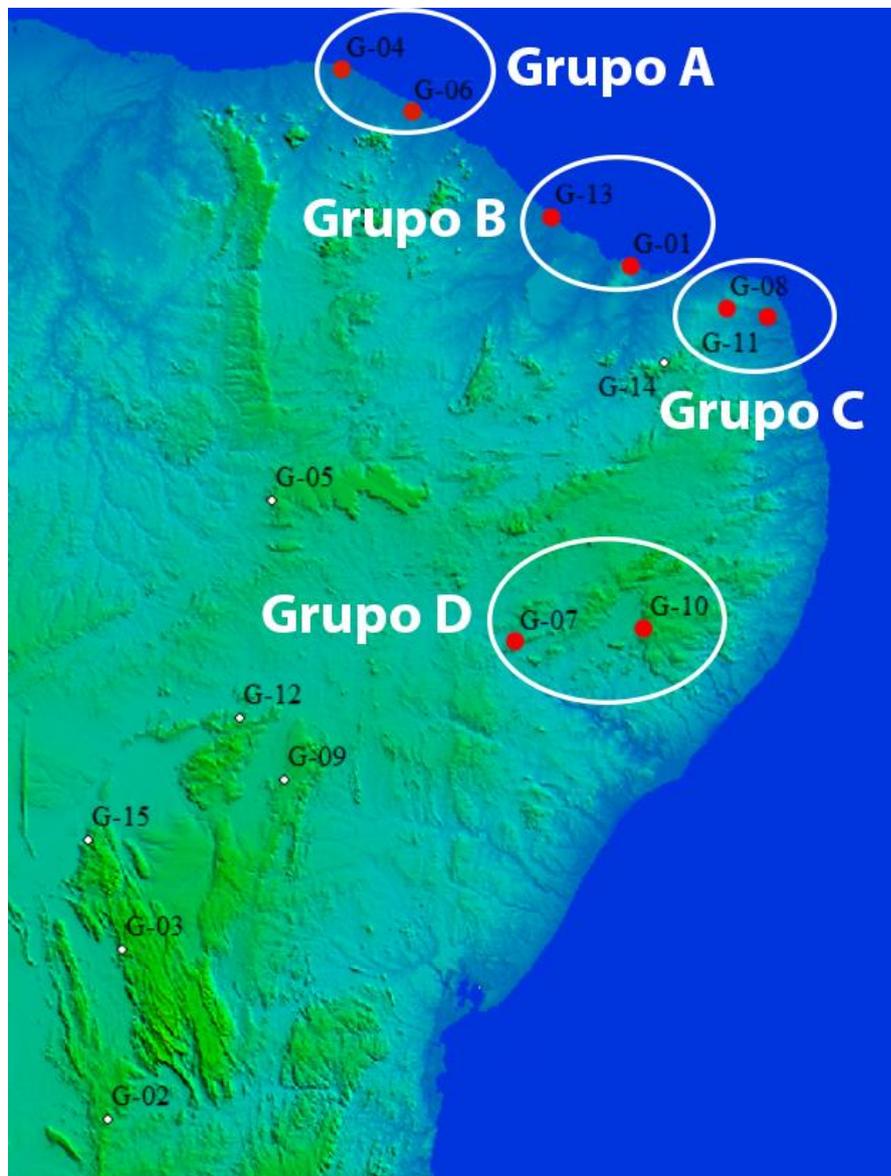
em que n_e é o número total de classificações incorretas e n_t é o número total de eventos classificados. As avaliações foram realizadas mensalmente e o MPCE médio anual foi de 8,93% para 1 passo à frente e de 9,36% para 6 passos à frente.

Em função do que foi visto ao longo desta seção, decide-se, aqui, trabalhar com uma definição de rampa baseada no gradiente local do sinal (Equação 11), a qual, em alguns casos, é aliada à inferência estatística proveniente de uma rede bayesiana, possibilitando a introdução de informações com respeito a centrais eólicas localizadas a barlavento do local de interesse, auxiliando a identificação deste tipo de regime. Ainda, alguns modelos utilizaram uma metodologia semelhante a de Zareipour et al. (2011), classificando as rampas em diferentes faixas de potência de acordo com o gradiente local. Por fim, as previsões em eventos de rampa serão realizadas através de redes neurais artificiais, tendo em vista o volumoso número de trabalhos que apresentaram êxito na previsão de ajuste global de séries de velocidade do vento e potência eólica utilizando esta técnica de previsão (MORE e DEO, 2003; BARBOUNIS et al, 2006; CADENAS e RIVERA, 2009; MONFARED et al, 2009; LI e SHI, 2010).

4 MATERIAL E MÉTODOS

Os dados observacionais utilizados neste estudo estão integrados a cada 10 minutos (*time-step*) e foram fornecidos pelo Operador Nacional do Sistema Elétrico (ONS) no âmbito do projeto High Performance Computing for Energy (<https://hpc4e.eu>). O mapa da Figura 5 apresenta, em vermelho, a localização aproximada das centrais eólicas utilizadas nesse estudo e a Tabela 1 contém os períodos relativos a cada grupo de centrais. As potências nominais destas centrais não são identificadas neste trabalho por questões de sigilo de dados.

Figura 5 - Mapa contendo as centrais eólicas utilizadas



Fonte: Própria.

Tabela 1 – Períodos dos grupos de centrais

Grupo	Período
A	01/11/2013 a 28/02/2017
B	01/01/2011 a 28/02/2017
C	01/05/2015 a 28/02/2017
D	01/12/2015 a 28/02/2017

De acordo com o método *holdout* (KOHAVI, 1995; WITTEN et al., 2016), comumente utilizado em aprendizado de máquina (*machine learning*), as séries foram divididas temporalmente de forma que os primeiros 2/3 das séries foram usados para ajuste dos modelos e o último 1/3, para validação dos resultados.

Fazendo uso de modelos de redes neurais do tipo *perceptron* multicamadas (NN-MLP), realizou-se a previsão, de um único valor (*single-value forecasting*), em rampas de potência eólica. Ainda, foram empregados modelos de redes bayesianas para, fazendo uso de observações de torres e centrais eólicas a barlavento do local de interesse, realizar uma inferência probabilística sobre os possíveis estados da potência, de forma a auxiliar as previsões das redes neurais no horizonte desejado. Vale salientar que, por se tratarem de modelos não paramétricos, não se faz necessária a determinação de uma Função Densidade de Probabilidade (PDF) a priori.

Com o objetivo de determinar as arquiteturas das redes neurais que proporcionam a maior acurácia na previsão, realizou-se um estudo de sensibilidade do erro, da correlação e do SS4 (ver Equação 23) entre a observação e as previsões das redes neurais para as diferentes variáveis relacionadas. Algumas dessas variáveis assumem valores comuns a todos os modelos, como a função de ativação, o algoritmo de treinamento, o número máximo de épocas e o número de inicializações. Outras, variam os valores de acordo com o modelo, como é o caso do par número de camadas e número de neurônios por camada. Por fim, algumas variáveis são ajustadas não só de acordo com o modelo, mas também de acordo com o local de interesse e o horizonte de previsão, como é o caso do número de variáveis

regressoras da central a sotavento (n) e do número de variáveis regressoras da central a barlavento (n_b).

Durante o estudo de sensibilidade, constatou-se que não ocorre aumento significativo na acurácia das redes neurais para um número de inicializações e um número máximo de épocas superiores a 200. Ainda, observou-se que o algoritmo de treinamento que proporcionou menores valores de RMSD (ver Equação 22) foi Levenberg–Marquardt (MORÉ, 1978), entregando 2,3 MW de erro, enquanto o segundo colocado, o algoritmo *Resilient Backpropagation* (RIEDMILLER e BRAUN, 1993), apresentou um erro de 3,2 MW. Finalmente, foi constatado que, para as séries temporais utilizadas neste estudo, as MLPs de apenas uma camada apresentaram maior acurácia que redes neurais de aprendizagem profunda (GOODFELLOW et al., 2016), entregando, no primeiro horizonte, valores de SS4 superiores a 0,8, quando a média para redes com mais de 4 camadas foi de 0,4.

Com base nesse estudo, os modelos desenvolvidos neste trabalho utilizam redes neurais do tipo MLP de uma única camada, cujo número de neurônios varia de acordo com o modelo. Em todos os modelos de ajuste global e alguns de ajuste local são utilizados 6 neurônios nesta única camada. Já os demais modelos locais utilizam, nas redes treinadas exclusivamente para rampas, 4 neurônios, e, nas redes treinadas para o regime normal, 6 neurônios. A escolha dos valores de n e n_b se deu a partir do treinamento de diversas redes neurais, para cada grupo de central, tipo de evento e horizonte, cuja entrada é fruto de todas as combinações possíveis de (n, n_b) no intervalo $[1, 10]$, de modo que a combinação que minimiza o erro é a escolhida.

Para determinar o *delay* temporal entre a central de interesse (T_1) e a central a barlavento (T_2), ou seja, o número de *time-steps* que uma hipotética partícula de vento levaria para percorrer a distância entre as duas centrais, fez-se uso de três abordagens: consistência física, relacionando a distância entre as centrais e a velocidade média do vento; máxima correlação, observando o *delay* relativo à maior correlação entre as séries temporais de T_1 e T_2 ; matriz de confusão, observando o *delay* que entrega a maior correspondência de rampas entre séries T_1 e T_2 . Todos os modelos foram treinados utilizando os *delays* calculados nessas três abordagens e o erro de previsão correspondente a cada *delay* foi calculado, de modo a determinar o número de *time-steps* que proporcione a maior acurácia de previsão para cada grupo de centrais.

A acurácia dos modelos será avaliada a partir de gráficos da melhora sobre a persistência (*Improvement over Persistence – IoP*), definida pela Equação 18, utilizando o erro médio quadrático das previsões (*Mean Squared Error – MSE*) e diagramas de Taylor (TAYLOR, 2001). O diagrama de Taylor foi escolhido por apresentar, de forma simultânea, informações a respeito: do desvio padrão dos modelos (σ_m) (Equação 20), permitindo a comparação da amplitude dos sinais observado e estimado; da correlação entre a observação e as saídas dos modelos (ρ) (Equação 21), possibilitando a avaliação da habilidade dos modelos em reproduzir a estrutura de fase e frequência do sinal original; e da raiz do erro médio quadrático das anomalias (*Root mean squared deviation – RMSD*), definido pela Equação 22.

$$\sigma_m = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2} \quad (20)$$

$$\rho = \frac{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sigma_o \sigma_m} \quad (21)$$

$$RMSD = \sqrt{\frac{1}{N} \sum_{i=1}^N [(y_i - \bar{y}) - (\hat{y}_i - \bar{\hat{y}})]^2} \quad (22)$$

em que, y_i representa a série observacional no instante i , \hat{y}_i , a série estimada no instante i , \bar{y} é o valor médio das observações, $\bar{\hat{y}}$, o valor médio das estimativas e σ_o representa o desvio padrão da série observacional.

Adicionalmente aos estatísticos já citados, utilizaremos o *skill score* de Taylor (SS4) para avaliar a acurácia geral dos modelos. Definido pela Equação 23, o SS4 varia de 0 (pior resultado) a 1 (melhor resultado) e também será apresentado nos diagramas de Taylor.

$$SS4 = \frac{4(1 + \rho)^4}{(\hat{\sigma}_m + 1/\hat{\sigma}_m)^2(1 + \rho_0)^4} \quad (23)$$

em que $\hat{\sigma}_m$ é a razão entre os desvios padrão do modelo e observação e ρ_0 a máxima correlação da série de referência. Aqui, a própria série observacional será utilizada como referência, portanto, adotou-se $\rho_0 = 1$.

A seguir, são apresentadas 5 diferentes abordagens que empregarão as MLPs com vistas a realizar as previsões locais, assim como modelos de referência, contra os quais serão comparados os resultados das mencionadas abordagens.

4.1 Modelos de Referência

4.1.1 Persistência

No que diz respeito à previsão eólica, o modelo da persistência (P) é muito empregado como modelo de referência por conta da característica *quasi*-estacionária da atmosfera, que implica em variações lentas na escala sinótica (NIELSEN et al., 1998). Sendo o modelo mais rudimentar para a realização da previsão eólica, a persistência assume que o comportamento da variável y em um dado instante t é exatamente igual ao seu comportamento em k passos à frente (COSTA, 2005), como pode ser visto na Equação 24.

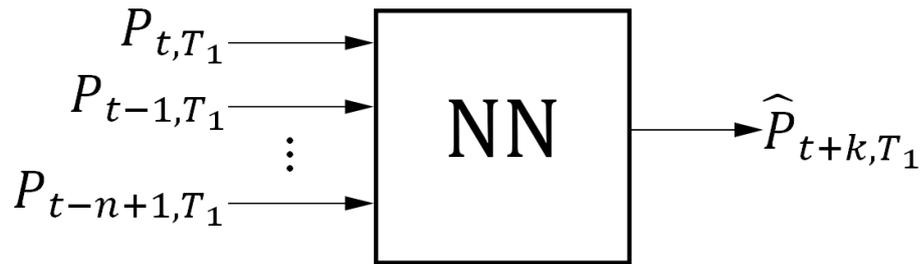
$$\hat{y}_{t+k} = y_t \quad (24)$$

Espera-se, portanto, que os modelos de previsão desenvolvidos ao longo deste estudo apresentem uma acurácia muito melhor que o modelo da persistência, de forma a justificar o esforço computacional que será empregado para o desenvolvimento de tais modelos.

4.1.2 Rede Neural de Ajuste Global

Embora o objetivo do trabalho seja o desenvolvimento de uma ferramenta específica para a previsão de comportamentos de rampa, foi desenvolvido, como aproximação inicial, um modelo global de previsão (B1), cuja arquitetura é ajustada de forma a minimizar o erro de previsão sobre toda a série temporal. Tal modelo consiste em uma única NN, na qual a entrada compreende uma janela de um passado recente contendo n dados observacionais da própria série temporal (T_1), incluindo o instante atual (t), e a saída será a estimativa desta mesma série temporal em k passos à frente. A Figura 6 exemplifica a estrutura do modelo.

Figura 6 - Diagrama representando o modelo B1



Fonte: Própria.

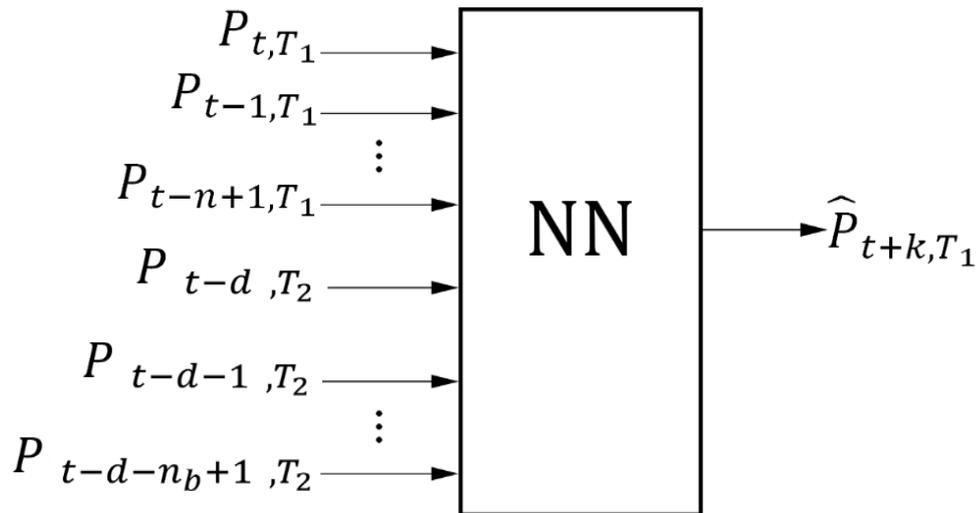
4.1.3 Rede Neural de Ajuste Global com dados da central a barlavento

Assim como o anterior, o modelo em questão procura minimizar o erro de previsão sobre toda a série temporal, porém utiliza como entrada da rede neural tanto os dados observacionais da central de interesse (T_1) quanto os dados observacionais de uma central a barlavento desta (T_2). Será utilizada uma única rede contendo, como entrada, uma matriz de variáveis regressoras contendo n dados observacionais do passado recente de T_1 e n_b observações de T_2 .

A janela de variáveis regressoras relativa a T_1 é idêntica à utilizada em B1, porém, buscando identificar a melhor abordagem quanto à janela utilizada em T_2 , foram desenvolvidas quatro variantes deste modelo:

- Variante 1 (B2): As n_b variáveis regressoras utilizadas em T_2 possuem um atraso d (*delay*) com relação ao instante atual t , como exemplificado na Figura 7. Tal variante parte do princípio que o comportamento do vento observado na central a barlavento (T_2), também será observado na central a sotavento (T_1) após um determinado período de tempo (*delay*).

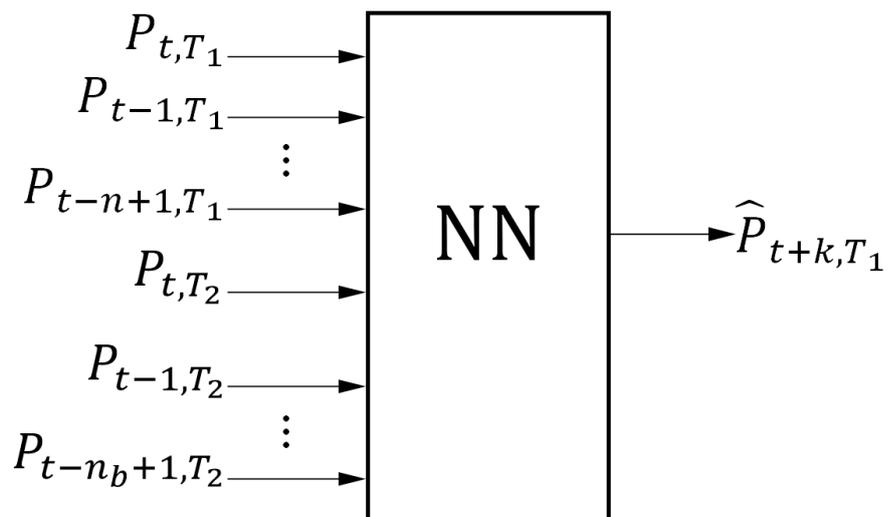
Figura 7- Diagrama representando o modelo B2



Fonte: Própria.

- Variante 2 (B3): Esta variante não leva em consideração o *delay* entre as centrais T_1 e T_2 , sendo assim, a janela de variáveis regressoras de T_2 possui n_b observações de um passado recente incluindo o instante atual t , como mostra a Figura 8. Neste caso, considera-se que ambas as centrais (barlavento e sotavento) estão sujeitas ao mesmo comportamento do vento de forma simultânea.

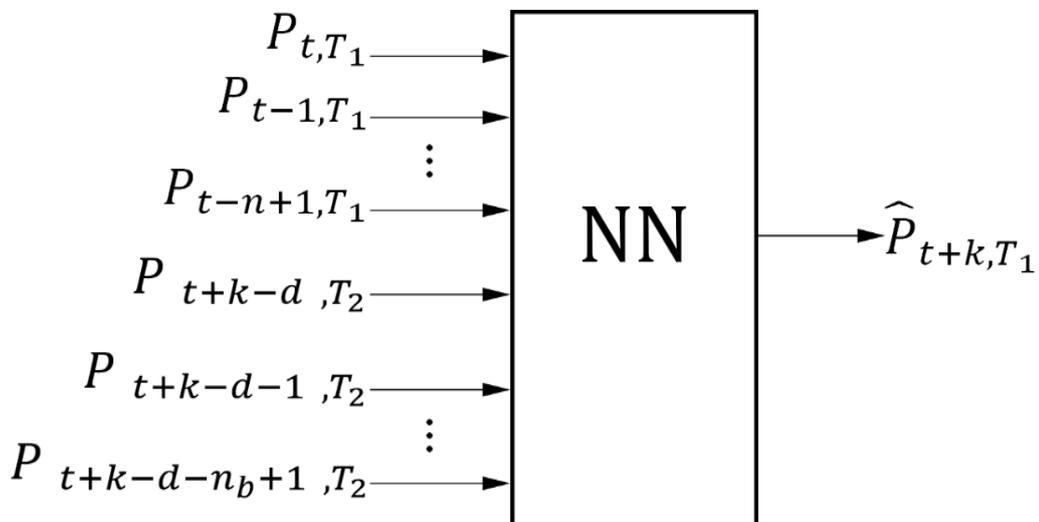
Figura 8 - Diagrama representando o modelo B3



Fonte: Própria.

- Variante 3 (B4): Assim como B2, a variante 3 também considera que o comportamento do vento observado em T_2 será observado em T_1 após um determinado *delay*, porém, no caso desta variante, o atraso d entre as centrais é aplicado com relação ao instante no qual será feita a previsão ($t + k$), de acordo com a Figura 9. Caso o horizonte de previsão k seja maior que o *delay* entre as centrais, a janela de variáveis regressora será fixada em $[t, t - 1, \dots, t - n_b + 1]$, semelhante ao que acontece em B3.

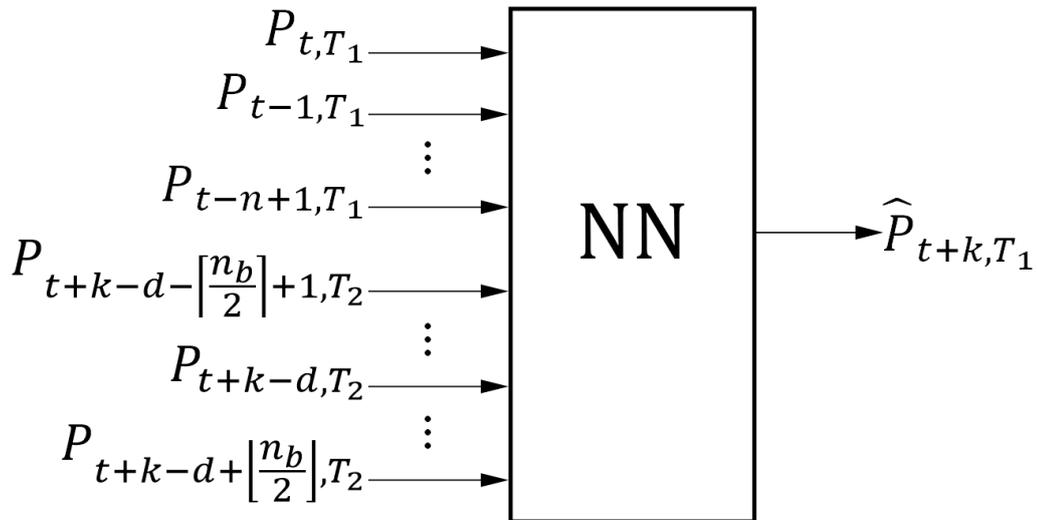
Figura 9 - Diagrama representando o modelo B4



Fonte: Própria.

- Variante 4 (B5): Assim como na variante 3, o atraso d é aplicado com relação ao instante de previsão $t + k$, porém, no caso atual, as n_b variáveis regressoras de T_2 se distribuem ao redor de $t + k - d$, como representado pela Figura 10. Cada variável regressora será multiplicada por um peso α que varia de 1 a 0,1 de acordo com a posição temporal da variável. O valor máximo ocorre no instante $t + k - d$ e, a cada afastamento deste, é decrescido de 0,1.

Figura 10 - Diagrama representando o modelo B5



Note que $\lfloor \cdot \rfloor$ e $\lceil \cdot \rceil$ representam, respectivamente, as funções piso (arredondamento para baixo) e teto (arredondamento para cima).

Fonte: Própria.

4.2 Modelos Locais

Diferente do que ocorre com os modelos globais, os modelos locais realizam o treinamento de uma rede neural diferente para cada um dos regimes identificados, possibilitando a minimização do erro de previsão nestes regimes separadamente. Apesar de possuírem diferentes métodos de identificação, três dos modelos locais classificam os regimes em três tipos: rampas de subida (*ramp-up*), rampas de descida (*ramp-down*) e regime normal (*no-ramp*). Um dos modelos classifica os regimes em grupos de faixas de potência divididos em seis grupos de rampas de descida, com gradiente local negativo, e seis grupos de rampas de subida, com gradiente local positivo. Por fim, um dos modelos locais realiza o ajuste de apenas uma rede neural, independente do regime no qual se encontra. Cada um destes modelos, bem como seus métodos de classificação, serão descritos a seguir. Anteriormente será introduzido o mecanismo identificador de regime (IR), utilizado pela maioria destes na classificação de rampas.

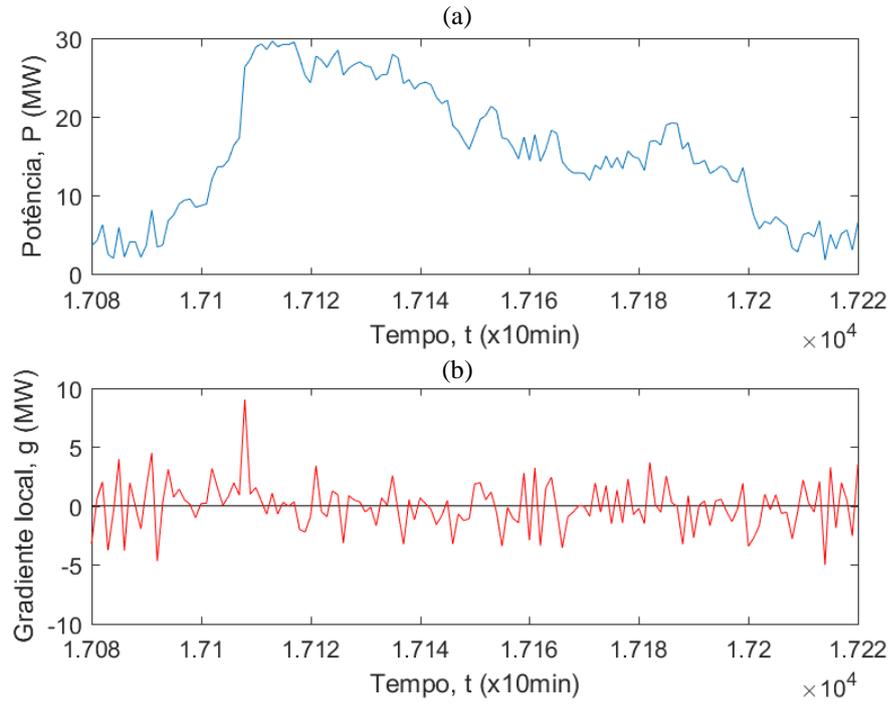
4.2.1 Mecanismo Identificador de Regime (IR)

Este mecanismo, desenvolvido ao longo deste estudo, tem como objetivo classificar o tipo de regime observado na série temporal em rampa de subida, rampa de descida ou regime normal e se baseia, exclusivamente, em uma detecção em tempo real do gradiente local do sinal (Equação 10). Sempre que o valor absoluto do gradiente g_t permanece acima de um determinado limite S_0 durante um período de tempo suficientemente longo Δt , observa-se um regime de rampa, podendo ser de subida ou de descida a depender do sinal do gradiente.

Os parâmetros S_0 e Δt não possuem valores universais que podem ser aplicados em todas as séries temporais de potência eólica. Estes fatores variam tanto com o tipo de série temporal com o qual se está trabalhando quanto com a localização da central eólica, tendo em vista que diferentes regiões experimentam regimes de vento diferentes. Sendo assim, durante a calibração, IR realiza uma análise prévia dos dados a fim de identificar as combinações de S_0 e Δt que melhor descrevem o comportamento de rampas nas regiões escolhidas para cada modelo. Vale salientar que os valores de S_0 e Δt não são necessariamente iguais para rampas de subida e rampas de descida.

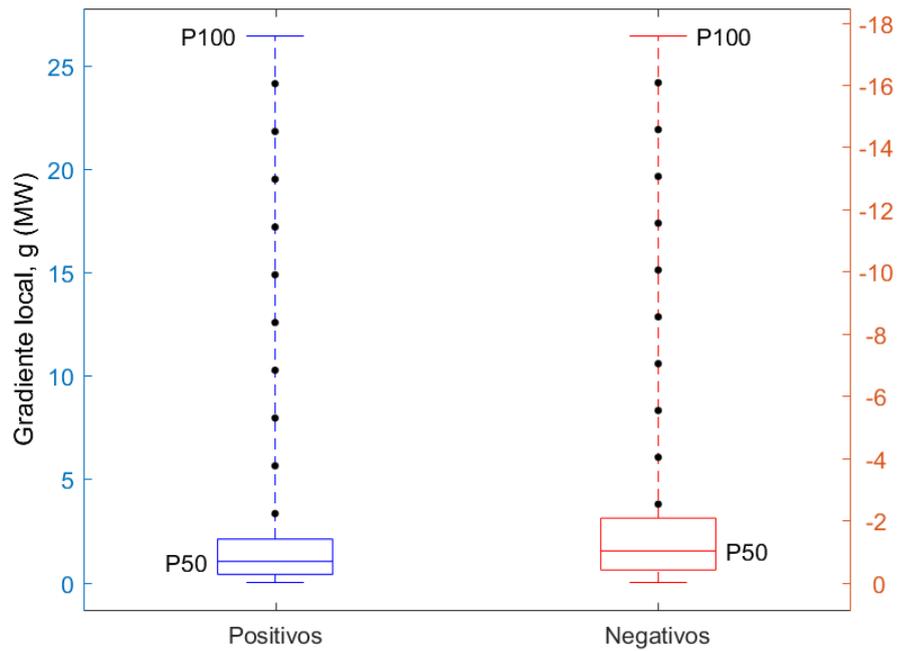
Para a determinação do limiar (S_0) das rampas de subida, IR calcula o gradiente local sobre todo o período de calibração (ver Figura 11) e isola seus valores positivos em um novo vetor. A partir daí, são determinados 10 limiares espaçados igualmente entre a mediana deste vetor (P50) e o máximo valor do gradiente (P100), como mostra a Figura 12. Cada um destes limiares (S_0) é testado para diferentes valores de Δt de modo que a combinação que forneça o menor erro de previsão será escolhida. Para as rampas de descida, é realizado o mesmo procedimento, porém utilizando os valores negativos do gradiente local.

Figura 11 – Exemplo de séries de: (a) potência; (b) gradiente local



Fonte: Própria.

Figura 12 – Exemplos de diagramas de caixa utilizados por IR para determinação do limiar



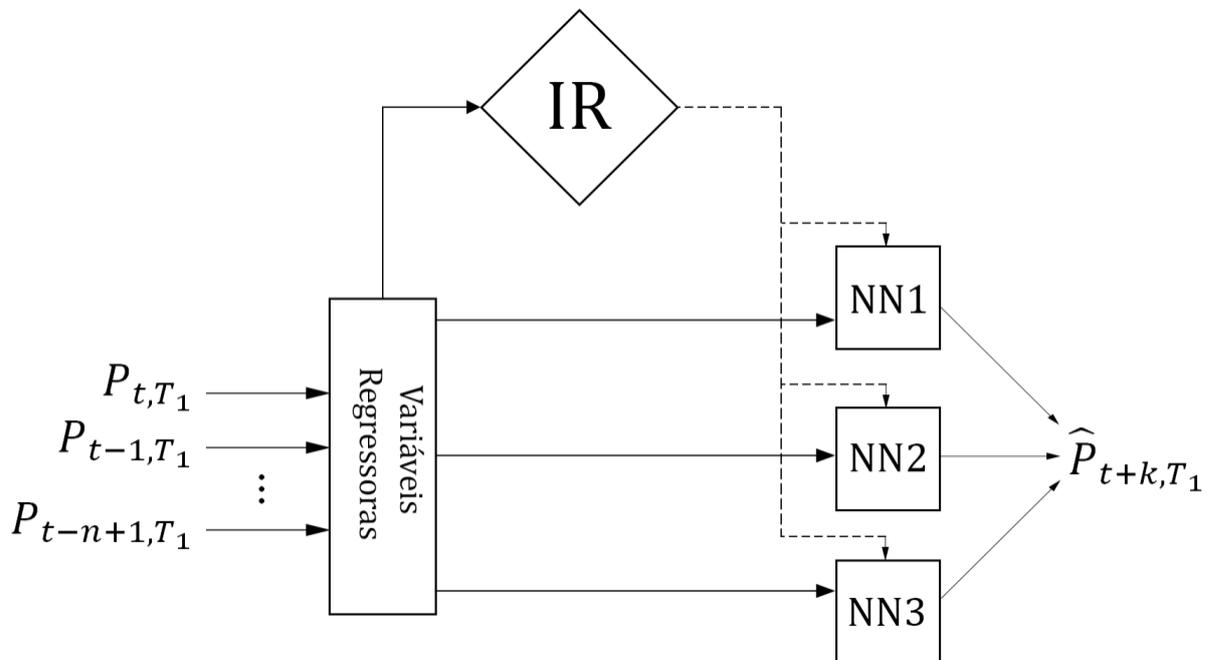
Fonte: Própria.

4.2.2 Modelo I

A arquitetura e os parâmetros do modelo I serão ajustados, separadamente, para rampas de subida, rampas de descida e regime normal, classificados através do mecanismo IR.

Assim como a Rede Neural de Ajuste Global, o ajuste da arquitetura e dos pesos sinápticos das redes neurais presentes no Modelo I (L1) é realizado utilizando, somente, um conjunto de dados observacionais da própria série temporal (T_1). Como a rede neural (NN) a ser utilizada varia de acordo com o regime identificado por IR, o número de dados de entrada n poderá variar de acordo com a rede neural utilizada. A Figura 13 ajuda a visualizar a estrutura deste modelo.

Figura 13 - Diagrama representando o modelo L1



Fonte: Própria.

4.2.3 Modelo II

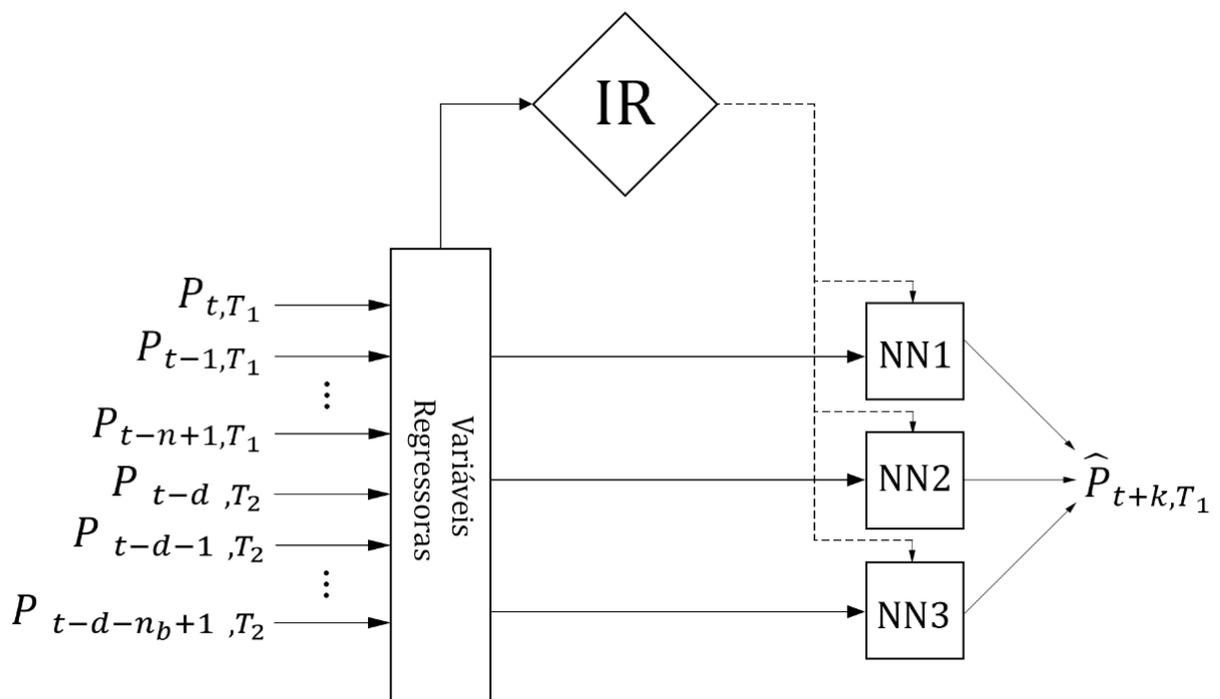
Este modelo utiliza não somente as observações da central eólica de interesse (T_1) como também introduz observações de outra central (T_2) localizada a barlavento daquela. Ainda assim, a classificação de regime deste modelo ocorre utilizando apenas os dados da central T_1 como entrada do mecanismo IR.

As informações fornecidas por T_2 são introduzidas nas redes neurais como variáveis exógenas, auxiliando a obtenção da previsão a k passos à frente na série T_1 . Serão utilizados n dados observacionais da série T_1 , com um *time-lag* de dt , e n_b dados observacionais da série T_2 , com um *time-lag* de dt_b , os quais podem variar dependendo da rede utilizada em cada regime.

O modelo em questão possui três variantes:

- Variante 1 (L2): A central T_2 contribui com n_b variáveis regressoras, as quais possuem um *delay* d com relação ao instante atual t , como mostra a Figura 14.

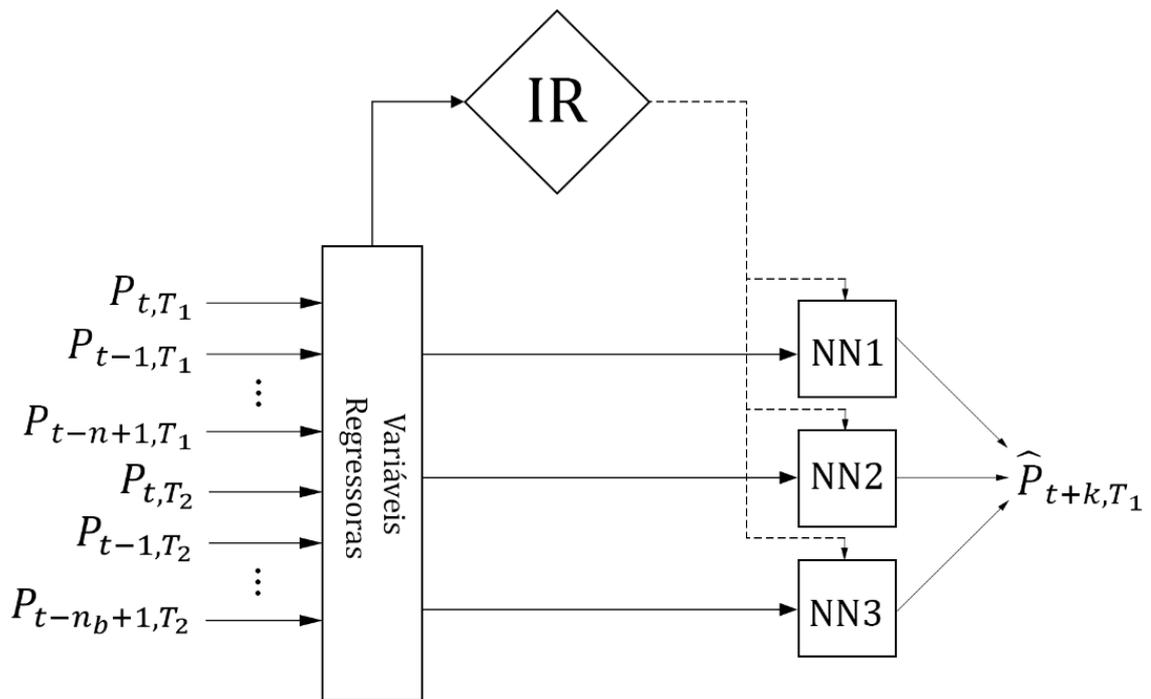
Figura 14 - Diagrama representando o modelo L2



Fonte: Própria.

- Variante 2 (L3): Nesta variante, o *delay* (d) entre as centrais não é levado em consideração. Dessa forma, a entrada das redes neurais será composta pelas n_b observações mais recentes, de acordo com a Figura 15, a seguir.

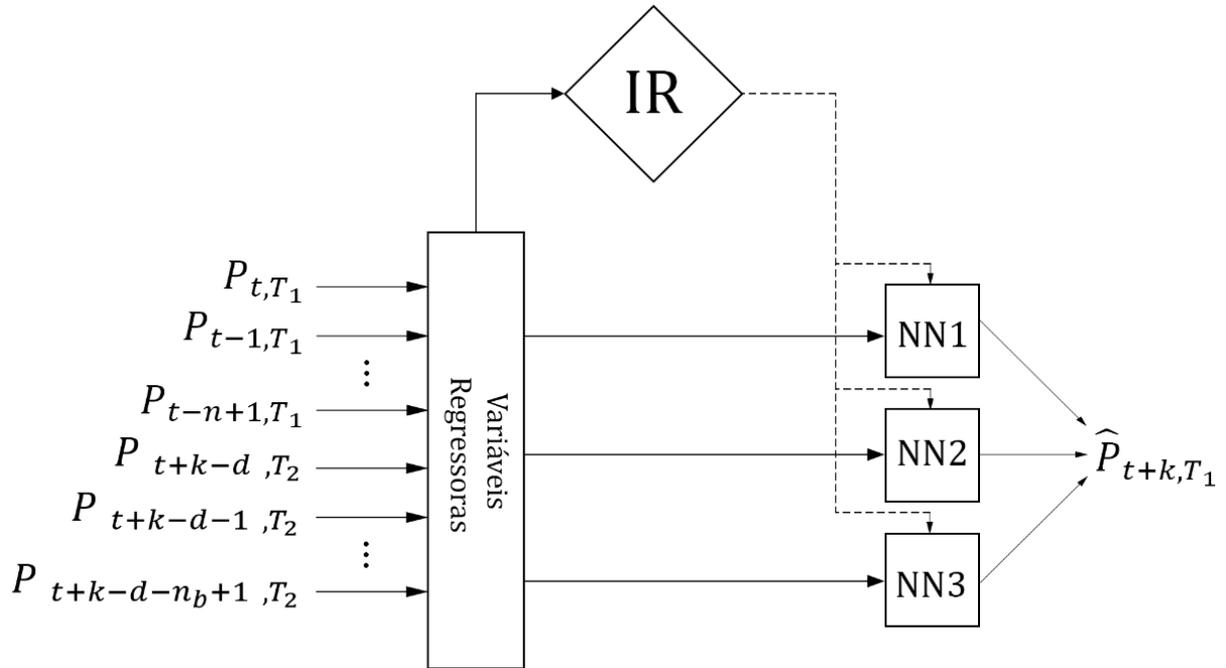
Figura 15 - Diagrama representando o modelo L3



Fonte: Própria.

- Variante 3 (L4): Assim como o modelo B4, o *delay* (d) é aplicado com relação ao instante alvo $t + k$, como mostra a Figura 16. Para horizontes de previsão k maiores que o *delay* (d), as entradas das redes serão fixadas em $[t, t - 1, \dots, t - n_b + 1]$, como em L3.

Figura 16 - Diagrama representando o modelo L4



Fonte: Própria.

4.2.4 Modelo III

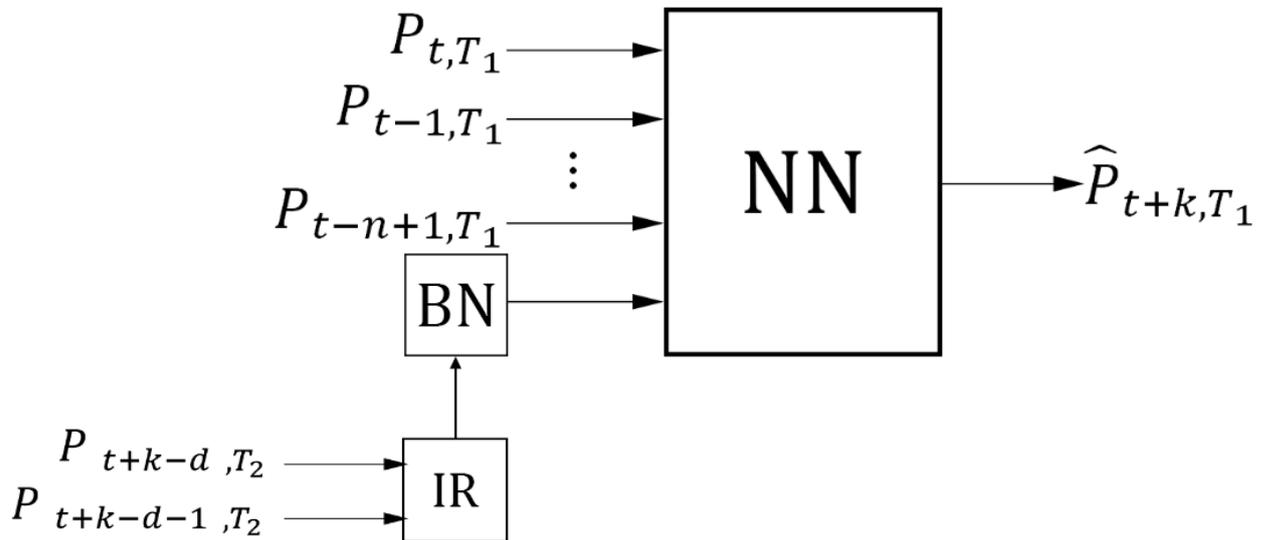
O modelo III (L5), semelhante ao modelo II, utiliza uma variável exógena para auxiliar a previsão do comportamento da série temporal T_1 . Porém, neste caso, esta variável consiste em uma inferência probabilística dos possíveis estados de T_1 em um horizonte k . Tal inferência é obtida a partir de uma rede bayesiana (BN), a qual relaciona as dependências condicionais entre regimes de T_1 e os regimes de uma central eólica a barlavento do local de interesse (T_2).

Este modelo parte do princípio de que é possível estimar o tipo de regime ao qual a central a sotavento será submetida, após um *delay* d , observando o regime atuante na central a barlavento. A Figura 17 apresenta uma representação do modelo III.

As tabelas de probabilidade de BN são calculadas durante o período de calibração a partir dos regimes (rampa de subida, rampa de descida ou regime normal) observados em T_2 (nó “pai”) e T_1 (nó “filho”), os quais são determinados pela função IR. Durante a validação, IR alimenta a rede bayesiana (BN) com o regime de T_2 no

instante $t + k - d$ e esta, por sua vez, entrega, como entrada da rede neural, as probabilidades da central T_1 estar em cada um dos três regimes.

Figura 17 - Diagrama representando o modelo L5

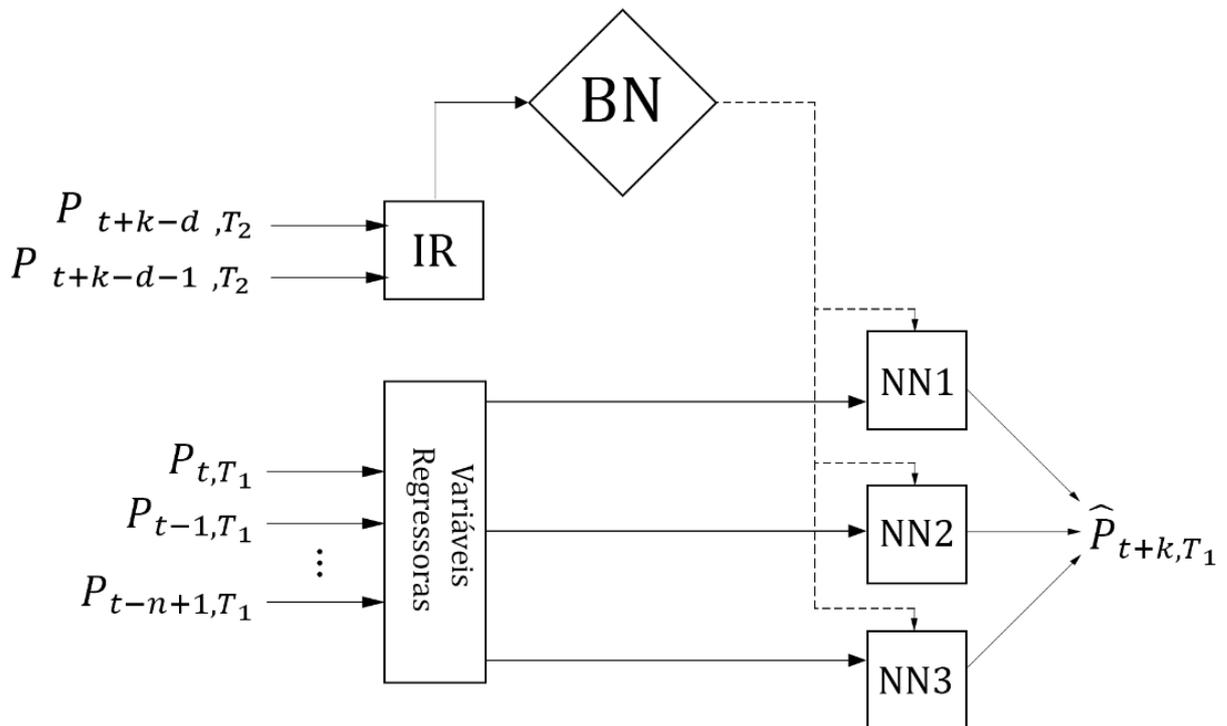


Fonte: Própria.

4.2.5 Modelo IV

O modelo IV (L6), assim como o modelo I, utiliza, como variáveis de entrada, apenas os dados observacionais da central de interesse (T_1), porém, este modelo realiza a seleção de regime a partir de uma rede bayesiana. Semelhante ao que ocorre no modelo III, a rede bayesiana recebe como entrada o regime observado em T_2 no instante $t + k - d$ e entrega a inferência probabilística dos possíveis regimes de T_1 no instante $t + k$. O diagrama da Figura 18 é a representação do modelo IV.

Figura 18 - Diagrama representando o modelo L6



Fonte: Própria.

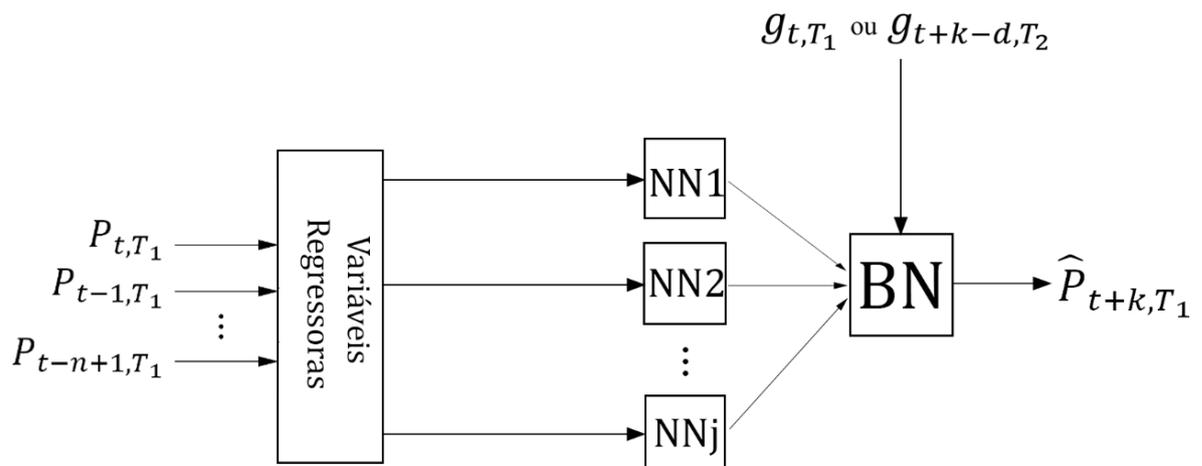
4.2.6 Modelo V

Partindo do princípio que rampas com inclinações diferentes possuem características diferentes, o modelo em questão, cuja estrutura está representada pela Figura 19, calcula o gradiente local da série temporal e organiza seus valores em faixas de potência, classificadas de acordo com seu percentual da potência nominal da central de interesse. Para as rampas de subida, são criados 5 grupos de potência variando de 0 a 50% da potência nominal, em passos de 10%, e um sexto grupo para gradientes acima de 50%. As rampas de descida possuem um procedimento semelhante, porém, como os gradientes possuem valores negativos, 5 grupos se dividem entre 0 a -50% e um sexto grupo recolhe os gradientes abaixo de -50% da potência nominal.

É treinada, então, uma NN para cada faixa de potência, de forma que o resultado final será o somatório das saídas de cada uma dessas redes ponderado pela inferência Bayesiana. Esse modelo possui duas variantes:

- Variante 1 (L7): As inferências da rede bayesiana são feitas utilizando o gradiente local dos dados de potência da central a barlavento (T_2) observado no instante $t + k - d$.
- Variante 2 (L8): A rede bayesiana utiliza, como entrada, o gradiente local da própria série temporal (T_1) observado no instante t .

Figura 19 - Diagrama representando os modelos L7 e L8



Fonte: Própria.

5 RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados relativos a 4 diferentes estudos de caso envolvendo centrais eólicas localizadas no Nordeste Brasileiro. As avaliações serão realizadas para regimes de rampa de subida e rampa de descida separadamente, tendo em vista que tais eventos possuem características distintas, portanto, não devem ser avaliados de forma conjunta (ELA e KEMPER, 2009; KAMATH, 2010; GALLEGO et al., 2011a; HECKENBERGEROVA et al., 2014). A Tabela 2 apresenta a média e o desvio padrão dos eventos de rampa de subida e dos eventos de rampa de descida normalizados pela potência nominal de cada central, bem como o Coeficiente de Variação (CV) destes eventos, que, por sua vez, pode ser definido como a razão entre o desvio padrão e a média aritmética da série temporal. Observa-se que, em geral, os dados observacionais em eventos de rampa são pouco homogêneos, tendo em vista que, na maioria dos casos, o CV superou os 40%.

Tabela 2 – Média, desvio padrão e coeficiente de variação das rampas correspondentes às centrais a sotavento

Central	Evento	Média, μ (%)	Desvio, σ (%)	CV (%)
G4	Rampa de subida	46,06	18,97	41,19
	Rampa de descida	31,78	17,90	56,32
G13	Rampa de subida	57,20	19,92	34,83
	Rampa de descida	38,80	20,08	51,75
G8	Rampa de subida	61,23	17,71	28,92
	Rampa de descida	42,96	17,89	41,64
G7	Rampa de subida	58,10	23,43	40,33
	Rampa de descida	42,84	23,59	55,07

5.1 Determinação do *delay* entre as centrais

Dos 13 modelos apresentados anteriormente, 10 fazem uso dos dados observacionais da central localizada a barlavento da central de interesse, dentre os quais, 7 modelos se veem diretamente influenciados pelo atraso (*delay*) entre as centrais. Sendo assim, é essencial que, durante a definição dos parâmetros, seja escolhido um *delay* adequado, de forma a maximizar a acurácia dos modelos.

Para a definição do *delay*, foram utilizadas três abordagens:

- Consistência física: O *delay* é determinado a partir da distância entre as centrais e da velocidade média do vento;
- Correlação: Calcula-se o coeficiente de correlação entre as séries de validação das duas centrais para diferentes *delays*, de forma a determinar qual *delay* fornece a maior correlação entre as centrais;
- Matriz de confusão: Uma matriz de confusão (ou matriz de classificação) é criada relacionando os instantes em que ocorre rampa e não rampa nas centrais a sota e a barlavento para diferentes *delays*. É, então, escolhido o *delay* que maximiza os *hits* rampa-rampa (RR), ou seja, observa-se regime de rampa tanto na central a barlavento quanto na central a sotavento.

Os cálculos destas abordagens são descritos a seguir para cada grupo de centrais.

5.1.1 Grupo A

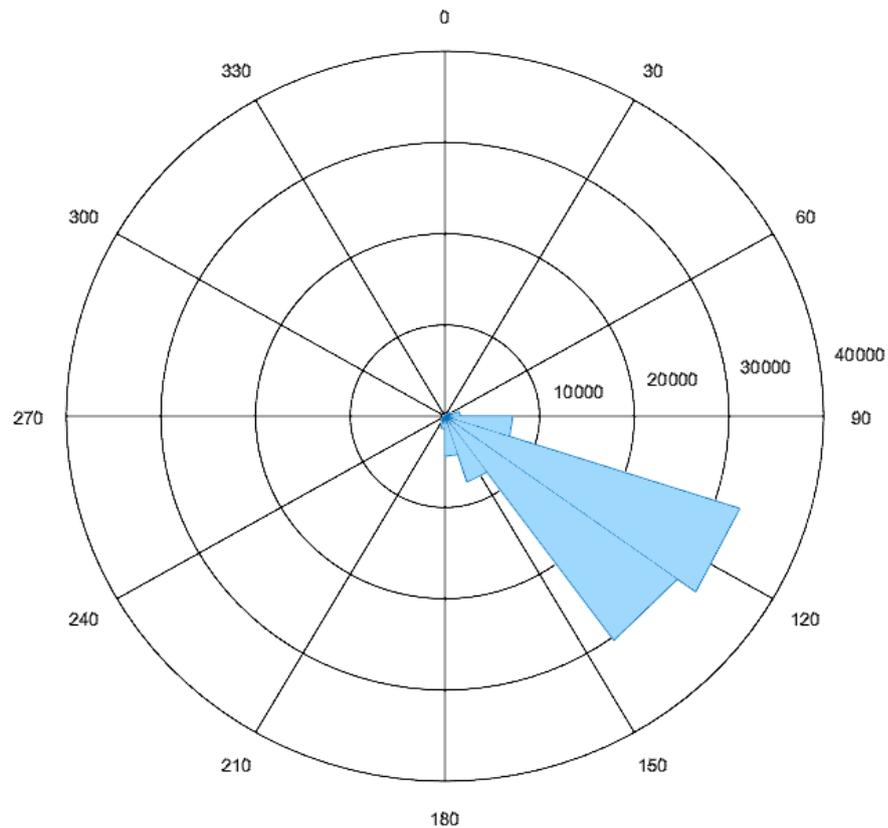
Pode-se verificar, de acordo com as localizações das centrais G4 e G6 (Figura 5) e da direção predominante do vento (Figura 20), que a central G4 está localizada a sotavento da central G6. O Apêndice A contém as séries temporais relativas a este grupo.

As duas centrais estão distanciadas de cerca de 187 km e as velocidades médias do vento observadas na central G4 é de 13,4 m/s e na central G6 é de 9,2 m/s. Tomando a velocidade média entre as duas centrais como 12,16 m/s, teremos que o *delay* físico será de 4,3h, equivalente a cerca de 26 *time-steps*.

Quanto à abordagem de correlação, variou-se o *delay* de 1 a 40 *time-steps* e calculou-se o coeficiente de correlação entre as centrais G4 e G6 para cada *delay*, gerando a curva apresentada na Figura 21. Observa-se que a máxima correlação (destacada em preto) entre as duas centrais é de apenas 0,3945 e ocorre com um *delay* de 13 *time-steps*.

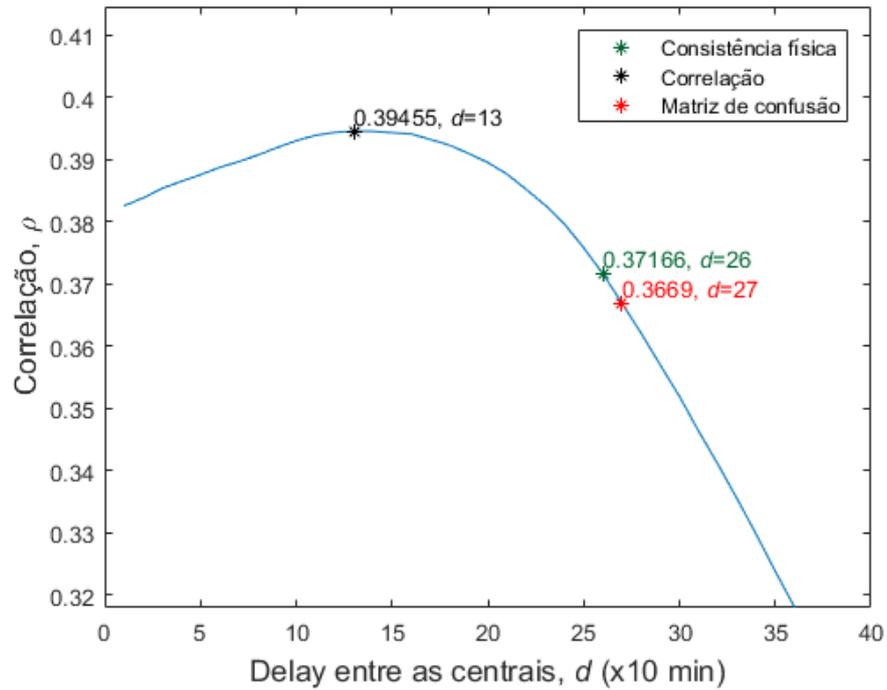
A curva da Figura 22 apresenta a taxa de *hits* rampa-rampa (RR), para diferentes *delays*, calculada a partir de uma matriz de confusão. Esta taxa corresponde ao número de instantes em que é possível observar um evento de rampa na central a barlavento e na central a sotavento, de forma concomitante, quando distanciadas por um *delay* d , normalizado pelo número de eventos de rampa observados na central a sotavento. Podemos observar que a máxima taxa RR ocorre quando aplicado um *delay* de 27 *time-steps* e corresponde a 10,326% do total de rampas observadas em G4.

Figura 20 - Rosa dos ventos a partir dos dados de direção observados em G6



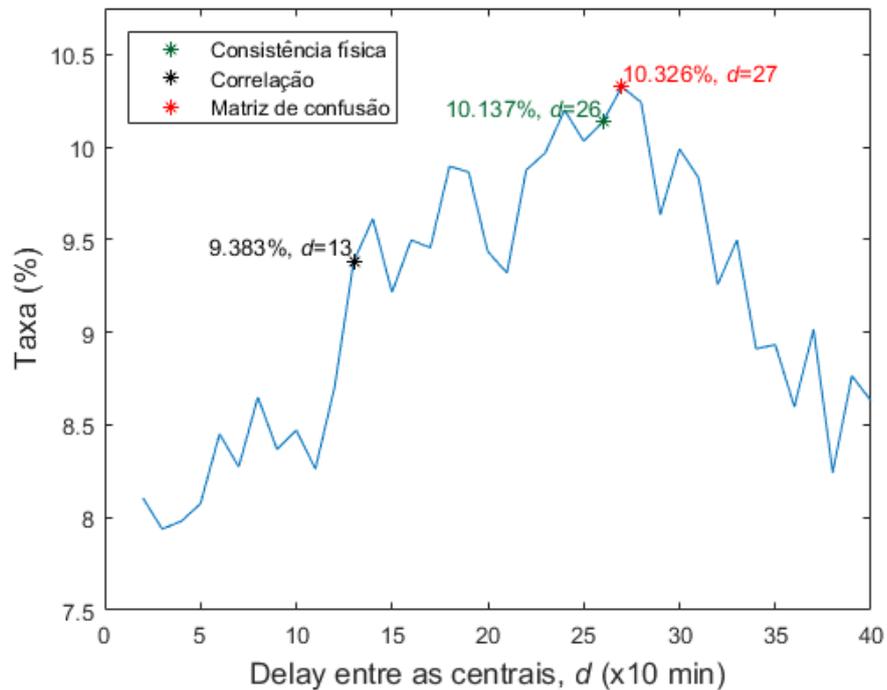
Fonte: Própria.

Figura 21 – Correlação entre as centrais G4 e G6 para diferentes *delays*



Fonte: Própria.

Figura 22 – Taxa de rampa-rampa entre G4 e G6 para diferentes *delays*



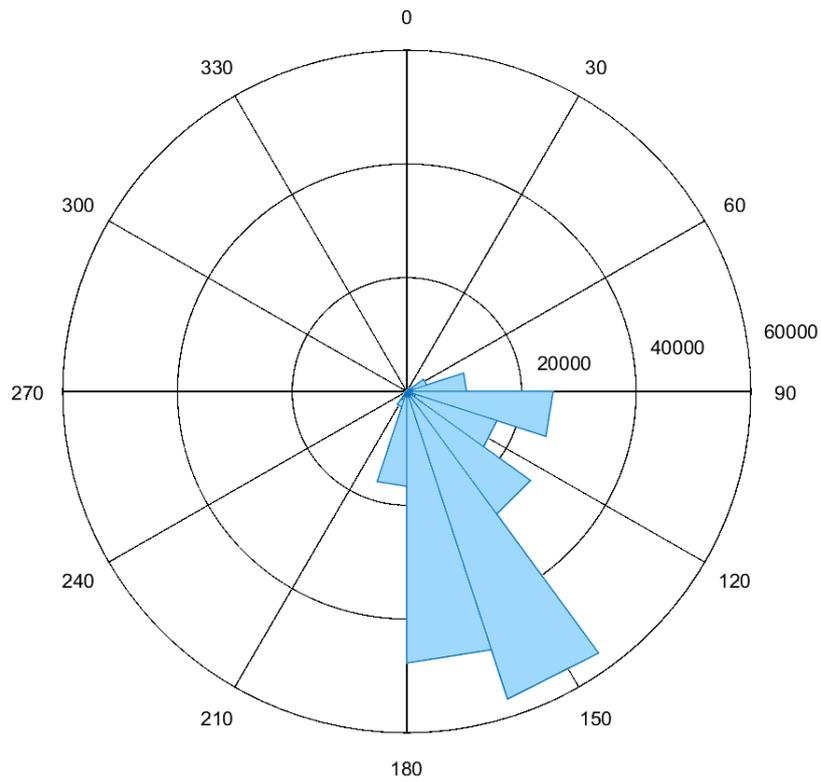
Fonte: Própria.

5.1.2 Grupo B

De acordo com as posições das centrais G1 e G13 (Figura 5) e da direção predominante do vento obtido com dados observacionais da central G1 (Figura 23), foi observado que a central G1 está localizada a barlavento da central G13. Sendo assim, os modelos desenvolvidos nesse estudo foram treinados para realizar a previsão das potências de saída da central G13, alguns deles utilizando, também, as saídas da central G1. As séries temporais referentes a essas centrais são apresentadas no Apêndice A.

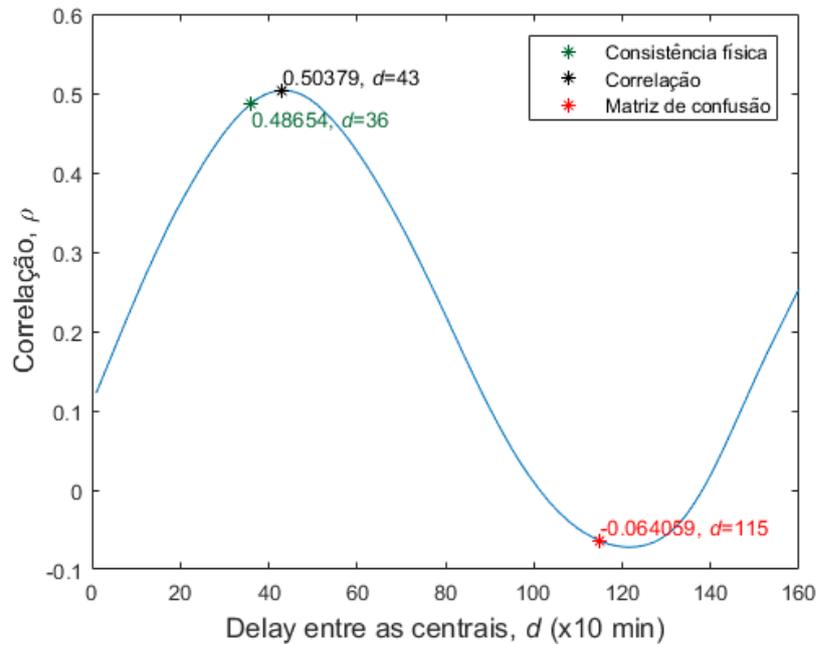
O *delay* físico entre as centrais foi calculado a partir da distância aproximada de 159 km e a velocidade média observada na central G1 de 7,47 m/s, o que nos dá uma distância temporal de 6h, ou seja, 36 *time-lags*. Os *delays* de máxima correlação ($d = 43$) e máxima taxa de RR ($d = 115$), apresentados nas Figuras 24 e 25, respectivamente, foram obtidos através do mesmo procedimento descrito na seção anterior. Observa-se que o *delay* obtido através da matriz de confusão é muito maior que os obtidos através das outras abordagens, o que aparenta ser incoerente tendo em vista que tal *delay* está associado a uma correlação entre as centrais negativa e muito próxima a zero. Esse resultado pode indicar que a maior parte das rampas observadas nas centrais G1 e G13 são causadas por fenômenos da microescala (da ordem de centenas de metros) e, portanto, não há relação entre os eventos de rampa destas duas centrais.

Figura 23 – Rosa dos ventos a partir dos dados de direção observados em G1



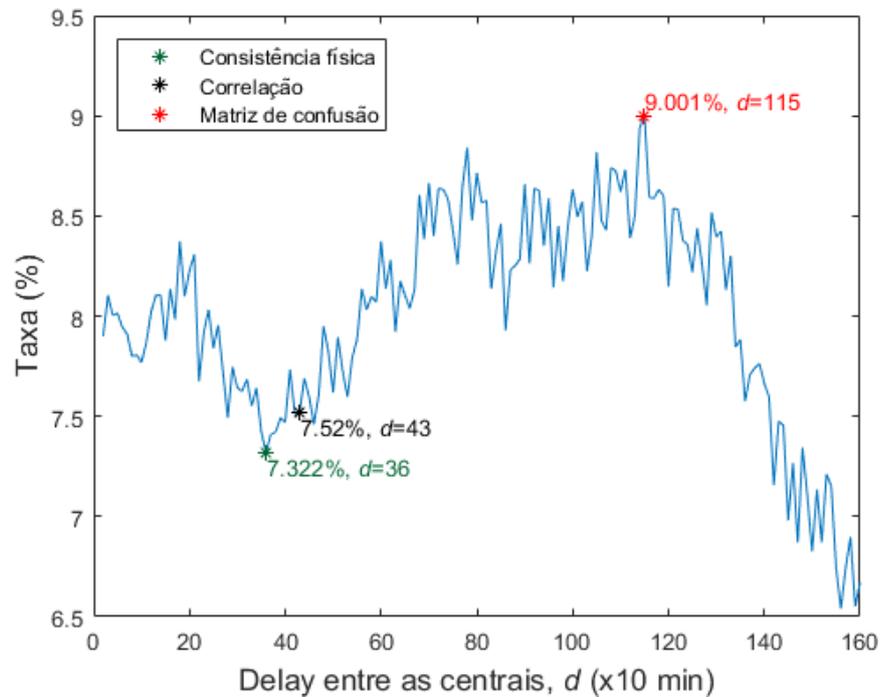
Fonte: Própria.

Figura 24 – Correlação entre as centrais G13 e G1 para diferentes *delays*



Fonte: Própria.

Figura 25 - Taxa de rampa-rampa entre G13 e G1 para diferentes *delays*



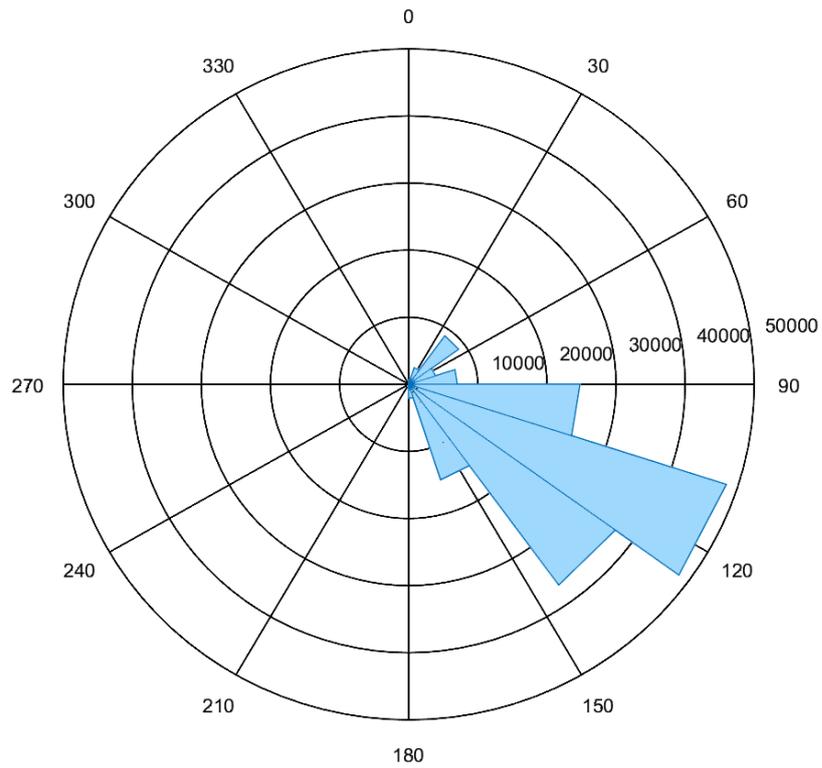
Fonte: Própria.

5.1.3 Grupo C

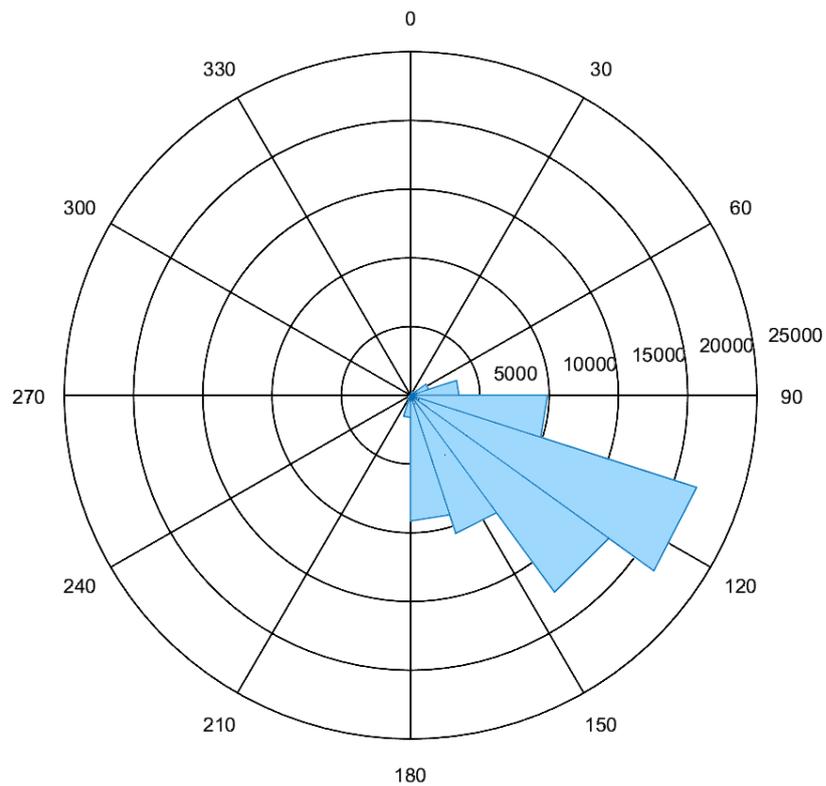
Observando a direção predominante do vento apresentada nas Figuras 26 e 27, verificamos que a central G11 encontra-se a barlavento da central G8 (ver Figura 5). O Apêndice A apresenta as séries temporais relativas a estas centrais.

A distância entre as G8 e G11 é de cerca de 51 km e as velocidades médias de ambas as centrais é de aproximadamente 7,5 m/s, o que nos fornece um *delay* físico de 1,9h, equivalente a 12 *time-steps*. Ao calcularmos a correlação entre as centrais para diferentes *delays*, observamos que a maior correlação também ocorre com o *delay* de 12, com o valor de 0,5042, em verde na Figura 28. Observa-se, ainda, que o coeficiente de correlação varia muito pouco em função do *delay* (terceira casa decimal).

A partir do gráfico da taxa de rampa-rampa para diferentes *delays* (Figura 29), vemos que o *delay* 13 apresenta a maior porcentagem de acertos rampa-rampa, valor muito próximo ao *lag* 12, obtido pelos métodos físico e de correlação. A diferença de taxa de acertos também é muito pequena entre esses dois *lags*: apenas 0,74%.

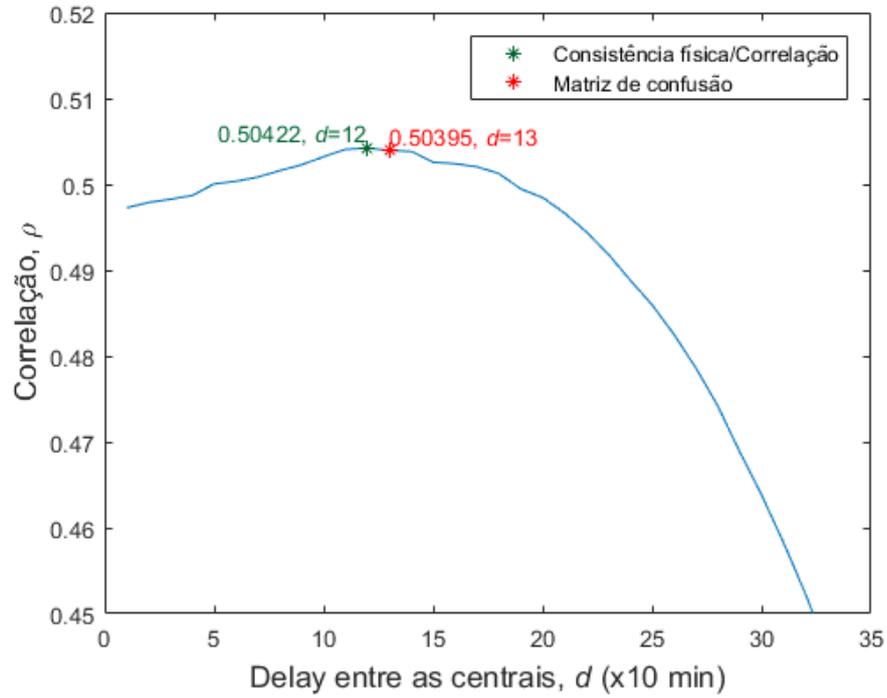
Figura 26 – Rosa dos ventos a partir dos dados de direção observados em G8

Fonte: Própria.

Figura 27 – Rosa dos ventos a partir dos dados de direção observados em G11

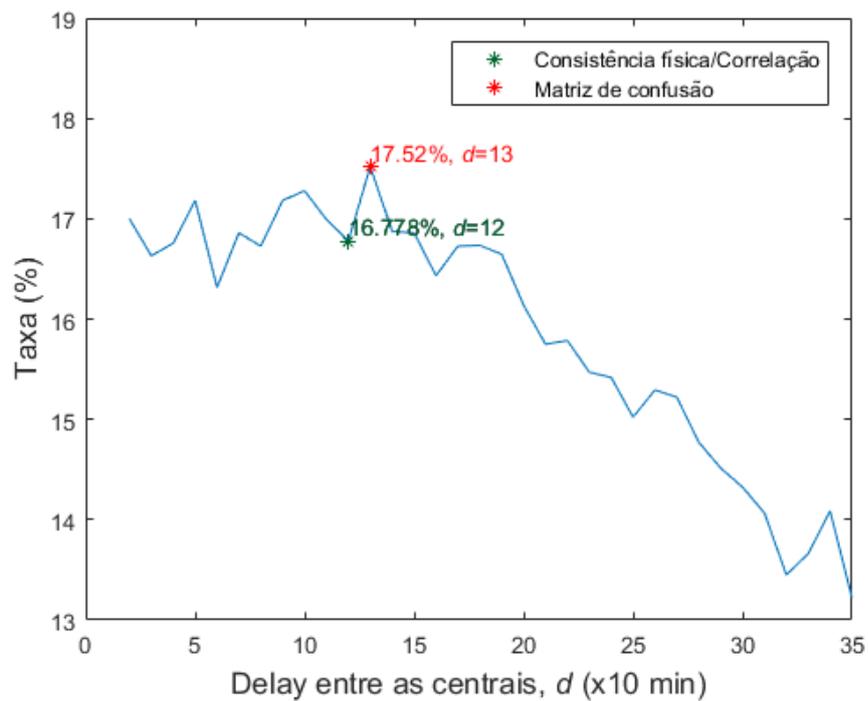
Fonte: Própria.

Figura 28 – Correlação entre as centrais G8 e G11 para diferentes *delays*



Fonte: Própria.

Figura 29 – Taxa de rampa-rampa entre G8 e G11 para diferentes *delays*



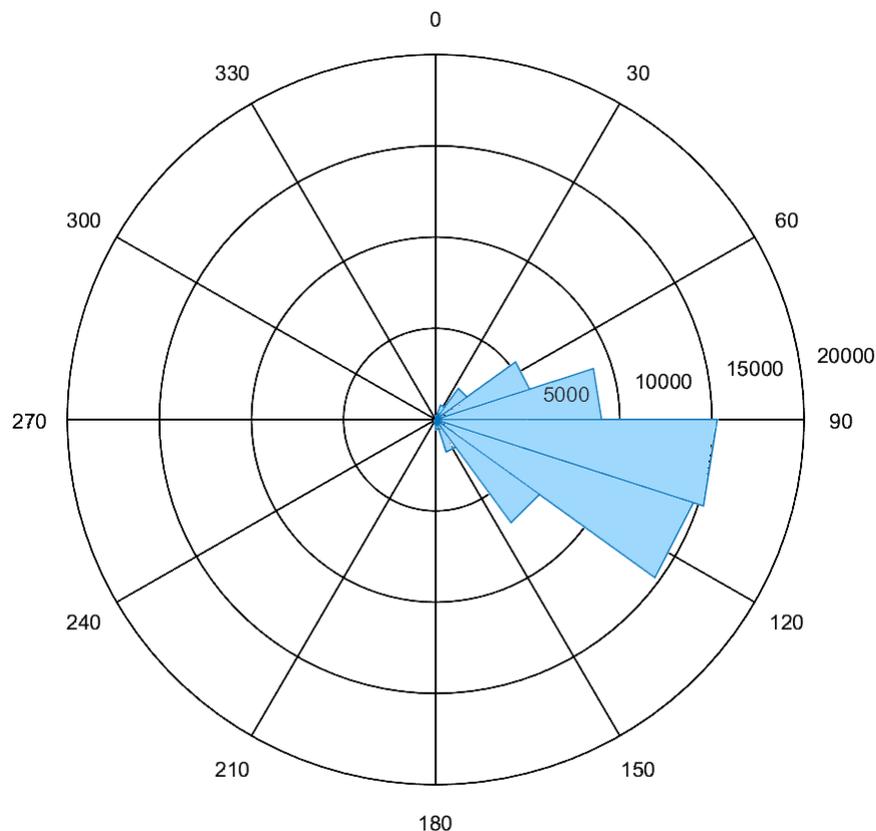
Fonte: Própria.

5.1.4 Grupo D

A partir da localização das centrais G7 e G10 (Figura 5) e da direção predominante do vento na central G10 (Figura 30), podemos observar que G10 se encontra a barlavento de G7. Sendo assim, utilizaremos dados observacionais de ambas as centrais para realizar a previsão da potência de saída da central G7. As séries temporais relativas a G7 e G10 estão contidas no Apêndice A.

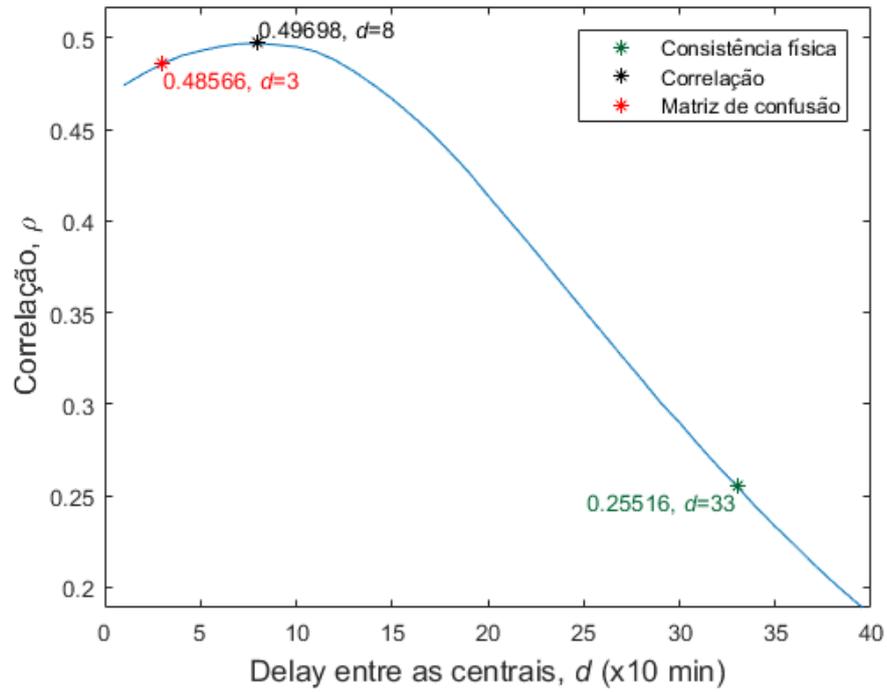
Para o cálculo do *delay* físico, de 33 *time-steps*, foram utilizadas a distância aproximada entre as centrais, de 155 km, e a velocidade média do vento, de 7,82 m/s, calculada a partir de dados observacionais de G10. A partir do cálculo de correlação entre os dados das duas centrais para diferentes *delays* (Figura 31), obteve-se que a maior correlação é de 0,497 e ocorre com um *delay* de 8 *time-steps*. Finalmente, através de uma matriz de confusão, foi calculado o *delay* de 3 *time-steps* que proporciona a maior taxa de *hits* rampa-rampa entre as centrais, destacado em vermelho na Figura 32.

Figura 30 – Rosa dos ventos a partir dos dados de direção observados em G10



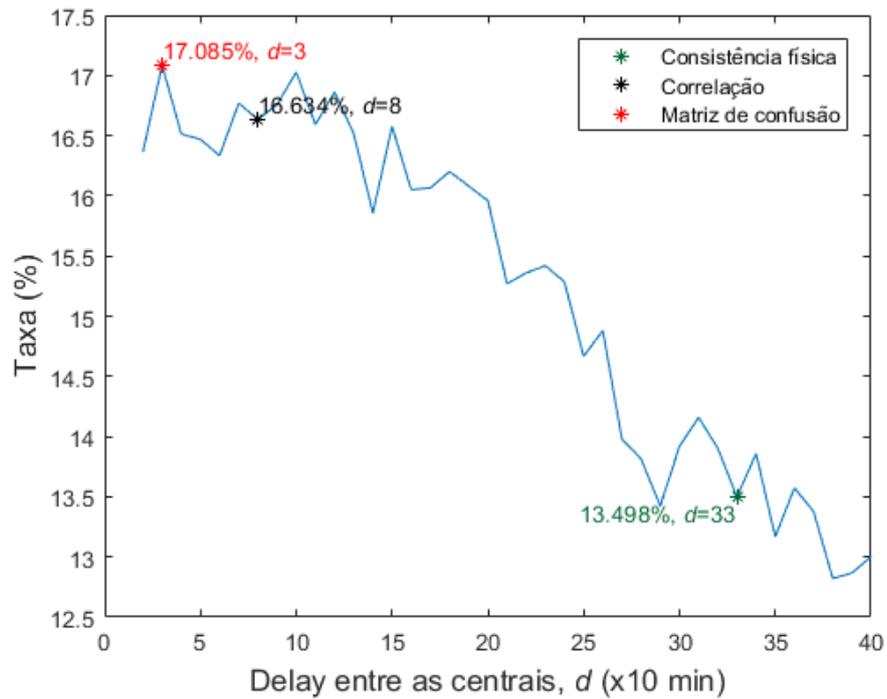
Fonte: Própria.

Figura 31 - Correlação entre as centrais G7 e G10 para diferentes *delays*



Fonte: Própria.

Figura 32 - Taxa de rampa-rampa entre G7 e G10 para diferentes *delays*



Fonte: Própria.

A Tabela 3 apresenta, de forma conjunta, os *delays* calculados para cada grupo de centrais. Os valores destacados com asterisco representam os *delays* finais de cada grupo, cujos resultados associados obtiverem maior acurácia quando aplicados aos modelos.

Tabela 3 – Delays calculados para cada grupos de centrais (em *time-steps* de 10 min)

Grupo	Consistência Física	Correlação	Matriz de Confusão
A	26	13*	27
B	36	43*	115
C	12	12	13*
D	33	8	3*

* *delays* finais de cada grupo.

5.2 Rampas de Subida

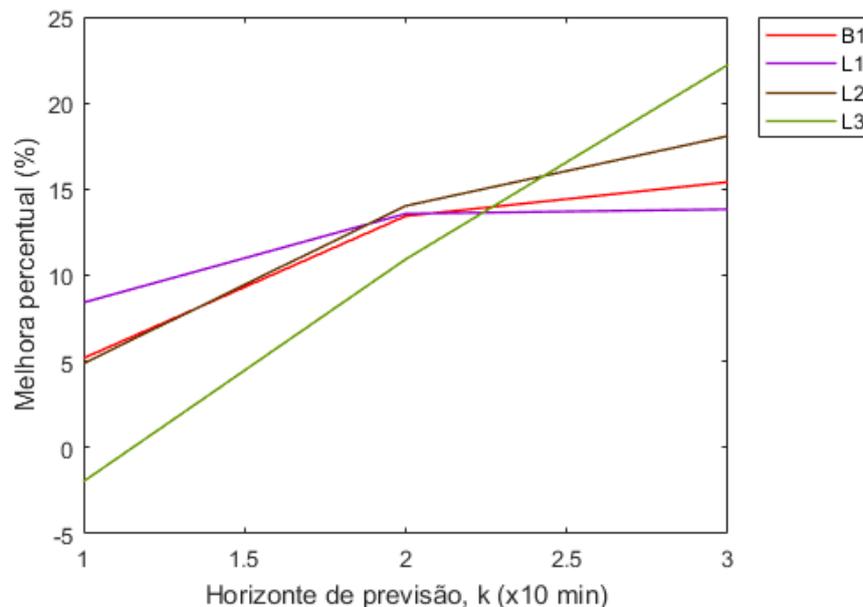
A seguir, serão apresentados os gráficos de melhora sobre a persistência (IoP) comparando os modelos globais e locais sobre as rampas de subida nos grupos de centrais estudados (Figuras 33 a 36).

Em geral, durante as rampas de subida, os modelos apresentam um comportamento crescente (Figuras 33, 34 e 36), ou seja, sua IoP aumenta conforme o horizonte de previsão avança. Apesar de ainda não se saber ao certo como se comportam as rampas de subida, os modelos em questão apresentaram comportamento de acordo com o que é esperado para modelos baseados em séries temporais (*Time Series Based Models – TSBM*), visto que a série temporal tende a ficar menos persistente conforme o horizonte de previsão aumenta. Em contrapartida, quando aplicados à central G8 (Figura 35), os modelos possuem um comportamento fora do padrão, entregando IoPs com um leve decréscimo no segundo horizonte seguidas de uma elevação considerável no horizonte seguinte. Apenas o modelo L3 possui comportamento inverso, com um grande pico no segundo horizonte seguido de um notável decaimento no terceiro horizonte. Mesmo com este decréscimo no

terceiro horizonte, o modelo L3 ainda se mantém na vanguarda quanto aos demais modelos, fato que se repete para as centrais G4 (Figura 33) e G7 (Figura 36).

Observa-se, na Figura 33, que nenhum modelo é destaque em todos os horizontes de previsão na central G4. No primeiro horizonte, o modelo L1 supera os demais com uma IoP aproximada de 8%. Já no segundo horizonte, os modelos B1, L1 e L2 apresentam resultados muito próximo, de aproximadamente 14% de melhora. Finalmente, no terceiro horizonte, vemos um salto considerável na IoP de L3, chegando a cerca de 22%. Ainda, dentre os modelos globais, percebe-se que apenas B1, o qual não utiliza dados da central a barlavento, apresentou resultados satisfatórios. Tal comportamento pode ser um resultado conjunto da baixa correlação entre as duas centrais, da baixa incidência de *hits* rampa-rampa e da qualidade dos dados relativos à central G6 (localizada a barlavento de G4), cuja potência é diversas vezes limitada a valores muito abaixo da potência nominal, provavelmente devido a estratégias de controle por parte do operador (ver Apêndice A). Por utilizar toda a série temporal para realizar o ajuste dos parâmetros, os modelos globais que utilizam informações a respeito da central G6 se veem muito mais afetados pela baixa qualidade dos dados.

Figura 33 - Melhora sobre a persistência sobre as rampas de subida de G4



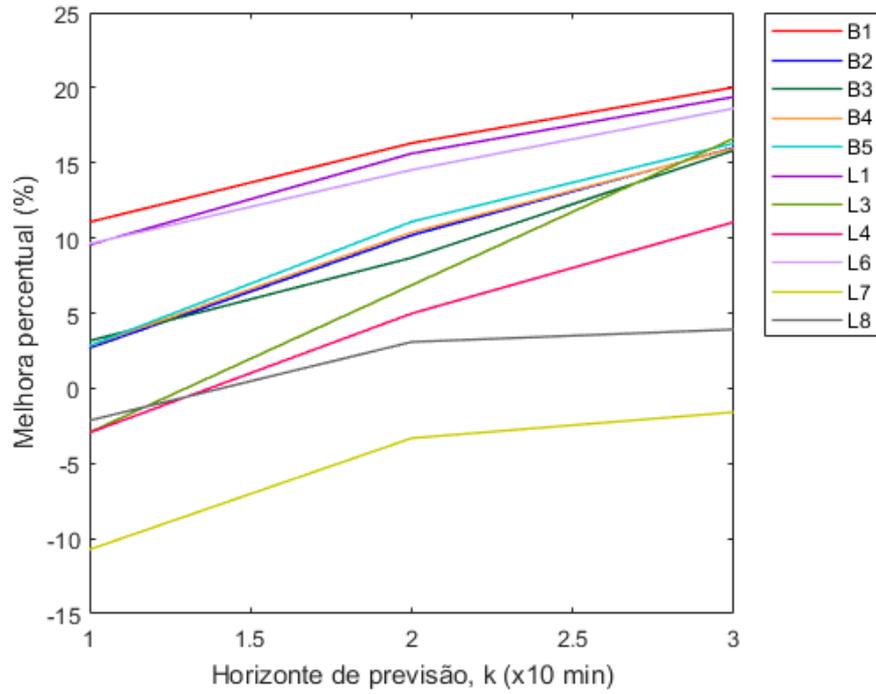
Fonte: Própria.

No caso da central G13 (Figura 34), podemos verificar que os modelos B1, L1 e L6 apresentaram resultados muito semelhantes entre si, partindo de uma melhora de cerca de 10% no primeiro horizonte para 20% no terceiro horizonte. Tais resultados se mostraram muito superiores aos apresentados pelos demais modelos, o que indica que a introdução de dados da central a barlavento como variáveis regressoras não fornece informação favorável à previsão das redes neurais. Este comportamento pode ser resultado da baixa correspondência de rampas entre as centrais a barlavento e a sotavento para o *delay* utilizado, o qual entrega uma taxa de *hits* rampa-rampa de apenas 7,5%.

Apesar de possuírem um comportamento fora do comum para a central G8, os modelos apresentados na Figura 35 entregam valores de melhora sobre a persistência bastante elevados. O modelo B1 apresenta uma IoP de aproximadamente 33% no primeiro horizonte. Já nos segundo e terceiro horizonte, o modelo L3 supera os demais chegando a quase 45% de melhora, no segundo horizonte e cerca de 35% no terceiro horizonte.

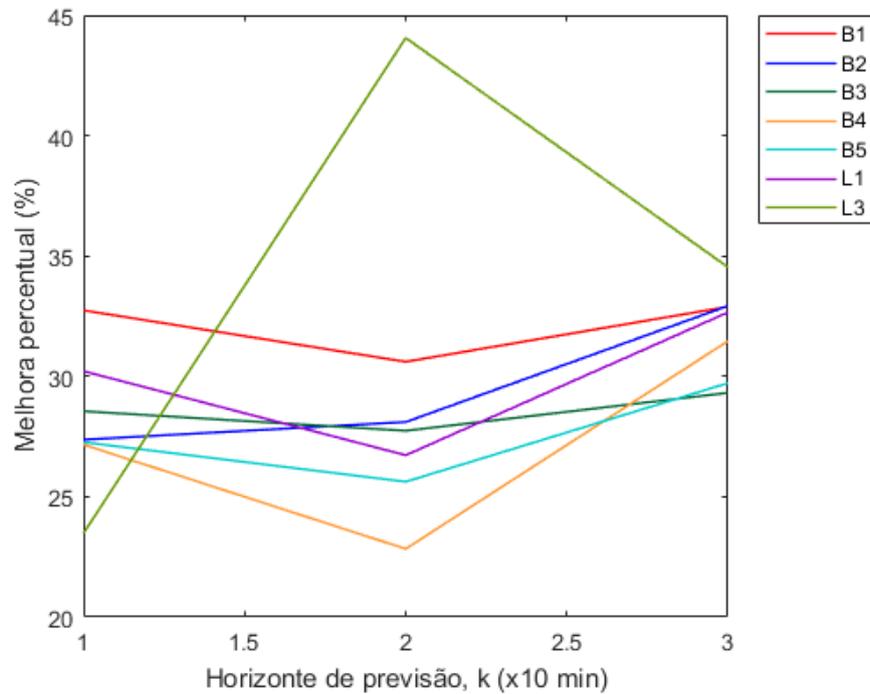
Com respeito à central G7 (Figura 36), os modelos apresentam um comportamento crescente, alcançando melhoras sobre a persistência bastante elevadas. Nos primeiro e segundo horizontes, destaca-se o modelo B3, atingindo melhoras um pouco maiores que 25%. No terceiro horizonte, o modelo L3 apresenta um crescimento bastante elevado e toma a dianteira, chegando a quase 40% de IoP.

Figura 34 - Melhora sobre a persistência sobre as rampas de subida de G13



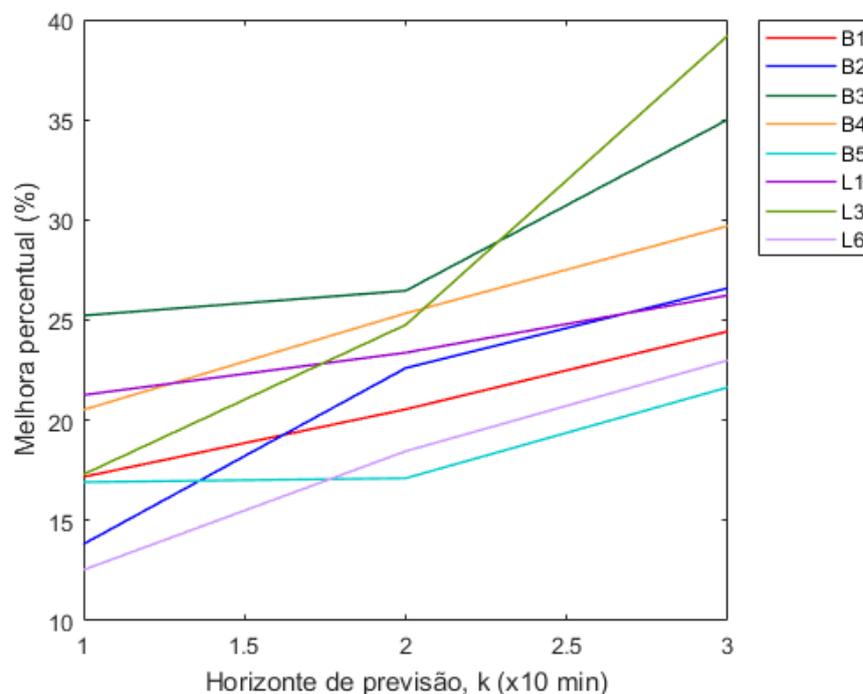
Fonte: Própria.

Figura 35 - Melhora sobre a persistência sobre as rampas de subida de G8



Fonte: Própria.

Figura 36 - Melhora sobre a persistência sobre as rampas de subida de G7



Fonte: Própria.

No entanto, não é prudente avaliar a precisão dos modelos utilizando exclusivamente a melhora sobre a persistência, pois tal critério de avaliação baseia-se somente no MSE. Sendo assim, utilizaremos, também, diagramas de Taylor para avaliar, de forma simultânea, a correlação, o SS4 e o RMSD entre a previsão de cada modelo e a observação, bem como a semelhança entre seus desvios padrão.

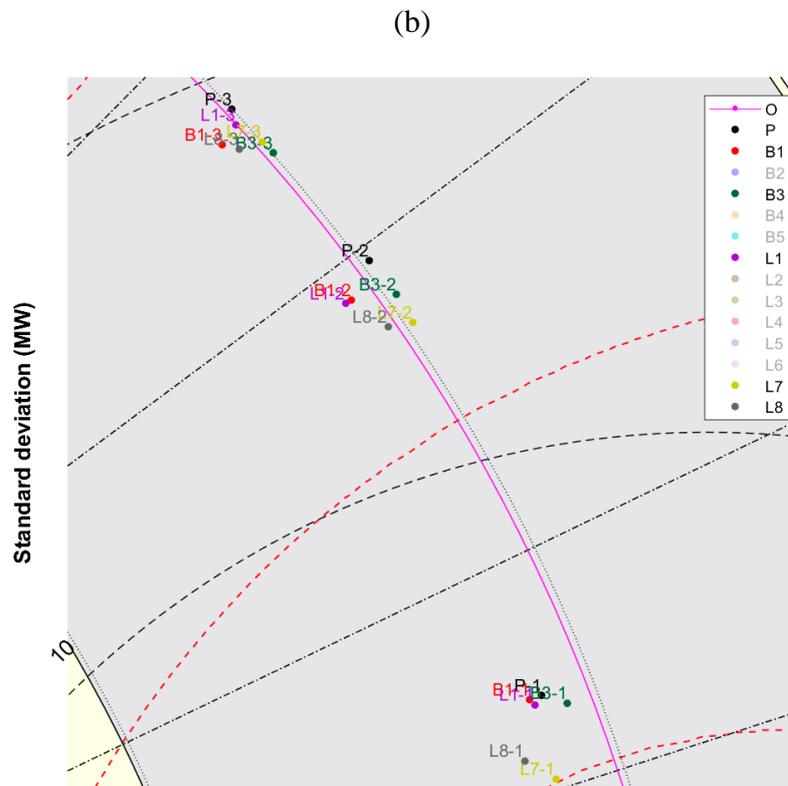
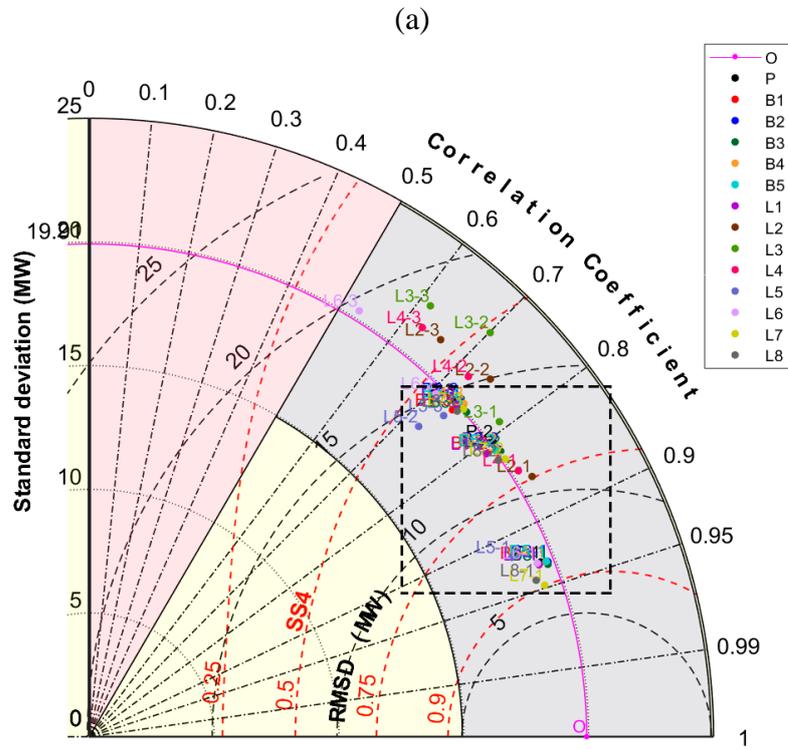
As Figuras 37 a 40 apresentam os diagramas de Taylor contendo os resultados dos modelos relativos às rampas de subida dos grupos de centrais A, B, C e D, respectivamente. Alguns modelos foram omitidos para evitar agrupamentos e facilitar a visualização, entretanto os diagramas completos são apresentados no Apêndice C. O ponto 'O', em magenta, corresponde ao sinal observado e, os demais pontos, às previsões dos modelos, cujas nomenclaturas obedecem à regra $M-k$, em que M representa o modelo e k , o horizonte de previsão (por exemplo, L8-2 corresponde ao modelo L8 e horizonte de previsão 2). Partindo da origem, podemos observar linhas azimutais, representando os coeficientes de correlação entre as previsões e a observação, e linhas radiais, representando o desvio padrão de cada série temporal. Partindo da observação, as linhas radiais vermelhas correspondem ao SS4, e as pretas, ao RMSD. Finalmente, observa-se que os diagramas foram subdivididos em 3

regiões, possibilitando uma avaliação ainda mais rápida quanto a qualidade dos modelos: R1, em cinza, com $\rho > 0,5$ e $0,5 \cdot \sigma_o < \sigma_m < 0,75 \cdot \sigma_o$; R2, em amarelo, com $\rho > 0,5$ e $0,5 \cdot \sigma_o > \sigma_m > 0,75 \cdot \sigma_o$; R3, em vermelho, com $\rho < 0,5$.

Podemos observar, nos diagramas de Taylor a seguir, que, geralmente, o modelo L7 atinge, no primeiro horizonte, valores de SS4 muito superiores à persistência, porém a distância entre os modelos local e de referência tende a diminuir à medida que o horizonte aumenta. Já o modelo B3 apresenta comportamento contrário, aumentando a distância com relação à persistência conforme aumentamos o horizonte de previsão, chegando a superar os demais modelos no terceiro horizonte, na maioria dos casos. Tais comportamentos indicam que, para um horizonte de 3 *time-steps*, o modelo global é o mais adequado para representar as estruturas de fase e frequência do sinal observado. Porém, quando a previsão é realizada para 1 *time-step* à frente, o modelo local reproduz estas estruturas de forma mais acurada. Ainda, observa-se que os desvios padrão de todos os modelos, inclusive a persistência, tendem a aumentar conforme o horizonte de previsão aumenta, sobrestimando a variabilidade do sinal observado. Tal comportamento se dá devido à inércia característica dos modelos, os quais acabam entregando previsões que subestimam, na maioria dos casos, as rampas de subida. Esta inércia é ainda maior para maiores horizontes, ocasionando em um aumento proporcional da variabilidade.

Finalmente, são perceptíveis algumas discrepâncias entre os resultados apresentados pelos gráficos de melhora sobre a persistência e diagramas de Taylor, possivelmente fruto do *bias* (viés), o qual é levado em conta pela melhora sobre a persistência, mas não pelos diagramas de Taylor. O *bias* nada mais é que diferença entre as médias das séries observada e prevista e seus efeitos podem ser atenuados com uma simples correção da média no modelo de previsão. A evolução dos *bias* nas séries de rampa de subida em cada central encontra-se representada no Apêndice B.

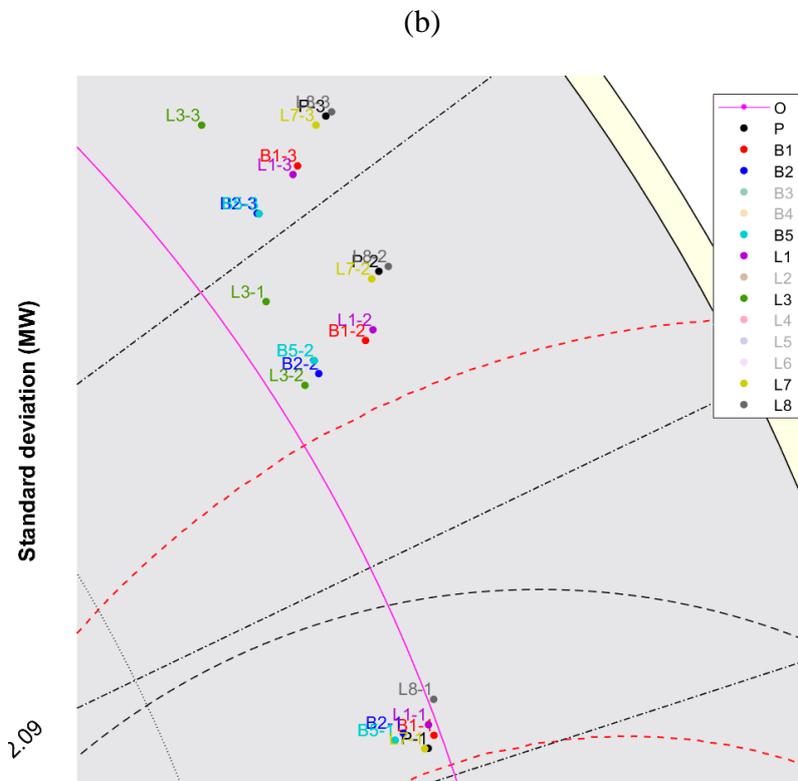
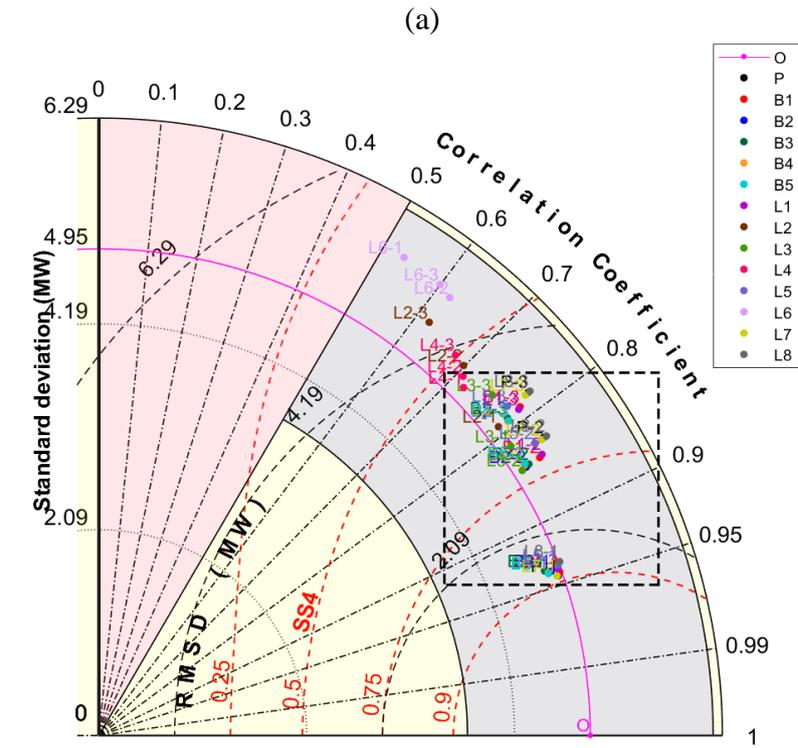
Figura 37 – Diagrama de Taylor sobre as rampas de subida de G4



(a) Diagrama de Taylor contendo todos os modelos; (b) Zoom da janela especificada em (a) contendo apenas os melhores modelos.

Fonte: Própria.

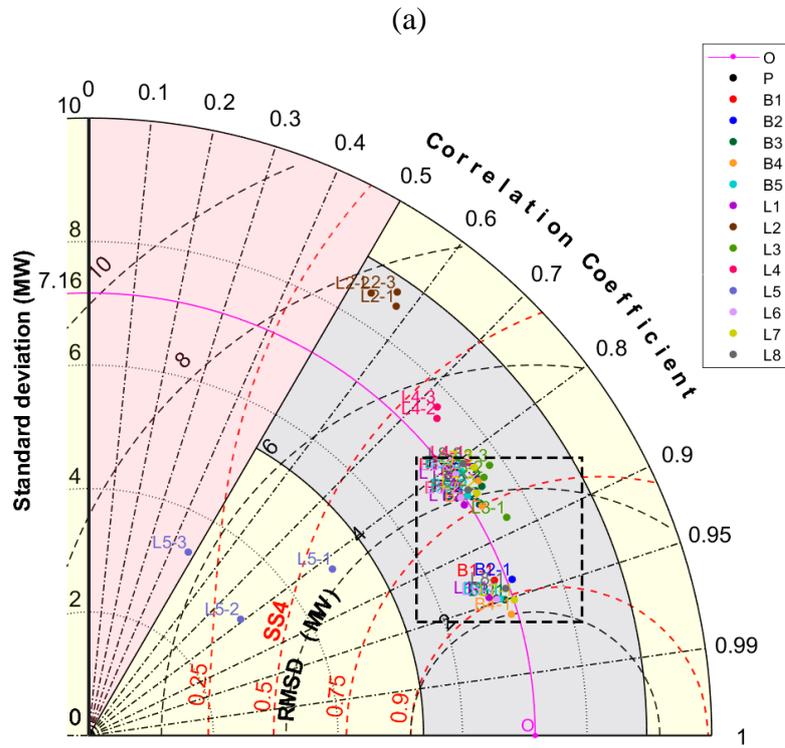
Figura 39 - Diagrama de Taylor sobre as rampas de subida de G8



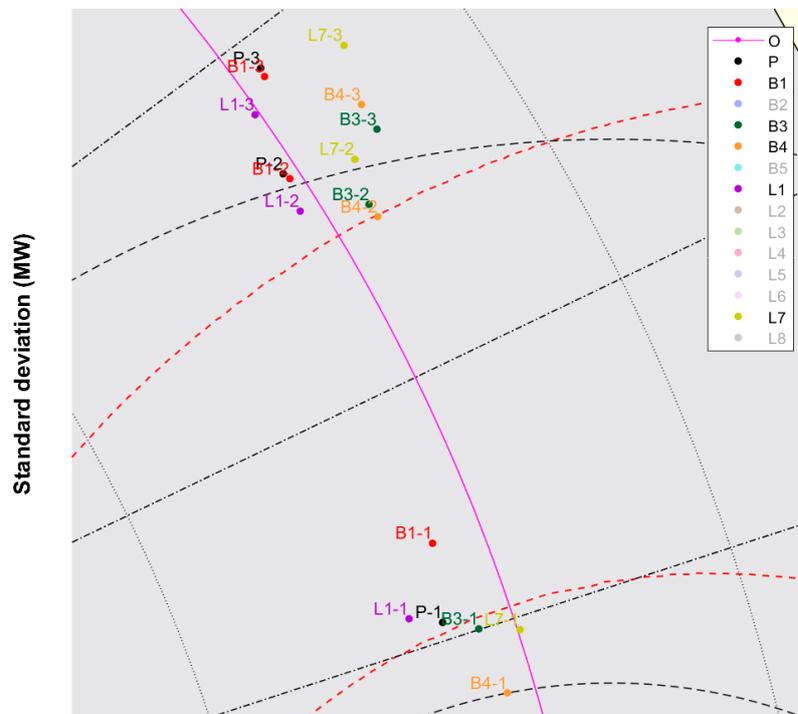
(a) Diagrama de Taylor contendo todos os modelos; (b) Zoom da janela especificada em (a) contendo apenas os melhores modelos.

Fonte: Própria.

Figura 40 – Diagrama de Taylor sobre as rampas de subida de G7



(b)



(a) Diagrama de Taylor contendo todos os modelos; (b) Zoom da janela especificada em (a) contendo apenas os melhores modelos.

Fonte: Própria.

5.3 Rampas de descida

Os gráficos de melhora sobre a persistência apresentados a seguir (Figuras 41 a 44) comparam os modelos globais e locais sobre as rampas de descida em cada um dos grupos de centrais estudados.

Durante as rampas de descida, os modelos, em sua maioria, tendem a apresentar um comportamento decrescente, ou seja, a IoP tende a diminuir à medida que o horizonte aumenta, o que vai de encontro ao comportamento esperado para TSBM. Entretanto, o conhecimento acerca do comportamento de modelos de previsão em regimes de rampa ainda é incerto, portanto, não podemos afirmar se o comportamento apresentado pelos modelos é realmente incomum. Os valores de IoP obtidos durante as rampas de descida se mostraram muito inferiores aos obtidos durante as rampas de subida, indicando que o primeiro tipo de regime é bastante persistente, ou seja, as variações das rampas de descida acontecem de forma suave, como verificado por Gallego et al. (2013). Este comportamento suave possibilitou que a persistência entregasse valores de *bias* (Apêndice B) muito menores que a grande maioria dos modelos, o que reflete diretamente nos resultados obtidos pelo MSE, resultando em baixos valores de IoP.

De acordo com o gráfico de melhora sobre a persistência da Figura 41, podemos observar que a central G4 é a única em que o modelo L7 não apresenta os melhores resultados. No caso desta central, o modelo L8 atinge valores de melhora sobre a persistência muito superiores a L7, partindo de uma IoP de cerca de 20% no primeiro horizonte para cerca de 10% de melhora no terceiro horizonte. Vale salientar que tais modelos apresentam metodologias muito semelhantes, cuja única diferença é a origem do dado de entrada da rede bayesiana: L7 utiliza informação da central a barlavento, enquanto L8 utiliza informação da própria central. Assim como nas rampas de subida, observa-se que, para a central G4, os modelos que utilizam dados da central a barlavento apresentaram resultados muito inferiores àqueles baseados exclusivamente na central de interesse, o que corrobora a ideia de que os dados da central G6 não fornecem informação favorável às previsões de G4.

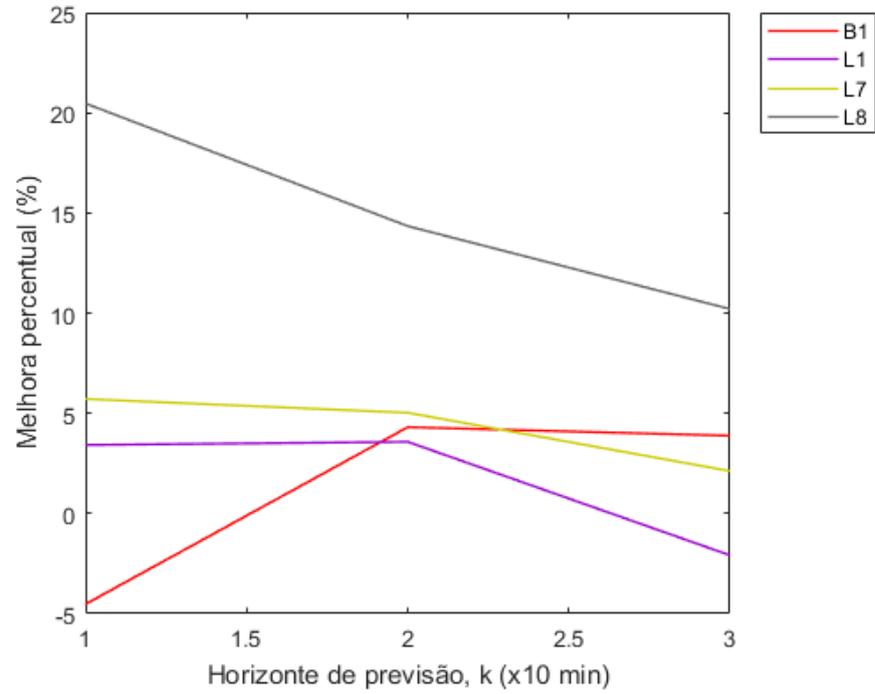
No que diz respeito à central G13 (Figura 42), os modelos locais conseguiram superar os globais em todos os horizontes. O modelo L7 supera os demais nos primeiro e segundo horizontes, com IoPs variando de aproximadamente 17% a cerca

de 7%. No terceiro horizonte, o modelo L3 toma a dianteira, alcançando pouco mais de 5%. Já na central G8 (Figura 43), L7 permanece na vanguarda em todos os horizontes, com valores de melhora sobre a persistência variando de cerca de 14%, no primeiro horizonte, para, aproximadamente, 8% no terceiro horizonte.

Finalmente, durante os eventos de rampa de descida da central G7, nenhum modelo foi capaz de superar a persistência, apresentando valores de loP negativos em todos os horizontes. Estes resultados podem ser fruto do ajuste ineficiente dos parâmetros devido à péssima qualidade dos dados da central G7 (ver Apêndice A), a qual apresenta lacunas numerosas e extensas. Como os modelos em questão apresentam valores absolutos de *bias* muito maiores que os apresentados pela persistência, uma simples correção do *bias* pode aumentar as loPs destes modelos.

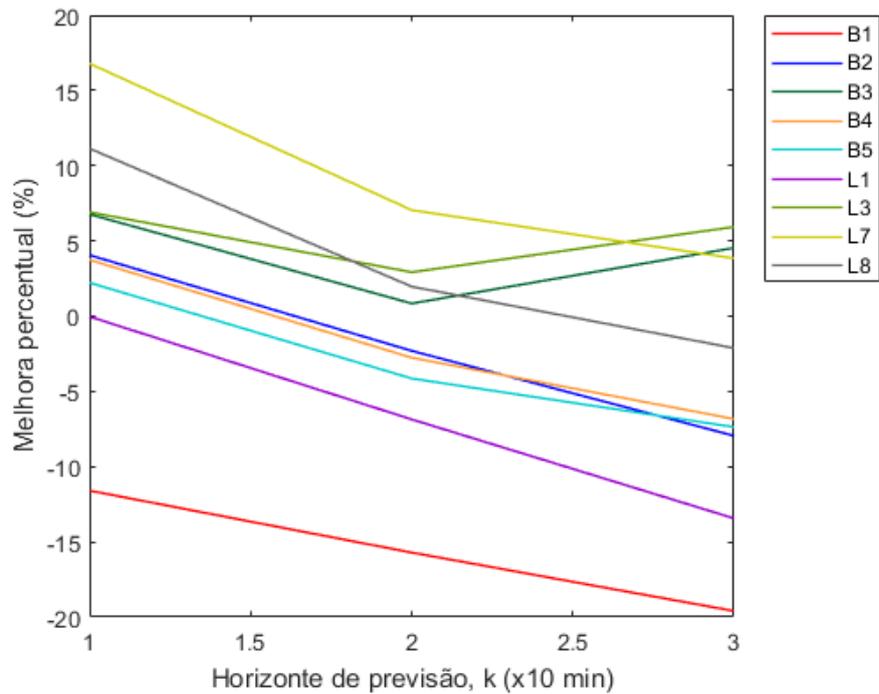
De acordo com os resultados de melhora sobre a persistência apresentados, podemos notar que os modelos L7 e L8 superaram os demais na grande maioria dos casos, indicando que a metodologia de classificação dos regimes em grupos de faixas de potência é a mais adequada para previsão de rampas de descida. Isto sugere que os regimes de rampa de descida são menos regulares que as rampas de subida (GALLEGO et al., 2011a), apresentando taxas bem distribuídas entre as diferentes faixas de potência e possibilitando um melhor ajuste dos modelos citados. Faz-se necessário, portanto, um estudo mais aprofundado do comportamento das rampas de descida.

Figura 41 - Melhora sobre a persistência sobre as rampas de descida de G4



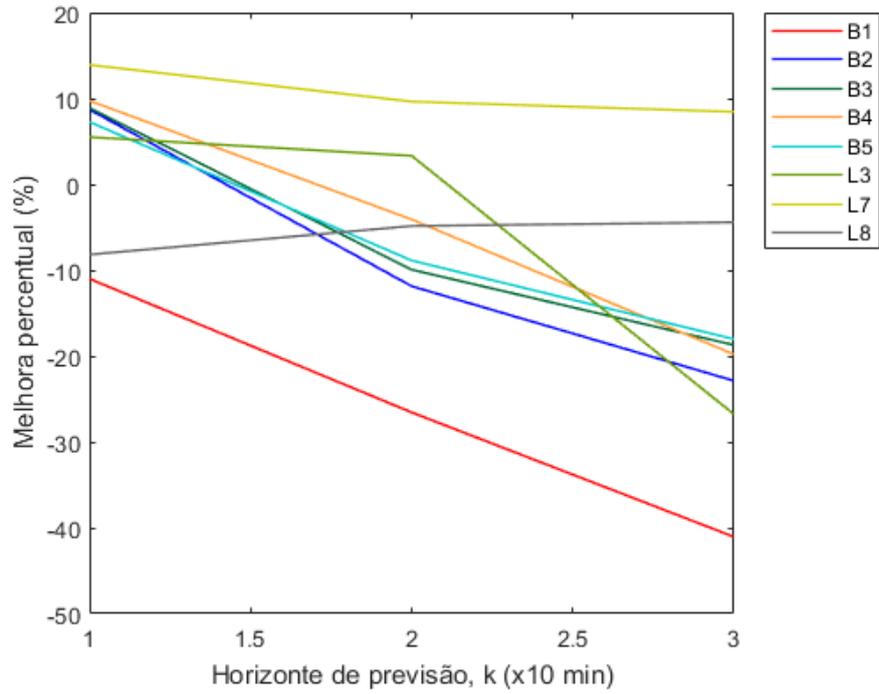
Fonte: Própria.

Figura 42 - Melhora sobre a persistência sobre as rampas de descida de G13



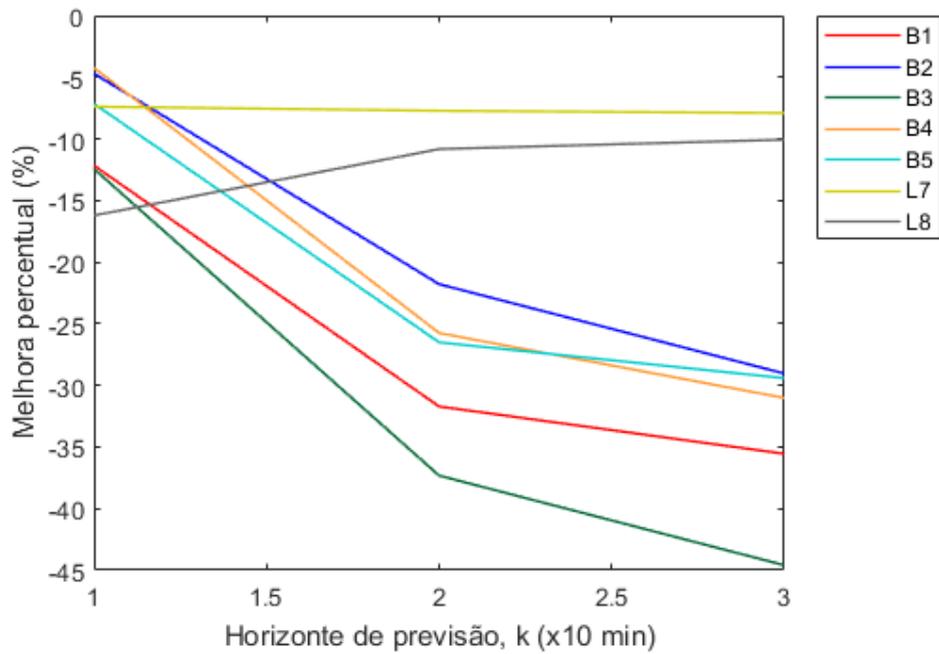
Fonte: Própria.

Figura 43 - Melhora sobre a persistência sobre as rampas de descida de G8



Fonte: Própria.

Figura 44 - Melhora sobre a persistência sobre as rampas de descida de G7



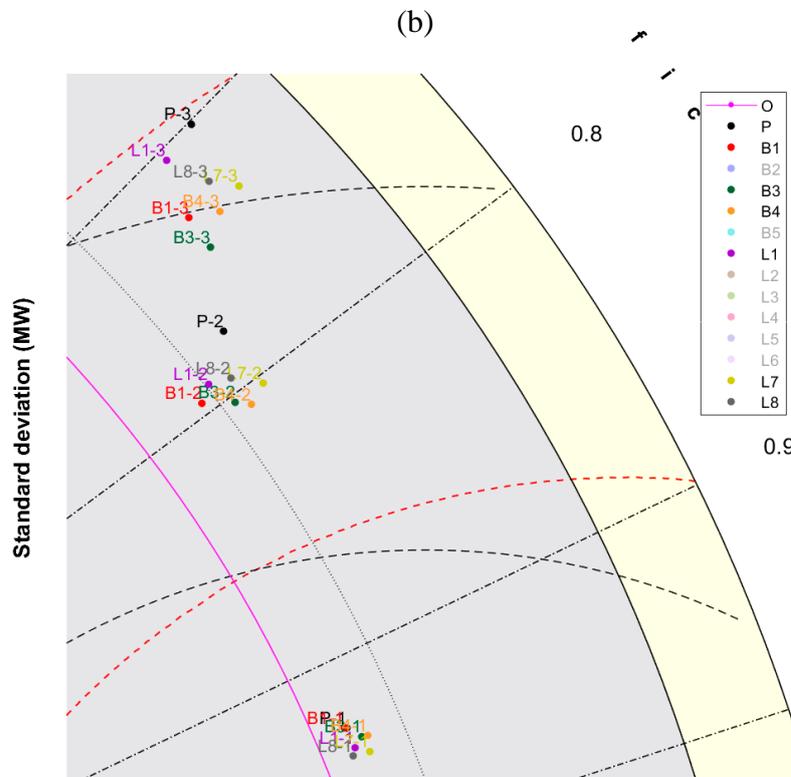
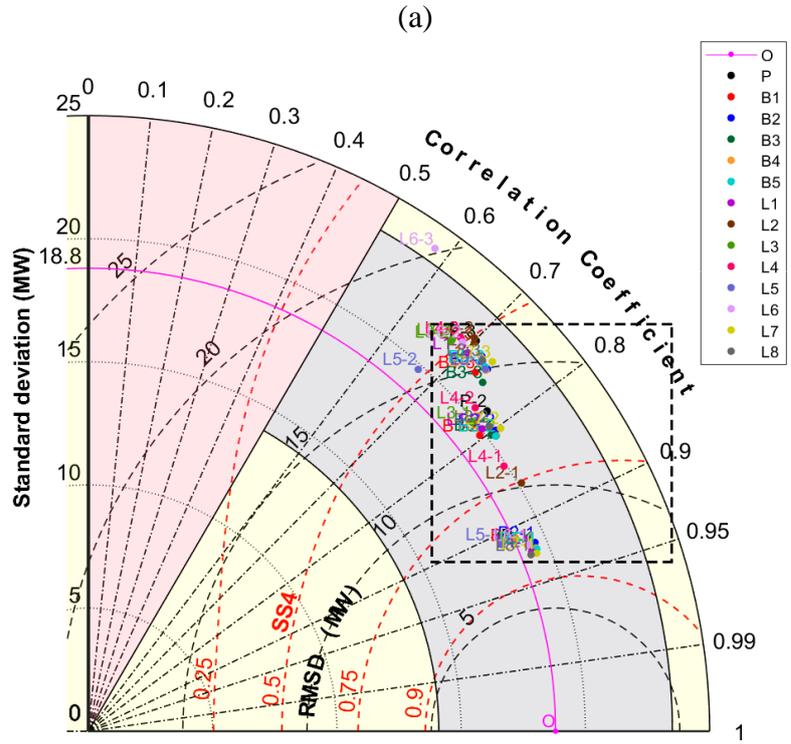
Fonte: Própria.

Novamente, diagramas de Taylor foram utilizados para avaliar, simultaneamente, a correlação, o RMSD e o SS4 entre as estimativas e a observação, assim como a similaridade entre as variâncias destes dois sinais através de seus desvios padrão. As Figuras 45 a 48 fornecem os diagramas de Taylor relativos às rampas de descida dos grupos A, B, C e D, respectivamente. Estes diagramas omitem alguns modelos para melhorar a visualização ao evitar agrupamentos. Os diagramas completos podem ser visualizados no Apêndice C.

De acordo com o que foi observado durante as rampas de descida, o modelo B3 consegue, na maioria dos casos, entregar valores de SS4 superiores aos demais modelos no terceiro horizonte de previsão. Novamente, este modelo se prova eficaz em replicar a fase e a frequência do sinal observado quando aplicado a um horizonte de 3 *time-steps*, apesar de tender a sobrestimar a variabilidade deste. Em geral, a variabilidade das estimativas dos modelos é semelhante à apresentada pelos dados observacionais no primeiro horizonte e aumenta conforme o horizonte de previsão cresce, sempre sobrestimando a variabilidade da observação no terceiro horizonte. Tais resultados são fruto, mais uma vez, da inércia característica dos modelos, os quais entregam previsões que, em geral, tendem a sobrestimar as rampas de descida. Esta inércia é mais suave no primeiro horizonte e cresce de acordo com o aumento do horizonte de previsão, entregando valores de desvio padrão muito superiores ao observado pelo sinal original.

Existem, contudo, algumas discrepâncias entre os resultados obtidos através dos diagramas de Taylor e dos gráficos de melhora sobre a persistência. Por exemplo, o gráfico de melhora sobre a persistência indica que o modelo L7 apresenta os menores valores de MSE nos dois primeiros horizontes. Já o diagrama de Taylor aponta que os melhores RMSDs nos primeiro e segundo horizontes são entregues pelo modelo L1. Analisando o gráfico de evolução do *bias* da Figura 60 (Apêndice B) para estes modelos, vemos que o valor absoluto do viés apresentado por L1 é muito superior à persistência, o que implica em maiores valores de MSE. Possivelmente, uma simples correção do *bias* no modelo L1 possibilitará a obtenção de valores de IoP muito maiores.

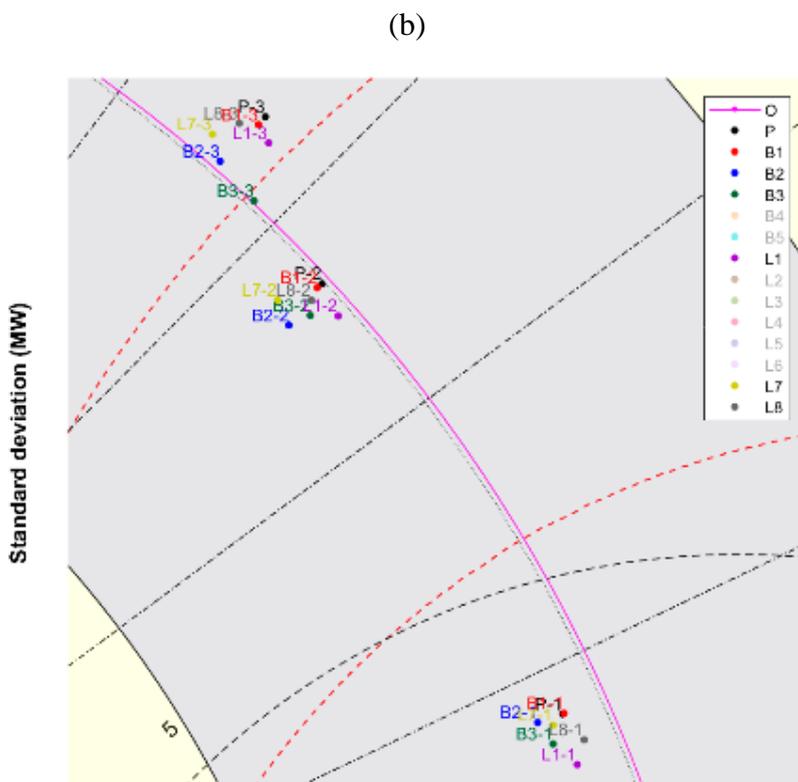
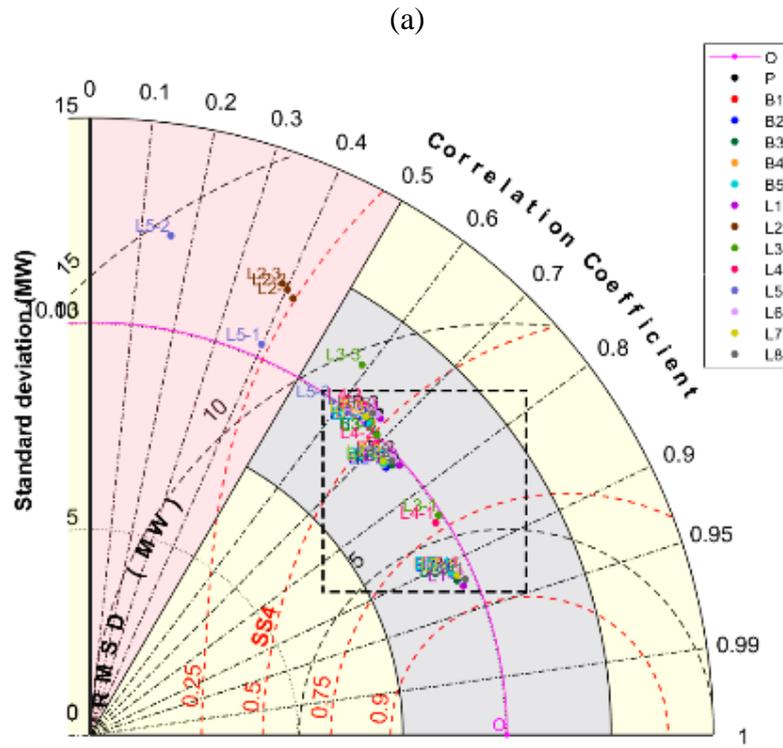
Figura 45 – Diagrama de Taylor sobre as rampas de descida de G4



(a) Diagrama de Taylor contendo todos os modelos; (b) Zoom da janela especificada em (a) contendo apenas os melhores modelos.

Fonte: Própria.

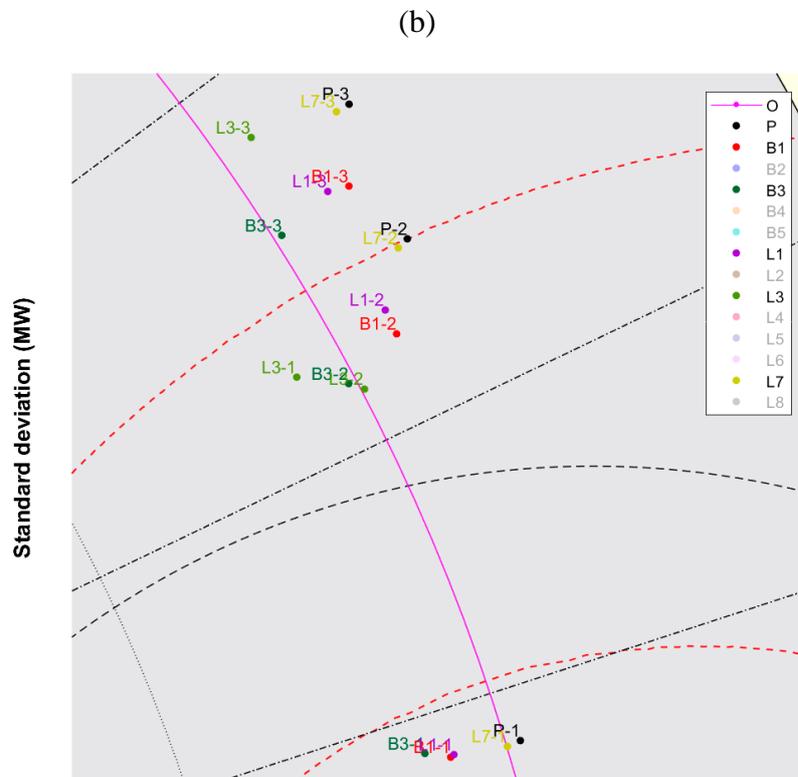
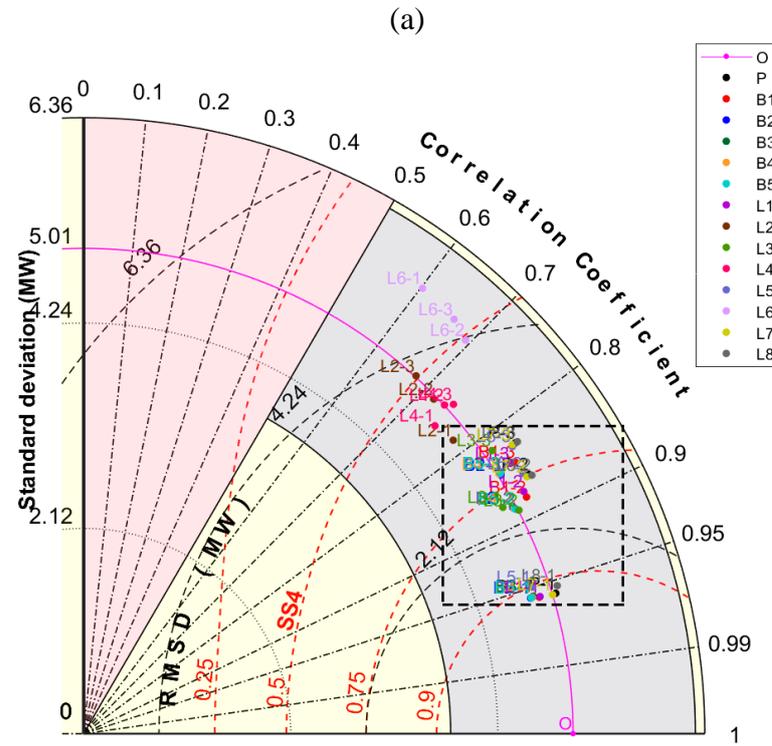
Figura 46 - Diagrama de Taylor sobre as rampas de descida de G13



(a) Diagrama de Taylor contendo todos os modelos; (b) Zoom da janela especificada em (a) contendo apenas os melhores modelos.

Fonte: Própria.

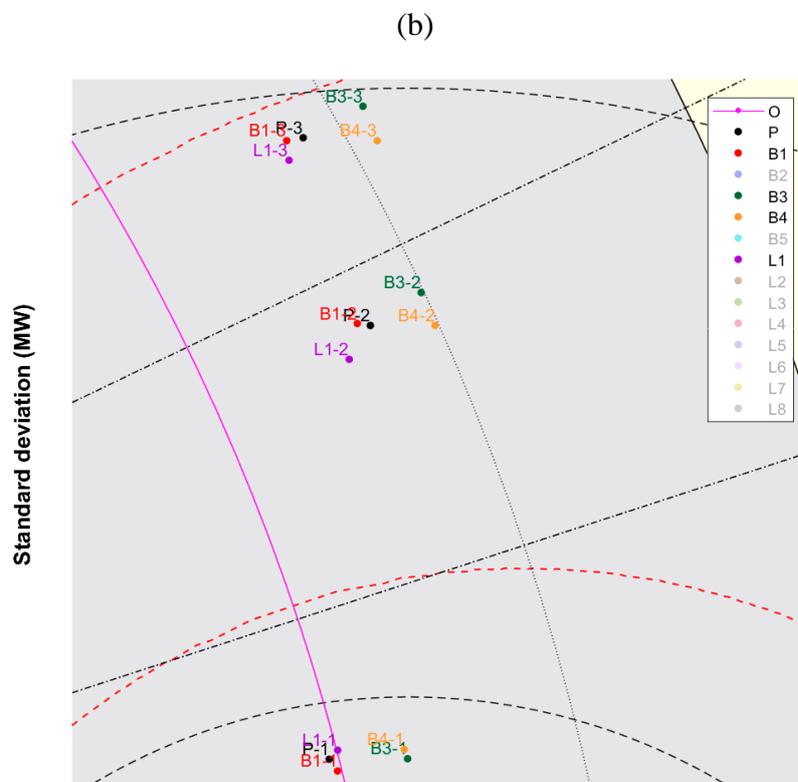
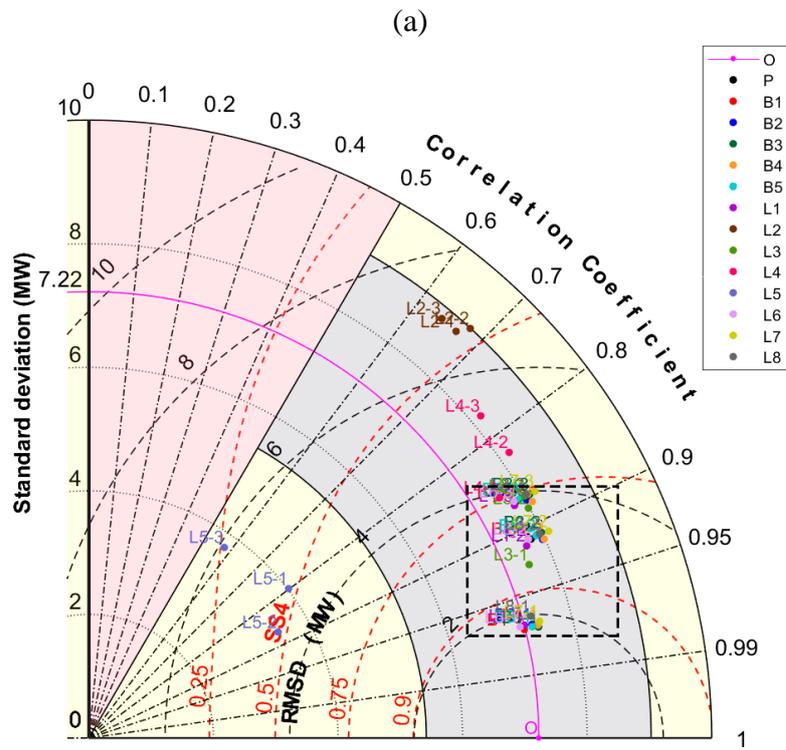
Figura 47 - Diagrama de Taylor sobre as rampas de descida de G8



(a) Diagrama de Taylor contendo todos os modelos; (b) Zoom da janela especificada em (a) contendo apenas os melhores modelos.

Fonte: Própria.

Figura 48 – Diagrama de Taylor sobre as rampas de descida de G7



(a) Diagrama de Taylor contendo todos os modelos; (b) Zoom da janela especificada em (a) contendo apenas os melhores modelos.

Fonte: Própria.

Os resultados obtidos com relação às rampas de subida mostram que a grande maioria dos modelos se ajustam de forma adequada a este tipo de regime, tendo em vista que seus gráficos de IoP apresentaram um comportamento crescente e, no diagrama de Taylor, se encontram na região R1, apresentando valores de correlação acima de 70% e valores de desvio padrão muito similares ao apresentado pelo sinal observado em todos os horizontes de previsão. No primeiro horizonte, o modelo L7 alcança os melhores resultados, entregando, nas centrais G4, G13 e G8, correlações superiores a 92% e RMSDs inferiores a 8% da potência nominal. Já no terceiro horizonte, o modelo B3 apresenta destaque, atingindo correlação de 85% na central G7, enquanto a persistência alcança apenas 81%.

No que diz respeito às rampas de descida, percebe-se que, apesar dos modelos L7 e L8 apresentarem valores de melhora sobre a persistência bastante elevados, ainda assim possuem um comportamento decrescente, o que é atípico para modelos baseados em séries temporais. Contudo, os resultados apresentados nos diagramas de Taylor revelam que os modelos, de maneira geral, tendem a se afastar da persistência à medida que o horizonte aumenta, nos levando a crer que este comportamento decrescente nos gráficos de melhora sobre a persistência é reflexo dos *bias* elevados apresentados por estes modelos. Como prova disso, ao calcularmos a melhora sobre a persistência do modelo B3, por exemplo, levando em consideração o RMSD, observamos que este modelo parte de uma IoP de 1,9% no primeiro horizonte para 10,6% no terceiro horizonte, para a central G4.

Os gráficos analisados nesta seção foram gerados a partir de valores de melhora percentual sobre a persistência (IoP), correlação (ρ), raiz do erro médio quadrático das diferenças (RMSD), *skill score* de Taylor (SS4) e desvios padrão da observação (σ_o) e dos modelos (σ_m). Tais resultados podem ser conferidos no Apêndice D, com exceção dos desvios padrão, os quais se encontram representados pela razão entre os desvios do modelo e da observação ($\hat{\sigma}_m$).

6 CONCLUSÃO

De acordo com os resultados obtidos, verificou-se que os modelos propostos conseguem, em sua maioria, entregar resultados satisfatórios, superando a persistência em todos horizontes de previsão para os grupos de centrais utilizados. Nos gráficos de melhora sobre a persistência a partir do erro médio quadrático (MSE), quando aplicados sobre as rampas de subida, os modelos tendem a apresentar um comportamento crescente, com resultados muito superiores aos obtidos quando tais modelos são aplicados às rampas de descida, nas quais o comportamento dos modelos é decrescente. Tal comportamento indica que as rampas de descida são muito mais difíceis de se prever que as rampas de subida, como já observado por AWS Truewind (2008), Gallego et al. (2011a, 2013) e Yang et al. (2013). Ainda assim, os dois modelos que utilizam faixas de potência para realizar a previsão se mostraram bastante eficientes quando aplicados a regimes de rampa de descida, entregando valores de melhora sobre a persistência bastante elevados.

A partir dos diagramas de Taylor, observou-se que, em quase todas as centrais, o modelo B3 entregou valores de SS4 e correlação superiores aos demais modelos no terceiro horizonte, tanto para as rampas de subida quanto para as rampas de descida. Sugere-se, portanto, que a partir do terceiro horizonte de previsão, um modelo de ajuste global é suficiente para entregar previsões acuradas a respeito da potência de saída de centrais eólicas em regimes de rampa, apresentando um RMSD máximo, nesse horizonte, de 15% da potência nominal da central de interesse. Ainda, verificou-se que a grande maioria dos modelos tende a sobrestimar cada vez mais a variabilidade dos dados observacionais a medida que o horizonte aumenta, entregando previsões ainda mais dispersas ao redor da média.

Por fim, o trabalho em questão foi capaz de contribuir com novas metodologias quanto à definição de rampa. Foi desenvolvido um mecanismo identificador de regime (função IR), cuja definição de rampa se baseia exclusivamente nas características da série temporal, excluindo a necessidade de conhecimento empírico por parte do operador. Criou-se, também, três outros métodos que utilizam redes bayesianas, em conjunto com a função IR, para identificar rampas fazendo uso de dados de centrais eólicas (ou torres anemométricas) situadas a barlavento da central de interesse.

Quanto aos métodos de previsão, foram desenvolvidas diversas metodologias, tanto para o ajuste global de toda a série temporal quanto para o ajuste local dos regimes de rampa, cujos resultados foram bastante favoráveis. Para que seja possível a intercomparação de acurácia entre os modelos aqui desenvolvidos e os existentes na literatura, utilizou-se, como métrica, a melhora sobre a persistência (IoP) dos modelos, tendo em vista que não são utilizados os mesmos dados observacionais. Entretanto, a utilização de tal métrica ainda não é comum, visto que, até então, apenas Gallego et al. (2011a) apresentou resultados comparando as IoPs do seu modelo. Como modelo de referência, além da persistência, o autor utilizou um modelo global de previsão, semelhante ao primeiro modelo global proposto neste trabalho, cuja IoP baseada no RMSE foi superada pelo modelo proposto em 1% nas rampas de descida. Aqui, fazendo uso da mesma métrica utilizada por Gallego et al, 2011a, um dos modelos locais conseguiu superar o modelo global de referência em cerca de 5% no primeiro horizonte, demonstrando o potencial da metodologia proposta.

7 PERSPECTIVAS

Como próximos passos, propõe-se:

1. Aprofundar o estudo a respeito do comportamento e das características das rampas, bem como de suas possíveis causas, com atenção especial às rampas de descida;
2. Desenvolvimento de uma metodologia que se adeque à definição de rampa utilizada pelo ONS;
3. Desenvolvimento de uma metodologia capaz de prever não só a potência de saída das centrais eólicas, como também os possíveis estados do sistema elétrico no Nordeste Brasileiro;
4. Incorporação de observações de vento como variáveis exógenas às redes neurais e/ou variáveis de entrada das redes bayesianas.
5. Estudo aprofundado a respeito da evolução do *delay* entre as centrais eólicas ao longo do tempo e sua dependência com a escala temporal utilizada.

REFERÊNCIAS

ABEEOLICA. **Dados mensais. Fevereiro de 2018.** Associação Brasileira de Energia Eólica. (<http://www.abeeolica.org.br>, acesso em Junho de 2018)

ALEXIADIS, M.; DOKOPOULOS, P.; SAHSAMANOGLU, H. Wind speed and power forecasting based on spatial correlation models. **IEEE Trans. Energy Conversion**, v. 14, n. 3, p. 836–842, 1999.

AWS TRUEWIND. AWS Truewind's final report for the Alberta forecasting pilot project. **Wind Power Forecasting PILOT Project**, 2008.

Balanço Energético Nacional (BEN) 2016: ano base 2015. Empresa de Pesquisa Energética (EPE), Ministério de Minas e Energia, Brasil, 2016.

Balanço Energético Nacional (BEN) 2017: ano base 2016. Empresa de Pesquisa Energética (EPE), Ministério de Minas e Energia, Brasil, 2017.

BARBOUNIS, T.; THEOCHARIS, J.; ALEXIADIS, M.; DOKOPOULOS, P. Long-term wind speed and power forecasting using local recurrent neural network models. **IEEE Transactions on Energy Conversion**, v. 21, n. 1, p. 273-284, 2006.

BOSSAVY, A.; GIRARD, R.; KARINIOTAKIS, G. Forecasting uncertainty related to ramps of wind power production. **European Wind Energy Conference and Exhibition**. European Wind Energy Association, p. 9, 2010.

BOSSAVY, A.; GIRARD, R.; KARINIOTAKIS, G. Forecasting ramps of wind power production with numerical weather prediction ensembles. **Wind Energy**, v. 16, n. 1, p. 51-63, 2013.

BRADFORD, K.; CARPENTER, R.; SHAW, B. Forecasting southern plains wind ramp events using the WRF model at 3-km. **AMS Student Conference**, 2010.

BRISTOL, E. Swinging door trending: Adaptive trend recording? **International Standards for Automation**, 1990.

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

CHATFIELD, C. **The analysis of time series**: An introduction. 5 ed. Londres: Chapman-Hall/CRC, 1996.

CHATFIELD, C. **Time-series forecasting**. Londres: Chapman-Hall/CRC, 2000.

COLLIER C, PARKES J, COLLINS J, LANDBERG L. Improved ramp event forecasting using upstream wind measurements. **European wind energy conference**, Warsaw, 2010.

COSTA, A. **Mathematical/statistical and physical/meteorological models for short-term prediction of wind farms output**. Ph.D. thesis, Escuela Técnica Superior de Ingenieros Industriales (Universidad Politécnica de Madrid), 2005.

COSTA, A.; CRESPO, A.; NAVARRO, J.; LIZCANO, G.; MADSEN, H.; FEITOSA, E. 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.

CUI, M.; ZHANG, J.; FLORITA, A.; HODGE, B.; KE, D.; SUN, Y. An optimized swinging door algorithm for wind power ramp event detection. **IEEE Power & Energy Society General Meeting**, p. 1-5, 2015.

CUTLER, N.; KAY, M.; JACKA, K.; NIELSEN, T. Detecting, categorizing and forecasting large ramps in wind farm power output using meteorological observations and WPPT. **Wind Energy**, v. 10, n. 5, p. 453-470, 2007.

CUTLER, N.; OUTHRED, H.; MACGILL, I; KAY, M.; KEPERT, J. Characterizing future large, rapid changes in aggregated wind power using numerical weather prediction spatial fields. **Wind Energy**, v. 12, n. 6, p. 542-555, 2009b.

DAS, A. K. An analytical model for ratio based analysis of wind power ramp events. **Sustainable Energy Technologies and Assessments**, v. 9, p. 49-54, 2015.

ELA, E.; KEMPER, J. Wind plant ramping behavior. **National Renewable Energy Laboratory**, 2009.

FERNÁNDEZ, A.; ALÁIZ, C.; GONZÁLEZ, A.; DÍAZ, J.; DORRONSORO, J. Diffusion methods for wind power ramp detection. **International Work-Conference on Artificial Neural Networks**, p. 106-113, 2013.

FERREIRA, C.; GAMA, J.; MATIAS, L.; BOTTERUD, A.; WANG, J. A survey on wind power ramp forecasting. **Argonne National Laboratory (ANL)**, 2011.

FLORITA, A.; HODGE, B.; ORWIG, K. Identifying wind and solar ramping events. **Green Technologies Conference**, IEEE, p. 147-152, 2013.

FOCKEN, U.; LANGE, M. Wind power forecasting pilot project in alberta. **Oldenburg, Germany: energy & meteo systems GmbH**, 2008.

FOLEY, A.; LEAHY, P.; MARVUGLIA, A.; MCKEOGH, E. Current methods and advances in forecasting of wind power generation. **Renewable Energy**, v. 37, n. 1, p. 1-8, 2012.

FREEDMAN, J.; MARKUS, M.; PENC, R. Analysis of West Texas wind plant ramp-up and ramp-down events. **AWS Truewind, LLC**, 2008.

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, 2011a.

GALLEGO, C.; PINSON, P.; MADSEN, H.; COSTA, A.; CUERVA, A. Influence of local wind speed and direction on wind power dynamics—Application to offshore very short-term forecasting. **Applied Energy**, v. 88, n. 11, p. 4087-4096, 2011b.

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

GALLEGO, C.; COSTA, A.; CUERVA, A.; LANDBERG, L.; GREAVES, B.; COLLINS, J. A wavelet-based approach for large wind power ramp characterization. **Wind Energy**, v. 16, n. 2, p. 257-278, 2013.

GALLEGO, C.; CUERVA, A.; LOPEZ, O. A review on the recent history of wind power ramp forecasting. **Renewable and Sustainable Energy Reviews**, v. 52, p. 1148-1157, 2015.

GIEBEL, G.; BROWNSWORD, R.; KARINIOTAKIS, G.; DENHARD, M.; DRAXL, C. The state-of-the-art in short-term prediction of wind power: A literature overview. **ANEMOS. plus**, 2011.

GIRARD, R.; BOSSAVY, A.; KARINIOTAKIS, G. Forecasting ramps of wind power production at different time scales. **European Wind Energy Conference**, 2011.

GOODFELLOW, I; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016

GREAVES, B.; COLLINS, J.; PARKES, J.; TINDAL, A. Temporal forecast uncertainty for ramp events. **Wind Engineering**, v. 33, n. 4, p. 309-319, 2009.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001.

HECKENBERGEROVA, J.; MUSILEK, P.; MAREK, J. Analysis of wind speed and power time series preceding wind ramp events. **Proceedings of the 2014 15th International Scientific Conference on Electric Power Engineering**. IEEE, p. 279-283, 2014.

JENSEN, F. **Bayesian Networks and Decision Graphs**. Springer Science & Business Media, 2001

KAMATH, C. Understanding wind ramp events through analysis of historical data. **Transmission and Distribution Conference and Exposition, 2010 IEEE PES**. IEEE, p. 1-6, 2010.

KAMATH, C. Associating weather conditions with ramp events in wind power generation. **Power Systems Conference and Exposition (PSCE)**. p. 1-8, 2011.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. **International Joint Conference on Artificial Intelligence (IJCAI)**, v. 14, n. 2, p. 1137-1145, 1995.

KOSKI, T.; NOBLE, J. **Bayesian networks: An introduction**. John Wiley and Sons, 2009.

KUSIAK, A.; ZHENG, H.; SONG, Z. Short-term prediction of wind farm power: A data mining approach. **IEEE Transactions on energy conversion**, v. 24, n. 1, pp. 125–136, 2009.

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

LOUKA, P.; GALANIS, G., SIEBERT, N.; KARINIOTAKIS, G.; KATSAFADOS, P.; PYTHAROULIS, I.; KALLOS, G. Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering. **Journal of Wind Engineering and Industrial Aerodynamics**, v. 96, n. 12, p. 2348-2362, 2008.

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

MORE, A.; DEO, M. **Forecasting wind with neural networks**. Marine structures, v. 16, n. 1, p. 35-49, 2003.

MORÉ, J. J. The Levenberg-Marquardt algorithm: implementation and theory. **Numerical analysis**. Springer, Berlin, Heidelberg, p. 105-116, 1978.

MORETTIN, P. A.; TOLOI, C. M. **Modelos para previsão de séries temporais**. Instituto de matematica pura e aplicada, 1981.

NEGNEVITSKY, M.; JOHNSON, P. Very short term wind power prediction: A data mining approach. **Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century**, IEEE, p. 1-3, 2008.

NIELSEN, T.; JOENSEN, A.; MADSEN, H.; LANDBERG, L.; GIEBEL, G. A new reference for wind power forecasting. **Wind energy**, v. 1, n. 1, p. 29-34, 1998.

PEASE, J. Critical short-term forecasting needs for large and unscheduled wind energy on the BPA system. **Conference at the 3rd Workshop on Best Practice in the Use of Short-term Forecasting of Wind Power**, Bremen, 2009.

PEREIRA, B; PAIS, M; SALES, P. **Análise espectral de séries temporais: Uma introdução para engenharia, economia e estatística**. Rio de Janeiro: Arte Final Leasing Editorial; Eletrobrás S.A., 1986.

PEREIRA, M. A. S.; MANSO, L. A. F.; SALES, W. S. Definição dos Níveis de Reserva Girante em Sistemas de Geração com Elevada Participação de Fontes Renováveis Intermitentes. **The 12th Latin-American Congress on Electricity Generation and Transmission – CLAGTEE**, 2017

PINSON, P.; KARINIOTAKIS, G. On-line assessment of prediction risk for wind power production forecasts. **Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology**, v. 7, n. 2, p. 119-132, 2004.

PINSON, P.; OTTERSON, S. Are ramp forecasts useful?. **European wind energy conference**, Copenhagen: 2012.

POTTER, C.; NEGNEVITSKY, M. Very short-term wind forecasting for Tasmanian power generation. **IEEE Transactions on Power Systems**, v. 21, n. 2, p. 965–972, 2006.

POTTER, C.; GRIMIT, E.; NIJSSEN, B. Potential benefits of a dedicated probabilistic rapid ramp event forecast tool. **Power Systems Conference and Exposition**, p. 1-5, 2009.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: The RPROP algorithm. **IEEE International Conference on Neural Networks, 1993**. p. 586-591, 1993.

SOMAN, S.; ZAREIPOUR, H.; MALIK, O.; MANDAL, P. A review of wind power and wind speed forecasting methods with different time horizons, **North American Power Symposium**. p. 1-8, 2010.

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

WEI, W. W. **Time series analysis**: univariate and multivariate methods. 2 ed. Pearson Addison Wesley, 2006.

WIDROW, B. e HOFF, M.E. Adaptive switching circuits. **IRE WESCOM Convention Record**, p. 96–104, 1960

WILLIAMSON, J. **Bayesian nets and causality**: philosophical and computational foundations. Oxford University Press, 2005.

WITTEN, I.; FRANK, E.; HALL, M.; PAL, C. **Data Mining**: Practical machine learning tools and techniques. Morgan Kaufmann, 2016.

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

YANG, Q.; BERG, L.; PEKOUR, M.; FAST, J.; NEWSOM, R.; STOELINGA, M.; FINLEY, C. Evaluation of WRF-predicted near-hub-height winds and ramp events over a Pacific Northwest site with complex terrain. **Journal of applied meteorology and climatology**, v. 52, n. 8, p. 1753-1763, 2013.

ZACK, J.; YOUNG, S.; COTE, M.; NOCERA, J.; AYMAMI, J.; VIDAL, J. Development and testing of an innovative short-term large wind ramp forecasting system. **Proceedings of the European Wind Energy Conference and Exhibition**, p. 20-23, 2010.

ZAREIPOUR, H.; HUANG, D.; ROSEHART, W. Wind power ramp events classification and forecasting: A data mining approach. **Power and energy society general meeting**. IEEE, p. 1-3, 2011.

ZHANG, J.; FLORITA, A.; HODGE, B. M.; FREEDMAN, J. Ramp forecasting performance from improved short-term wind power forecasting. **ASME 2014 international design engineering technical conferences and computers and information in engineering conference**. American Society of Mechanical Engineers, 2014.

ZHENG, H.; KUSIAK, A. Prediction of wind farm power ramp rates: A data-mining approach. **Journal of solar energy engineering**, v. 131, n. 3, p. 031011, 2009.

ZHU, X.; GENTON, M. Short-Term Wind Speed Forecasting for Power System Operations. **International Statistical Review**, v. 80, n. 1, p. 2-23, 2012.

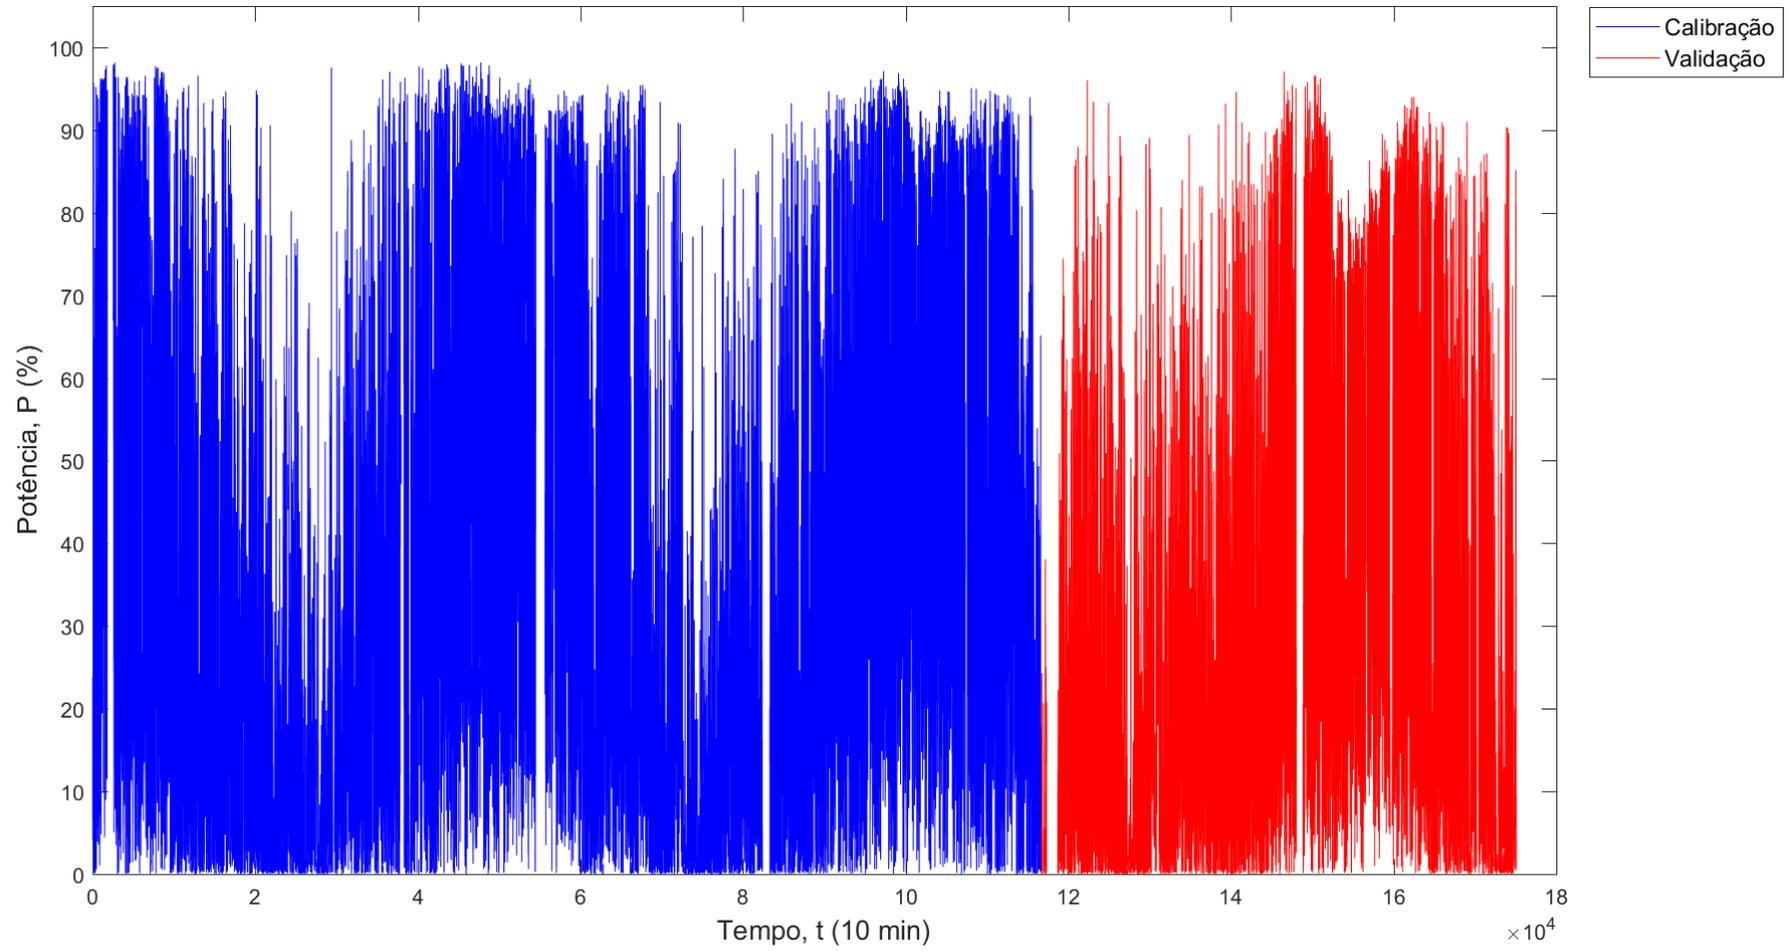
APÊNDICE A - SÉRIES TEMPORAIS

Aqui são apresentadas as séries de potência de saída das centrais eólicas utilizadas neste estudo normalizadas pela potência nominal de cada central. Todas as séries foram fornecidas pelo Operador Nacional do Sistema Elétrico (ONS) e possuem intervalo de integração de 10 minutos. Os períodos de calibração, utilizado durante o ajuste dos parâmetros, e de validação, aplicado para avaliação da acurácia dos modelos, estão destacados em azul e vermelho, respectivamente.

Vale salientar que, antes de serem introduzidas nos modelos de previsão, as séries temporais passaram por testes de garantia de qualidade a fim de identificar e retirar possíveis anomalias, como, por exemplo, dados ausentes, dados persistentes, dados fora dos limites físicos ($0 < y < P_N$), em que P_N representa a potência nominal da central, entre outros.

- Central G4

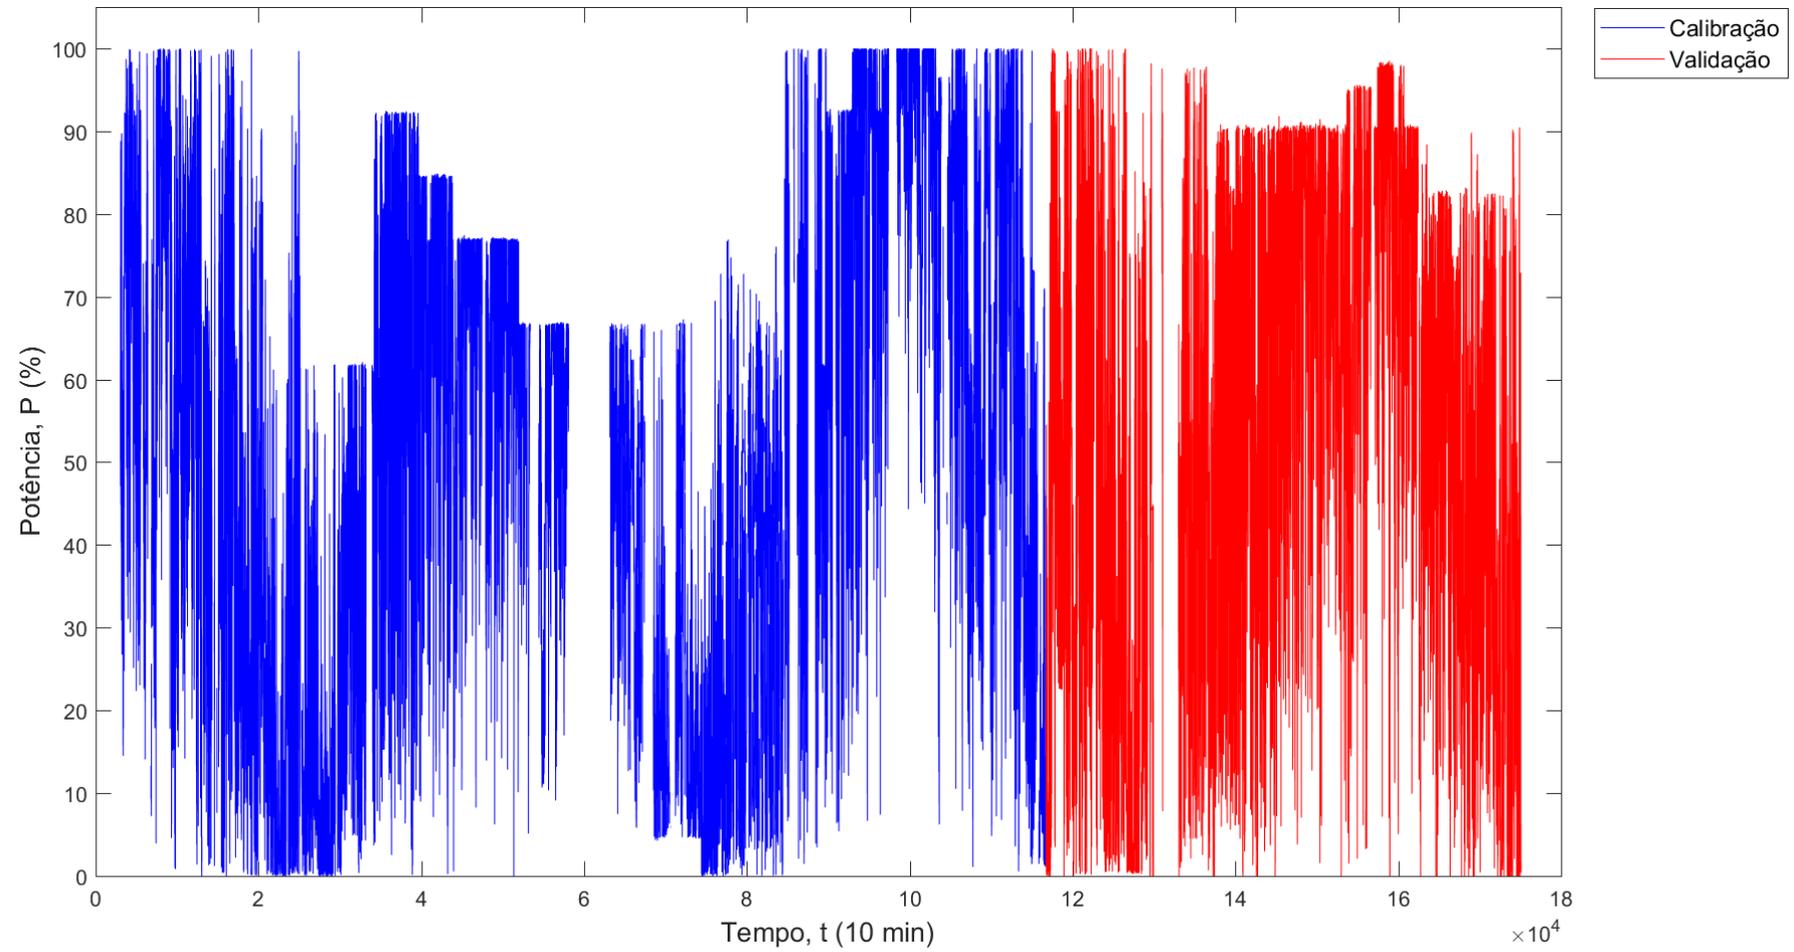
Figura 49 – Série temporal de G4



Fonte: Própria.

- Central G6

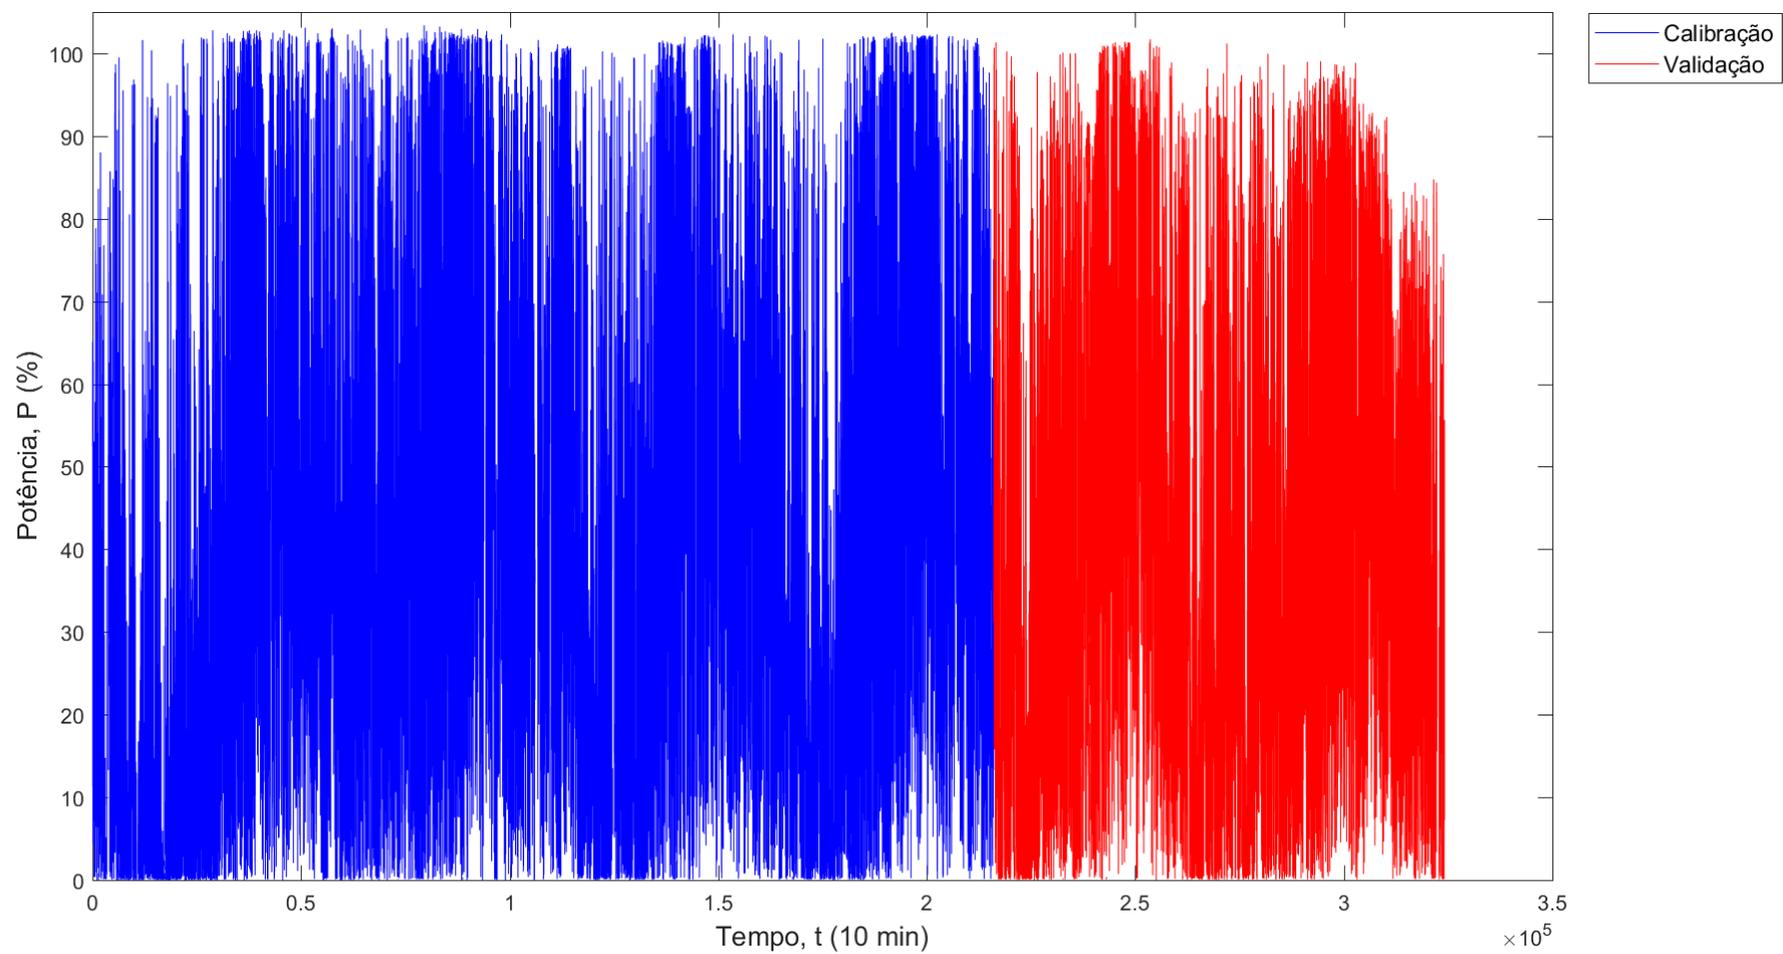
Figura 50 – Série temporal de G6



Fonte: Própria.

- Central G13

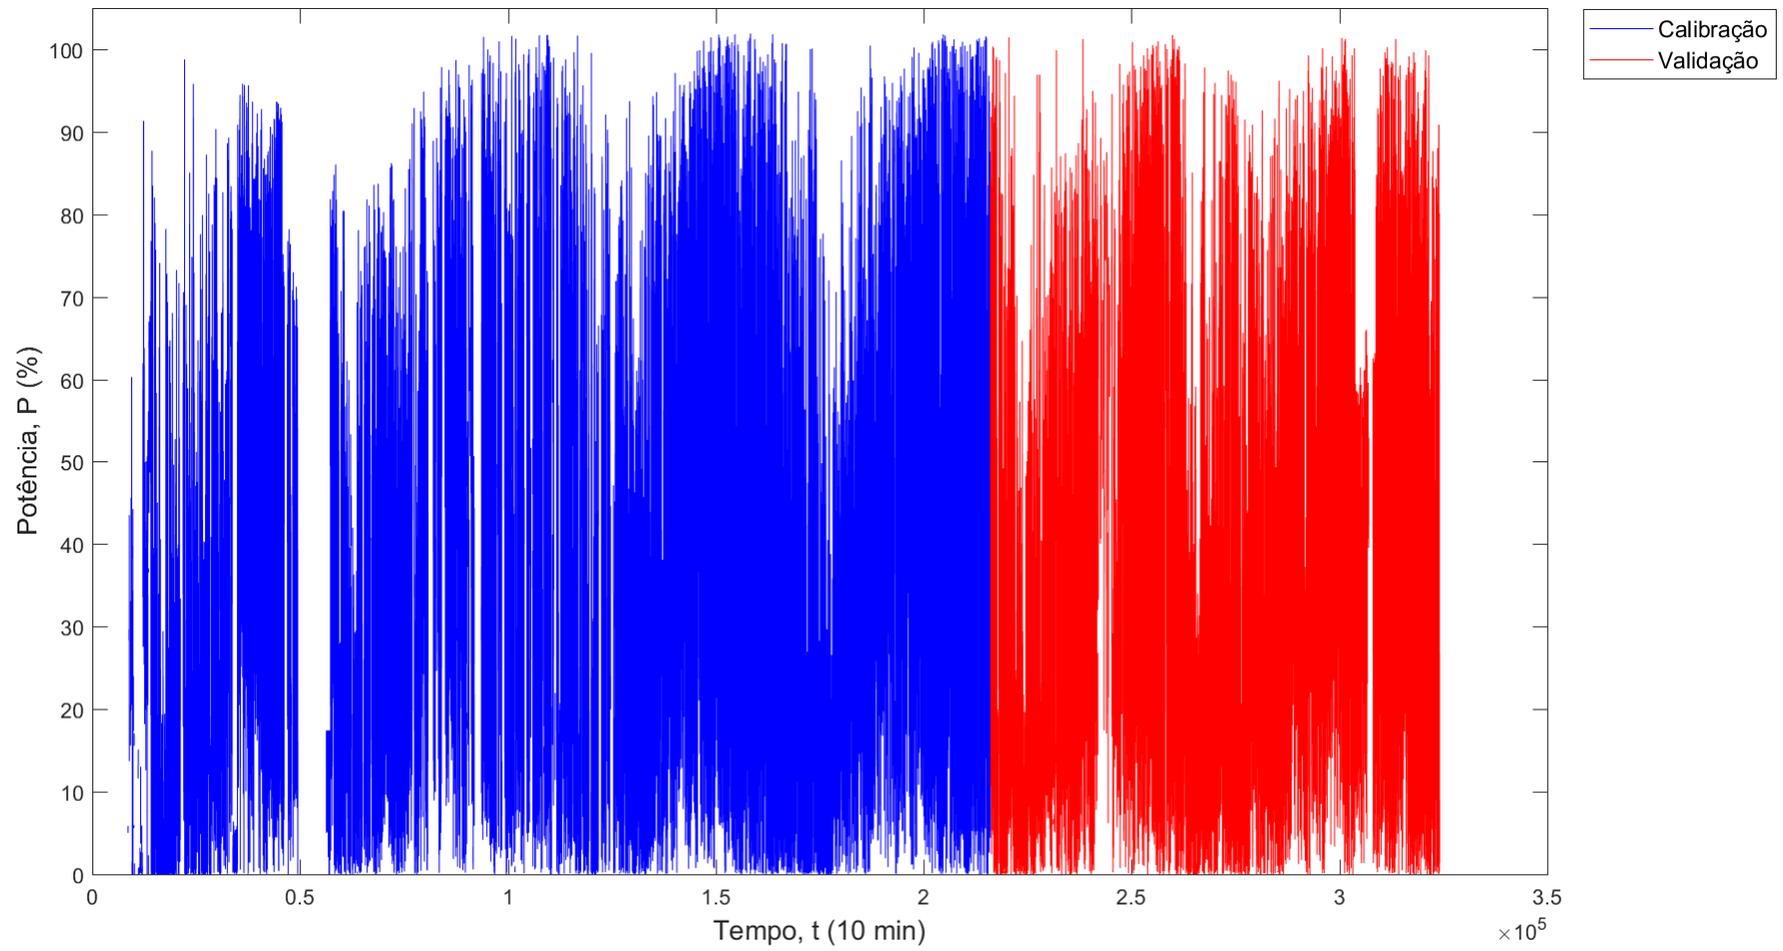
Figura 51 – Série temporal de G13



Fonte: Própria.

- Central G1

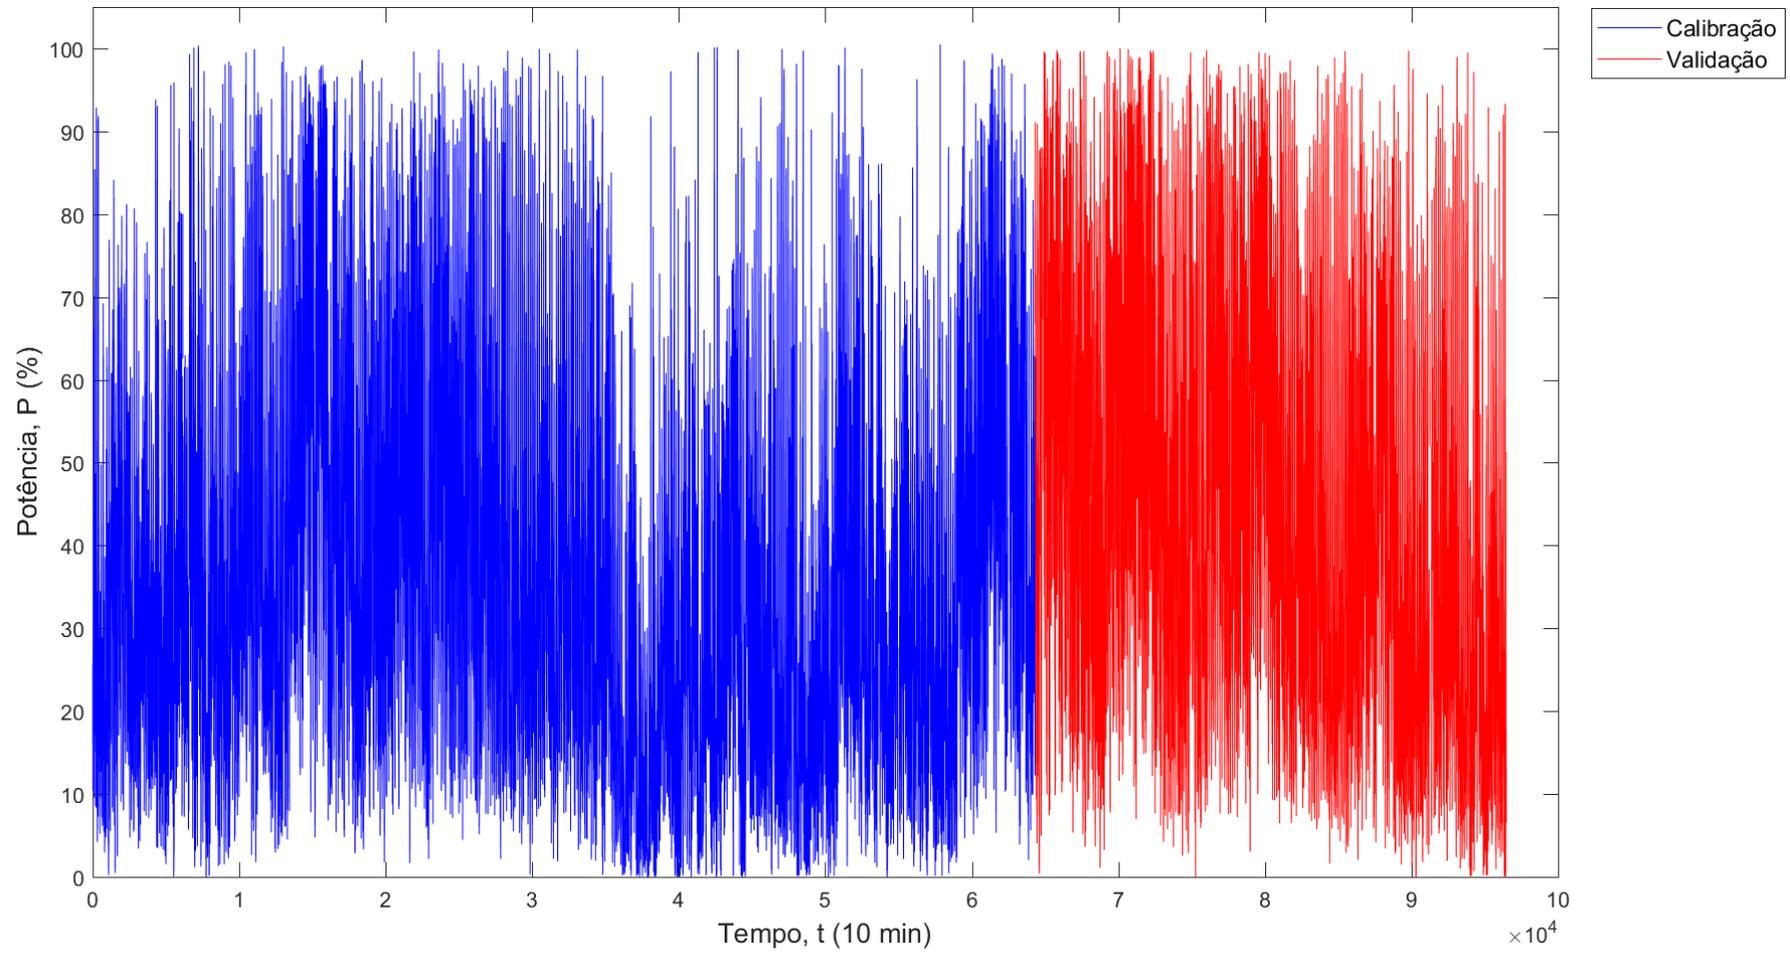
Figura 52 – Série temporal de G1



Fonte: Própria.

- Central G8

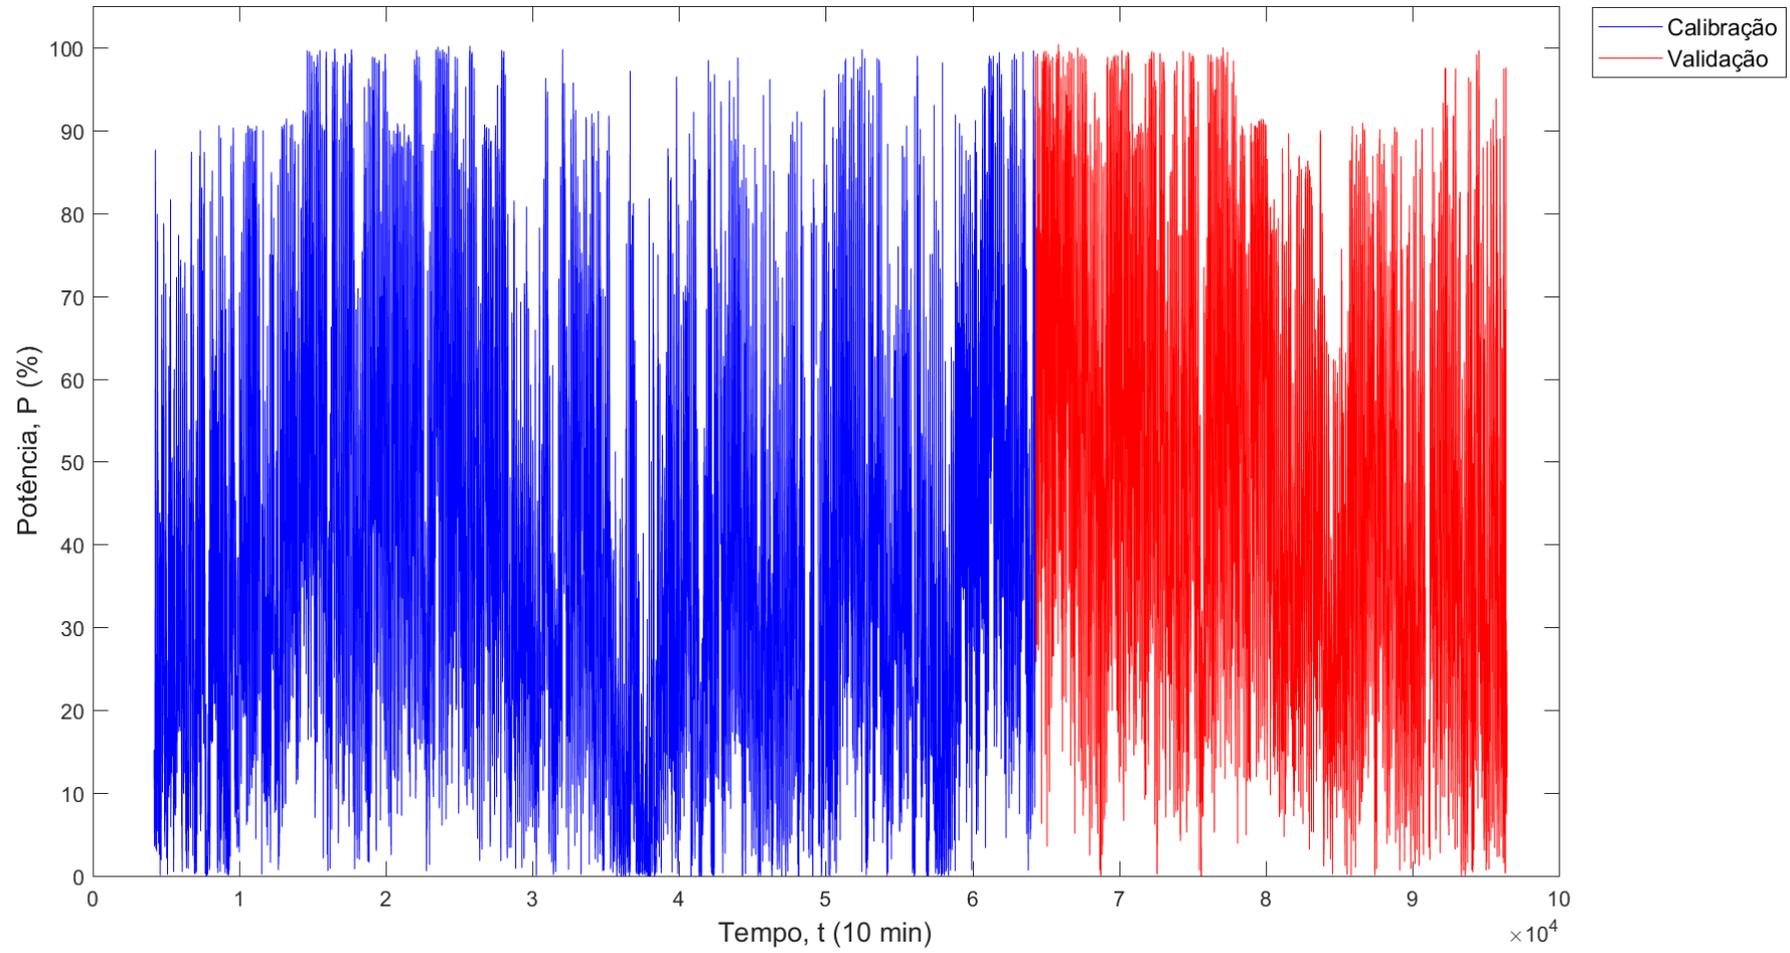
Figura 53 – Série temporal de G8



Fonte: Própria.

- Central G11

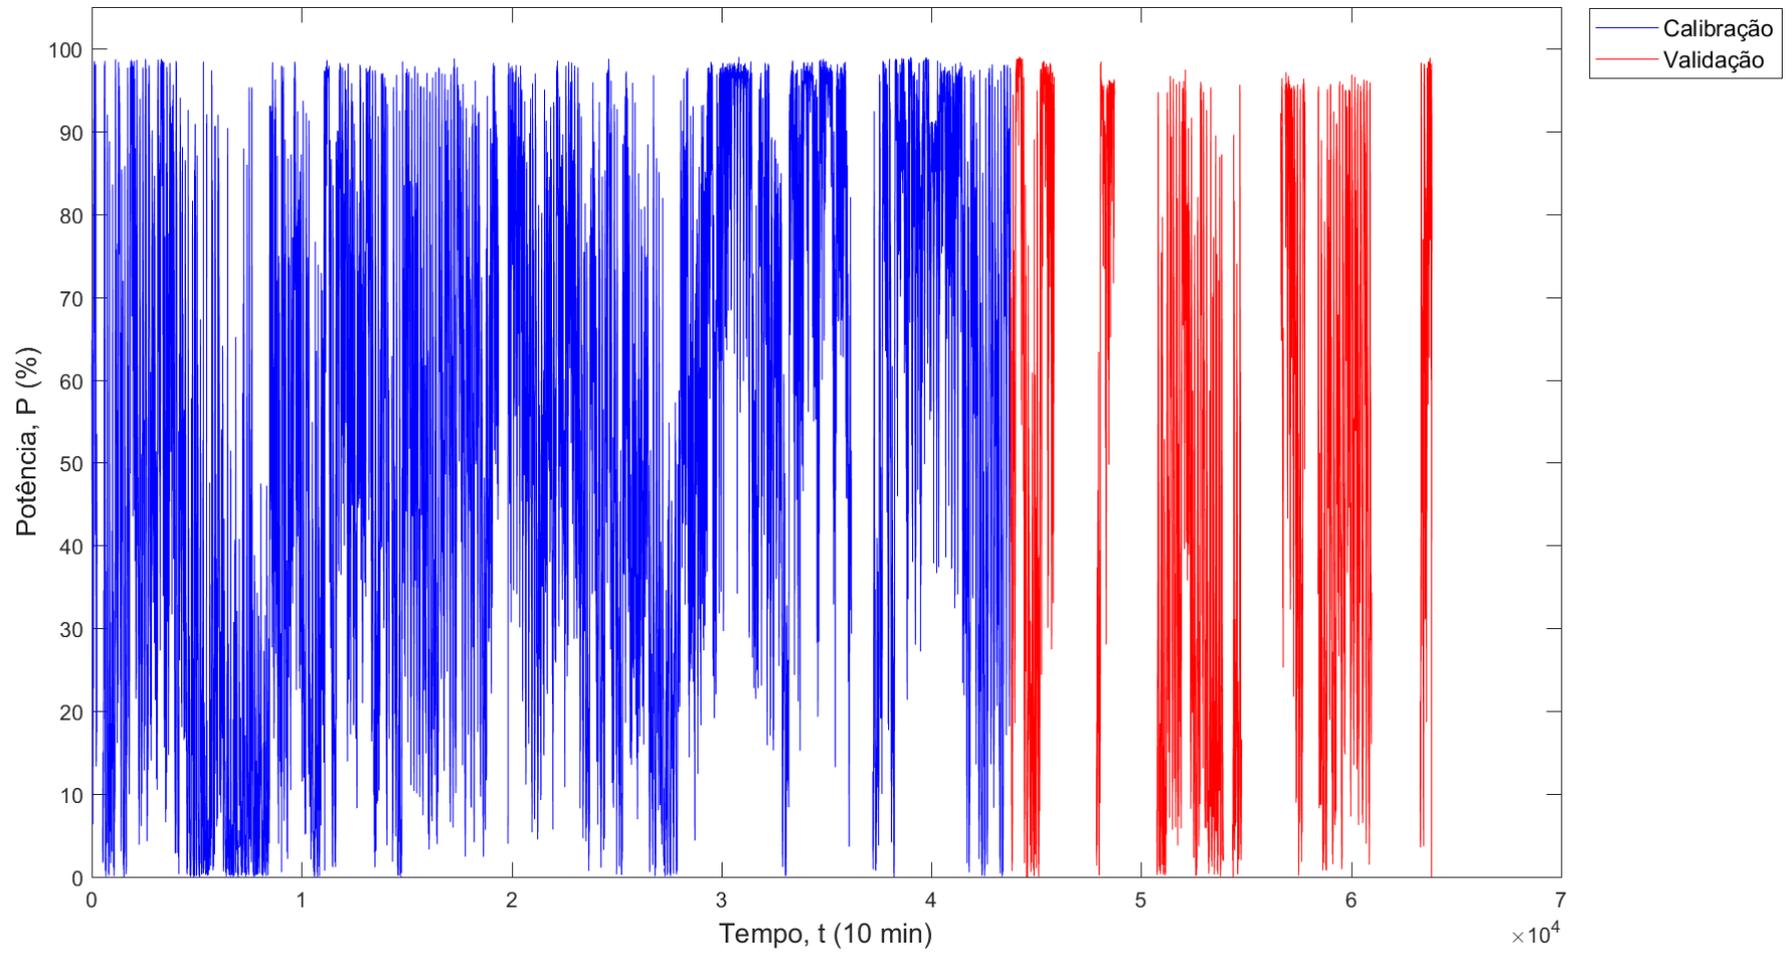
Figura 54 – Série temporal de G11



Fonte: Própria.

- Central G7

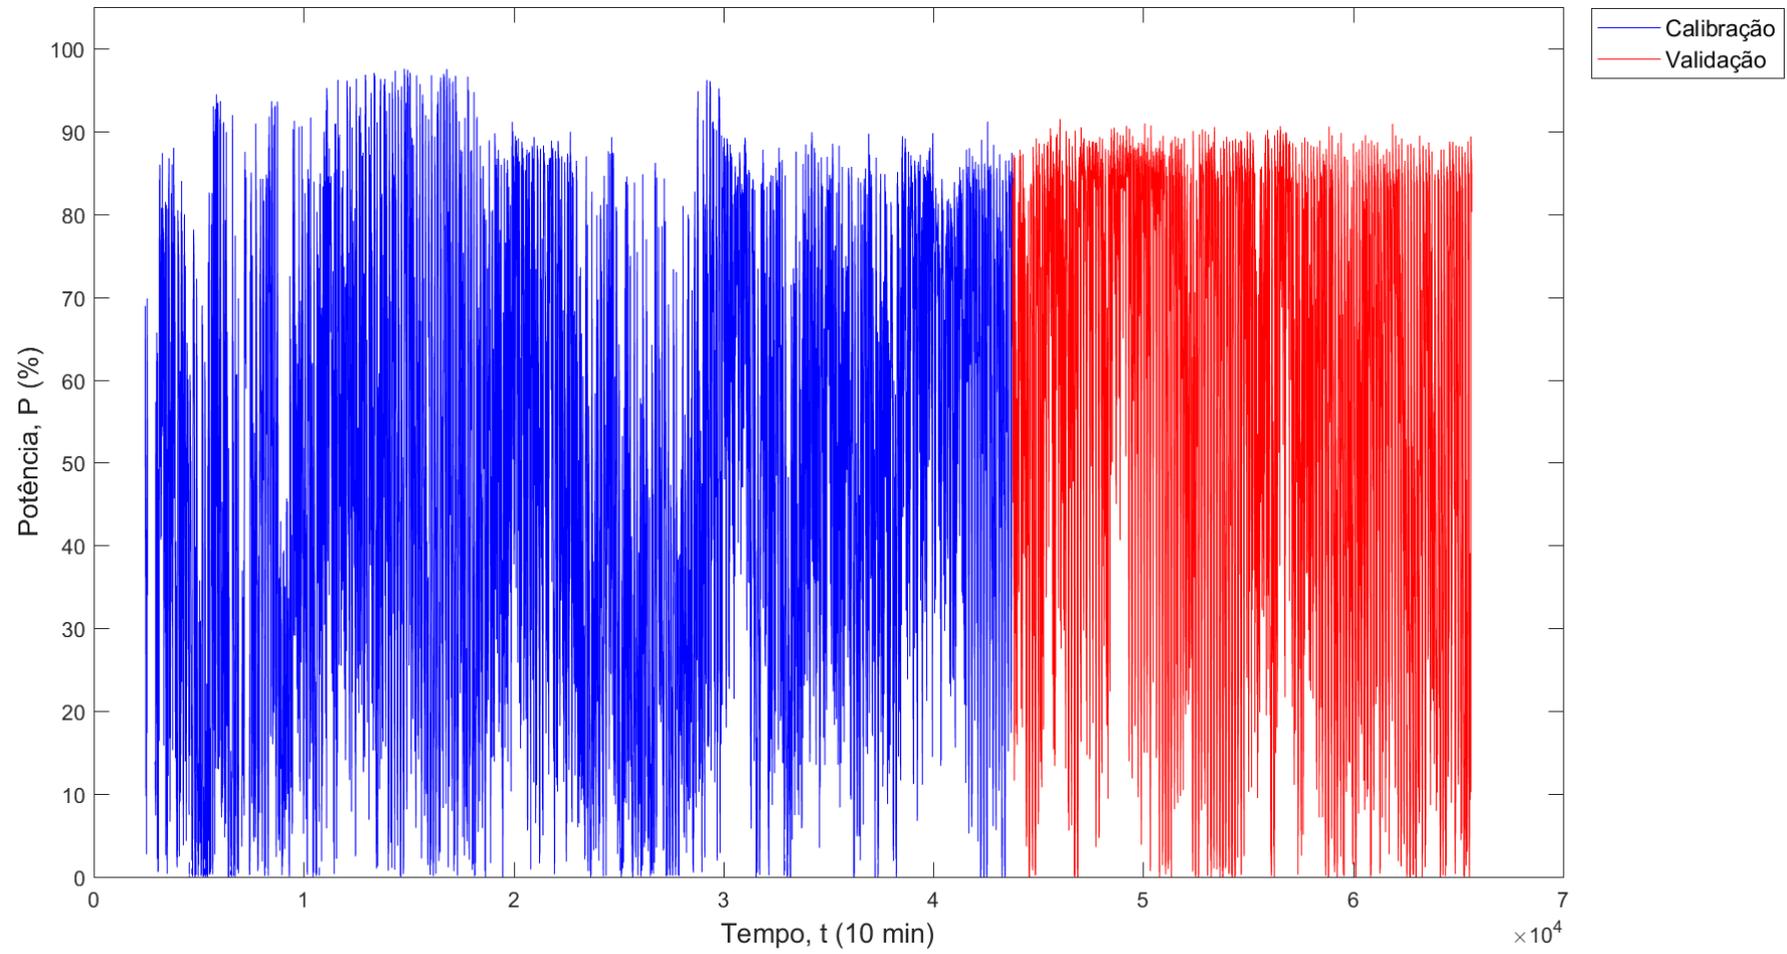
Figura 55 – Série temporal de G7



Fonte: Própria.

- Central G10

Figura 56 – Série temporal e G10



Fonte: Própria.

APÊNDICE B - EVOLUÇÃO DO BIAS

Este apêndice apresenta a evolução do *bias* de cada modelo, incluindo a persistência, em função do horizonte de previsão. O *bias* nada mais é que a diferença entre as médias da observação e da previsão de cada modelo, como descrito na Equação 25.

$$bias = \bar{y} - \hat{y} \quad (25)$$

Apenas o modelo L5 não é contemplado nestes gráficos, pois o valor absoluto de seus *bias* é muito elevado, dificultando a visualização dos *bias* dos demais modelos.

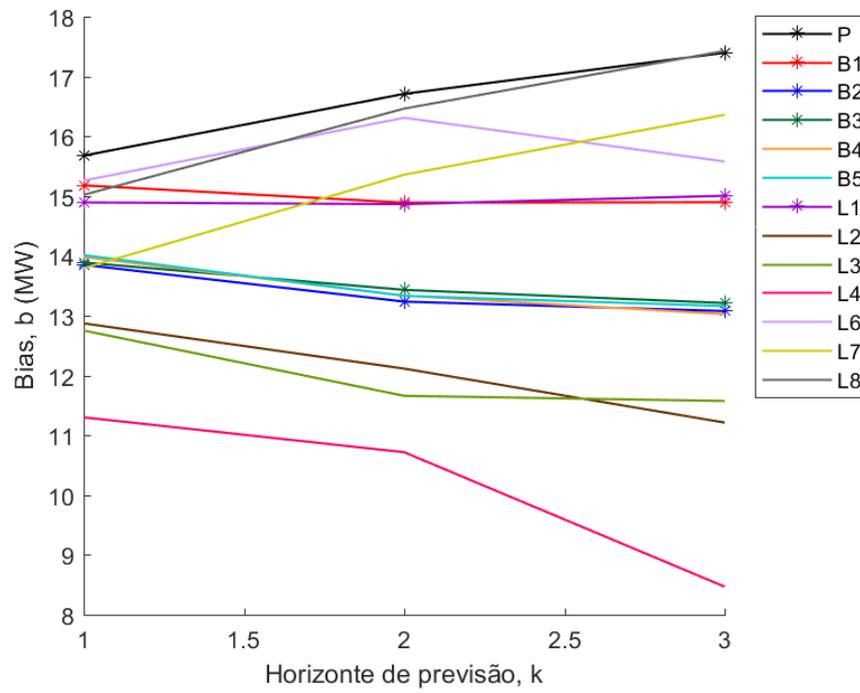
Analisando a evolução do *bias* sobre toda a série temporal, percebe-se que, para todas as centrais estudadas, os modelos, em geral, tendem a sobrestimar cada vez mais a média da observação a medida que o horizonte aumenta, chegando a variar até 5% da potência nominal da central. Apenas os modelos L7 e L8 apresentam *bias* quase invariável em função do horizonte de previsão.

No que diz respeito aos eventos de rampa, a média da série observada tende a ser subestimada nos eventos de rampa de subida e sobrestimada nos eventos de rampa de descida. Em ambos os regimes, o *bias* chega a alcançar cerca de 18% da potência nominal nos piores casos.

A seguir, seguem os gráficos de evolução do *bias* em função do horizonte de previsão para toda a série temporal e para os regimes de rampa de descida e rampa de subida, separadamente.

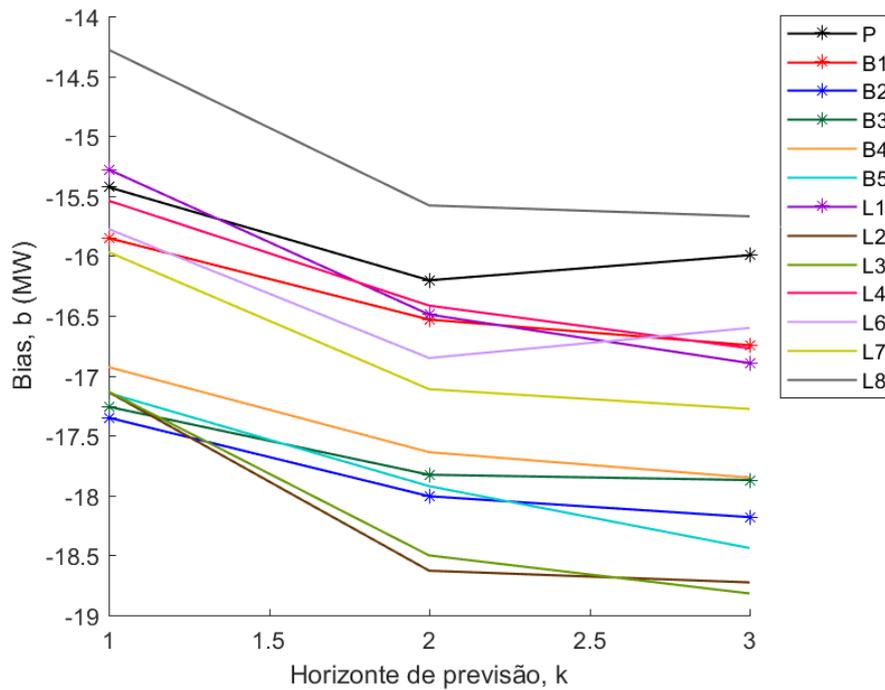
- Central G4

Figura 57 – Evolução do *bias* sobre as rampas de subida de G4



Fonte: Própria.

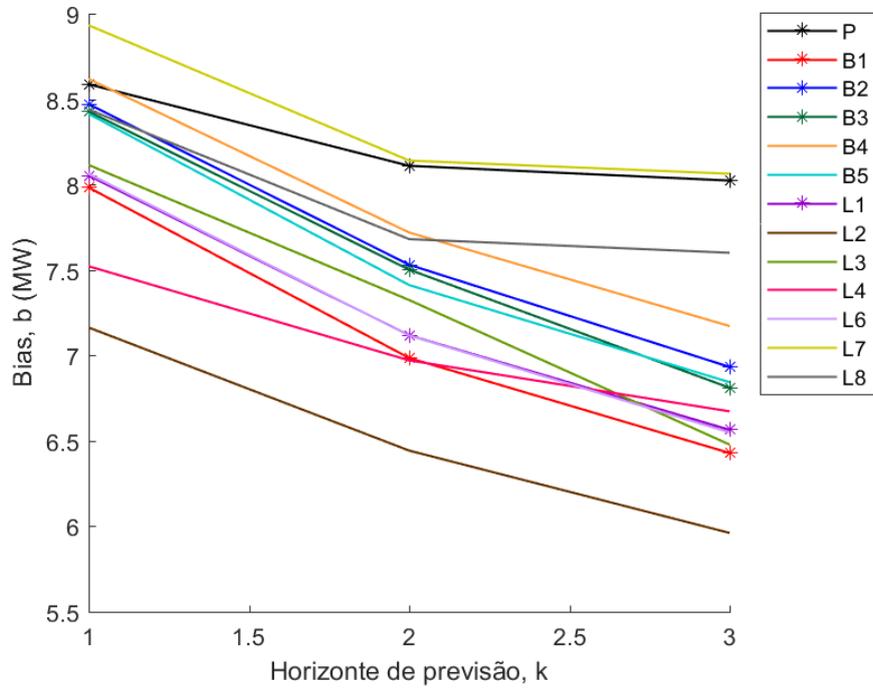
Figura 58 – Evolução do *bias* sobre as rampas de descida de G4



Fonte: Própria.

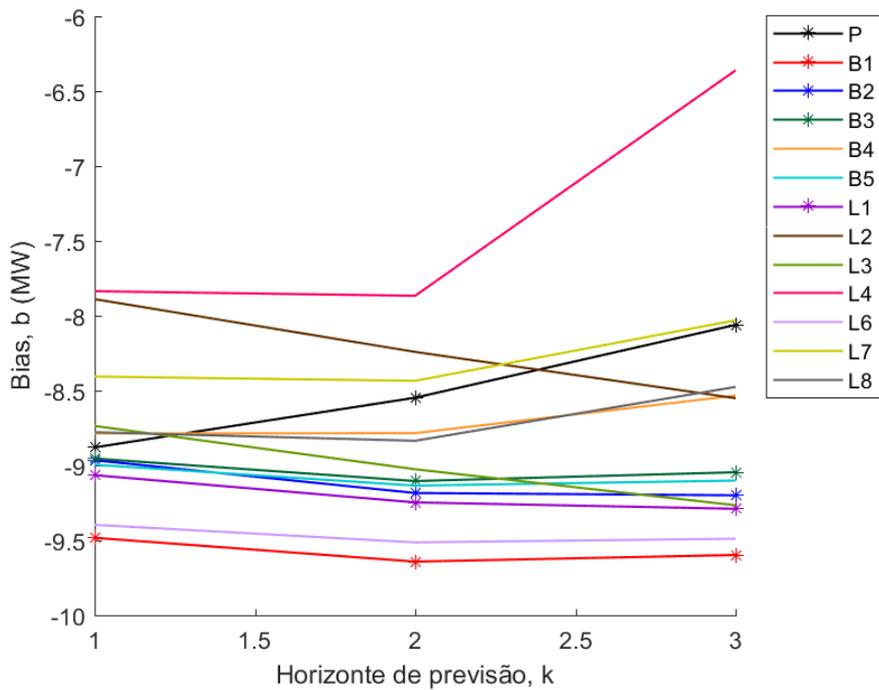
- Central G13

Figura 59 – Evolução do *bias* sobre as rampas de subida de G13



Fonte: Própria.

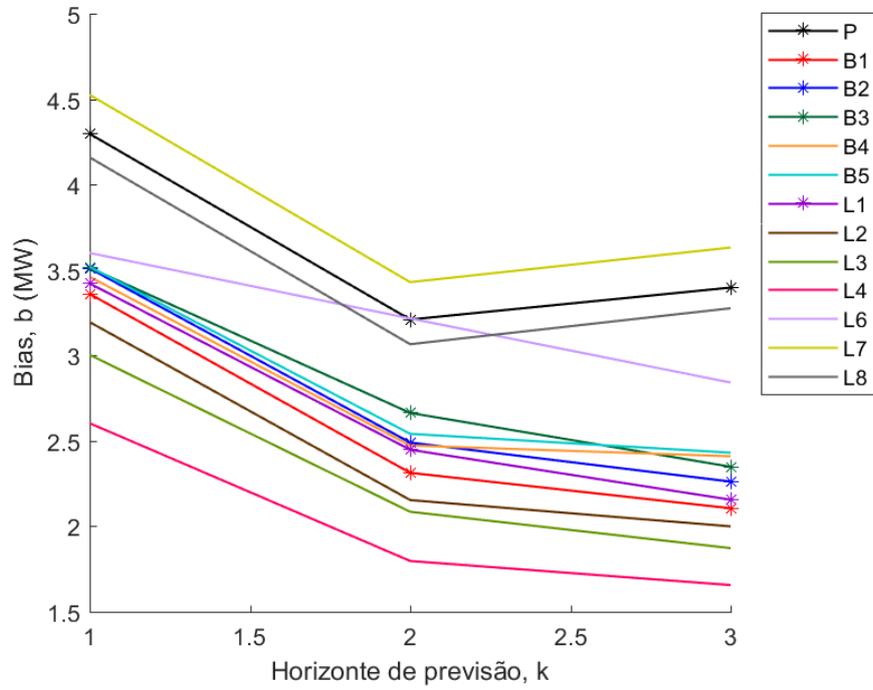
Figura 60 – Evolução do *bias* sobre as rampas de descida de G13



Fonte: Própria.

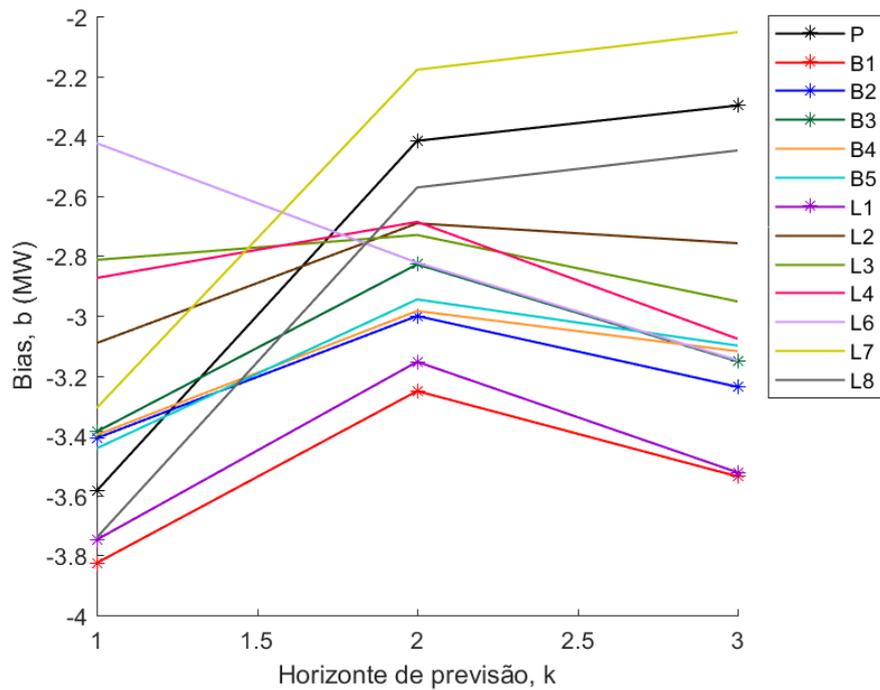
- Central G8

Figura 61 – Evolução do *bias* sobre as rampas de subida de G8



Fonte: Própria.

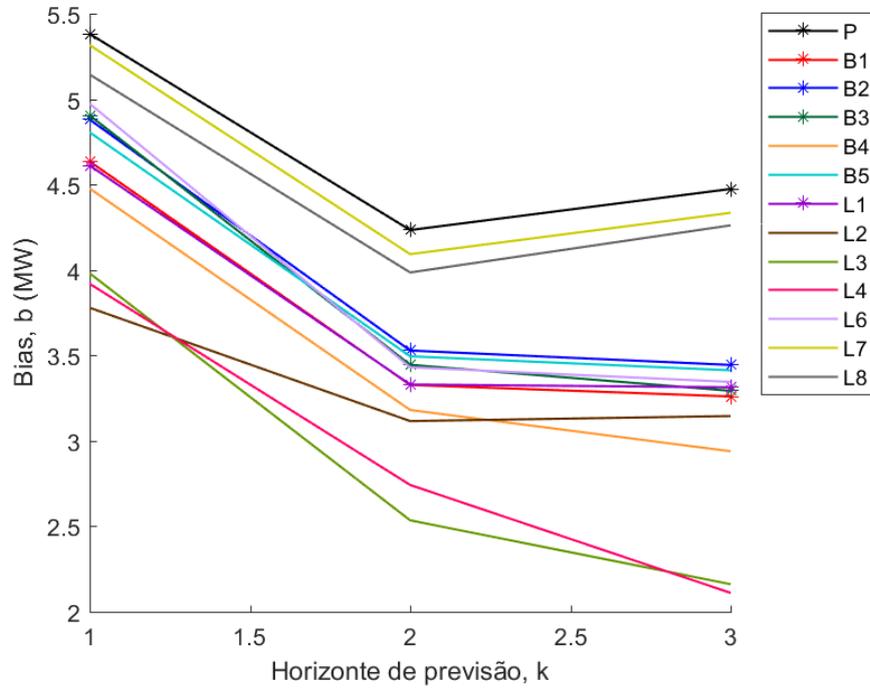
Figura 62 – Evolução do *bias* sobre as rampas de descida de G8



Fonte: Própria.

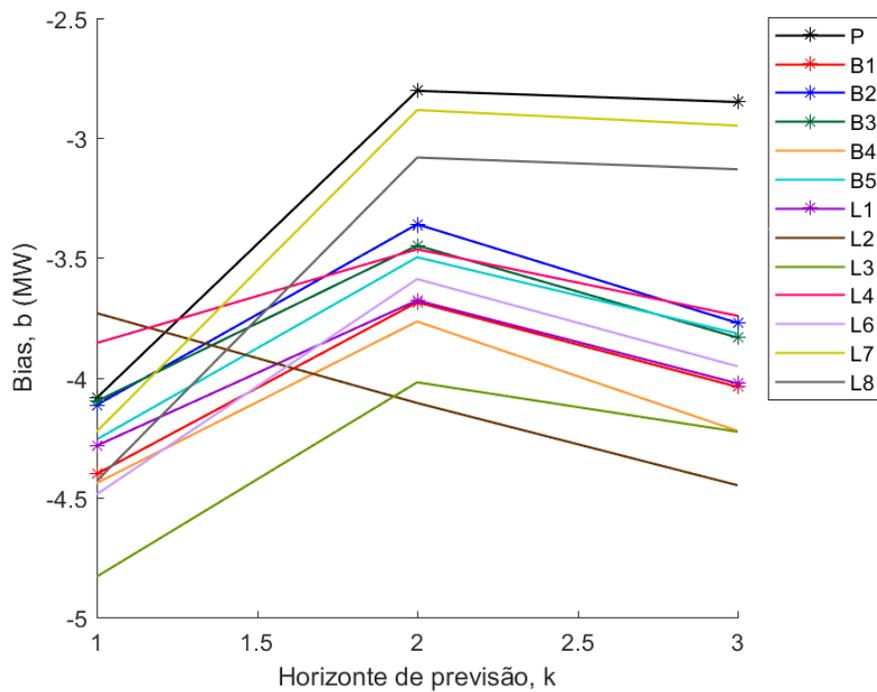
- Central G7

Figura 63 – Evolução do *bias* sobre as rampas de subida de G7



Fonte: Própria.

Figura 64 – Evolução do *bias* sobre as rampas de descida de G7



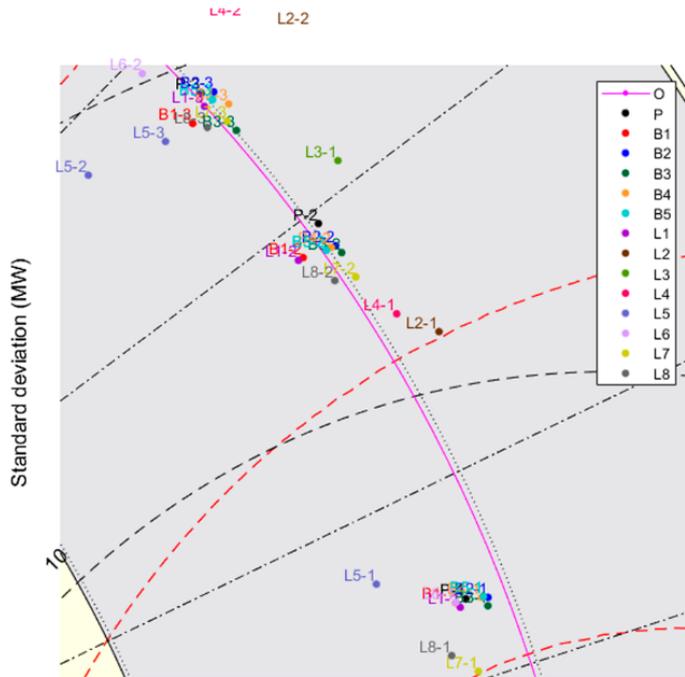
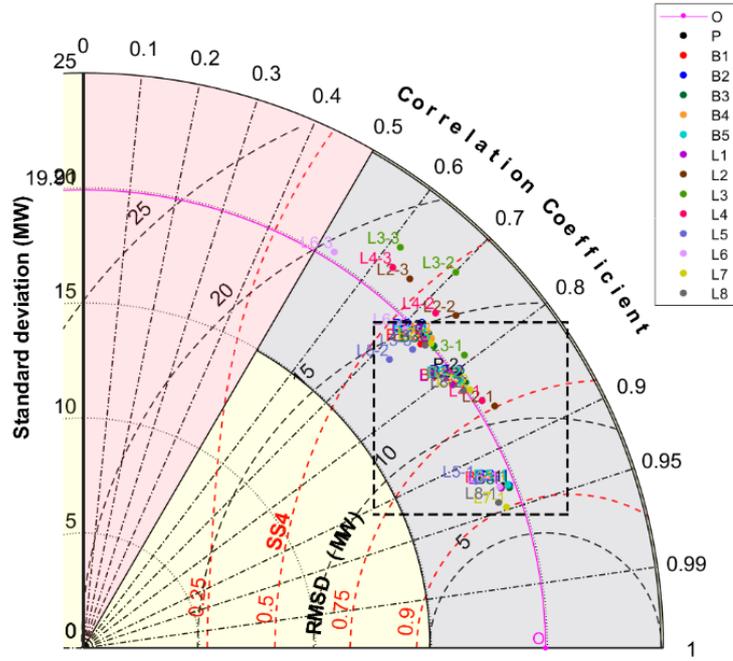
Fonte: Própria.

APÊNDICE C - DIAGRAMAS DE TAYLOR

A seguir, estão apresentados os diagramas de Taylor referentes a cada um dos grupos citados na seção de resultados, porém sem nenhuma omissão.

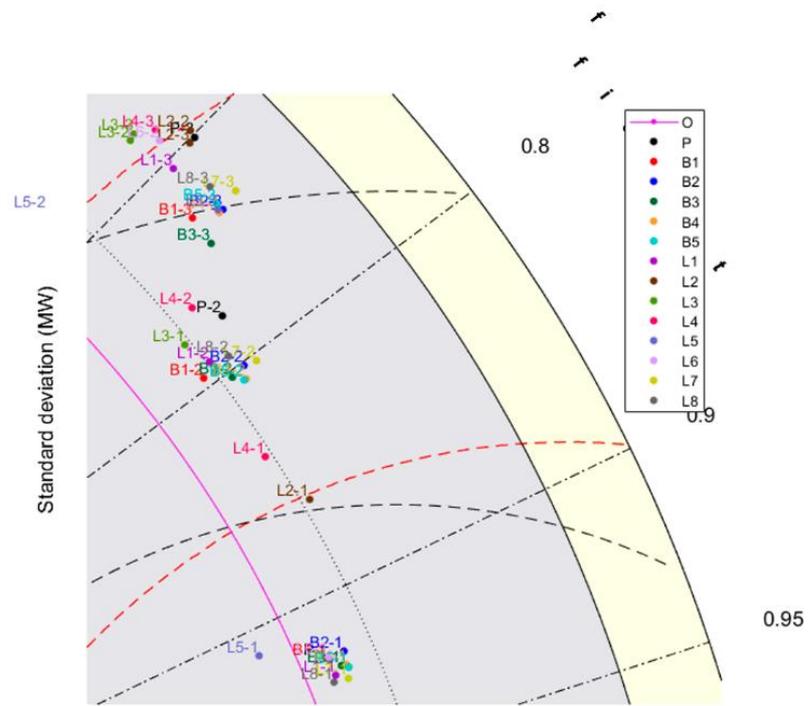
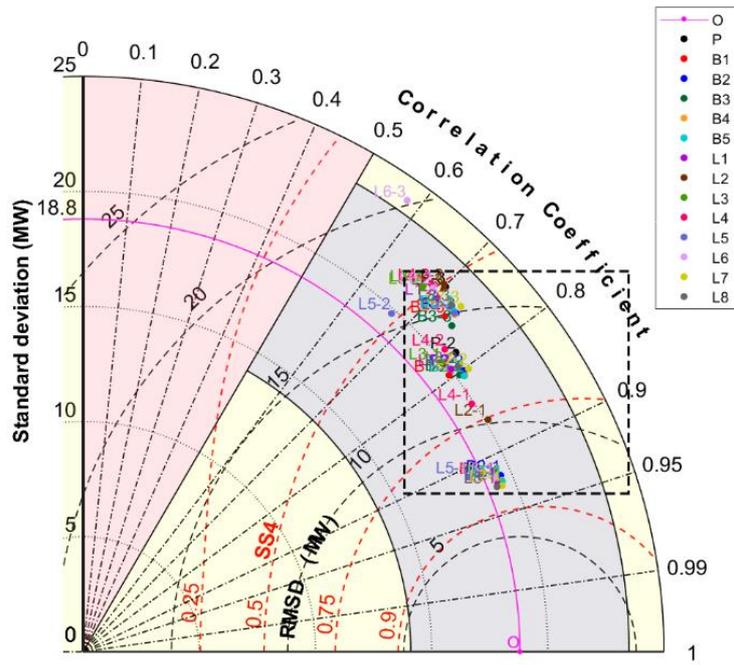
- Grupo A - Central G4

Figura 65 - Diagrama de Taylor sobre as rampas de subida de G4



Fonte: Própria.

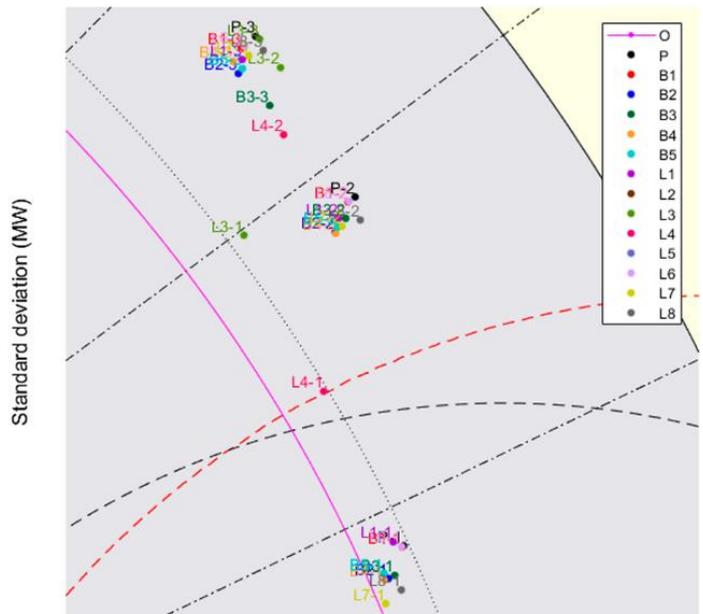
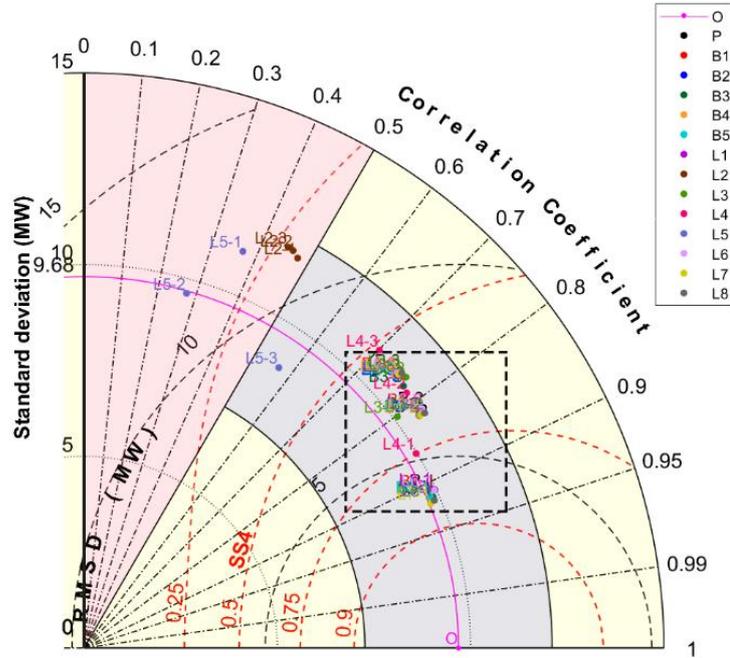
Figura 66 - Diagrama de Taylor sobre as rampas de descida de G4



Fonte: Própria.

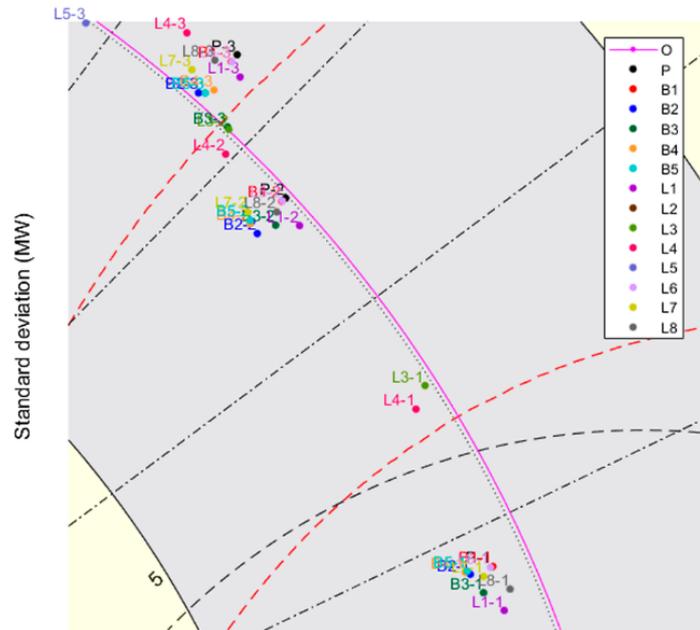
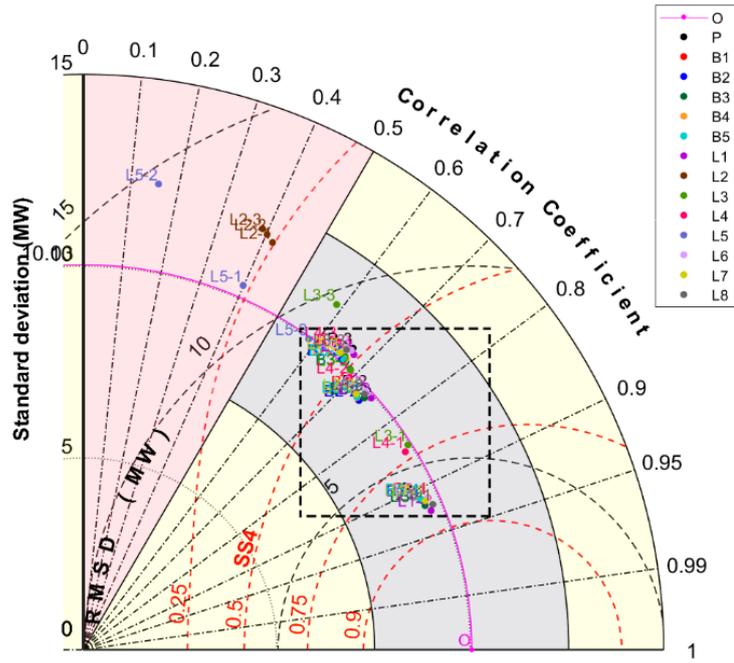
- Grupo B - Central G13

Figura 67 - Diagrama de Taylor sobre as rampas de subida de G13



Fonte: Própria.

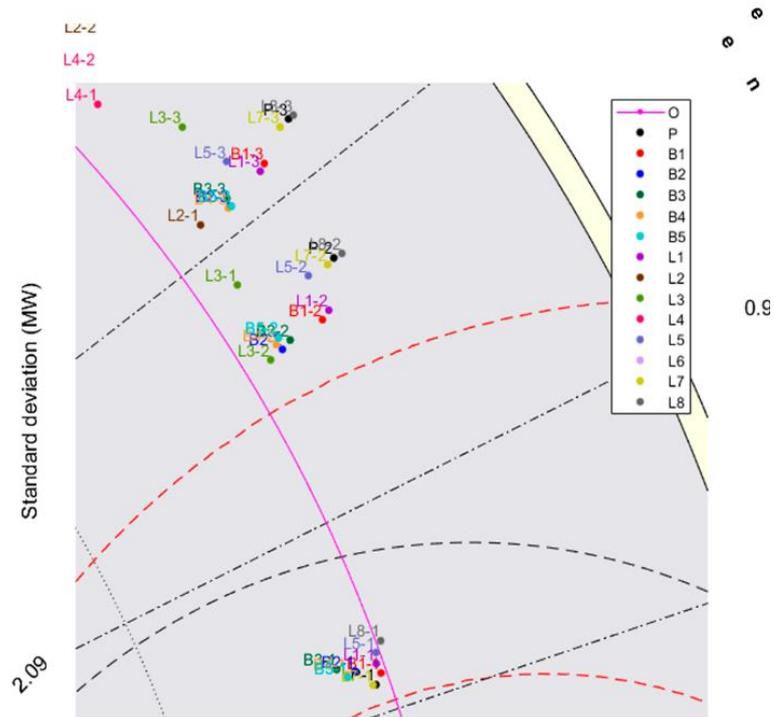
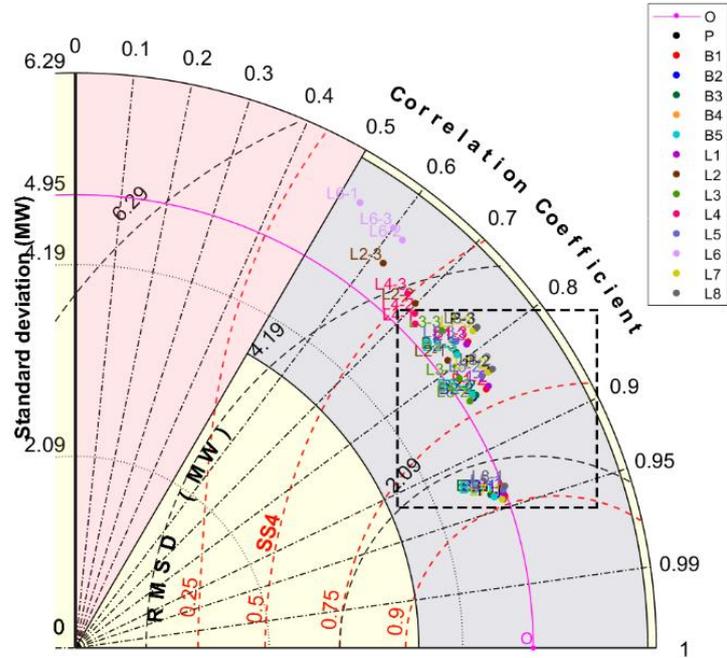
Figura 68 - Diagrama de Taylor sobre as rampas de descida de G13



Fonte: Própria.

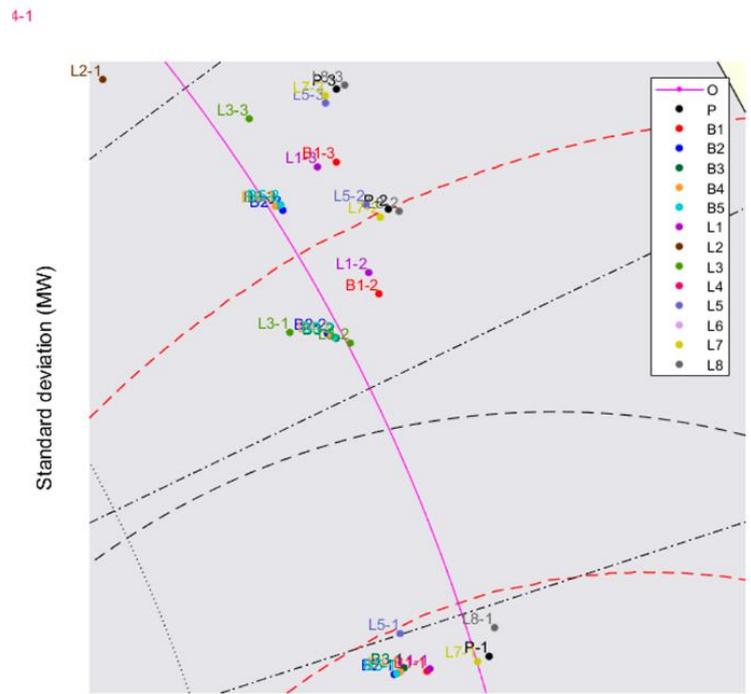
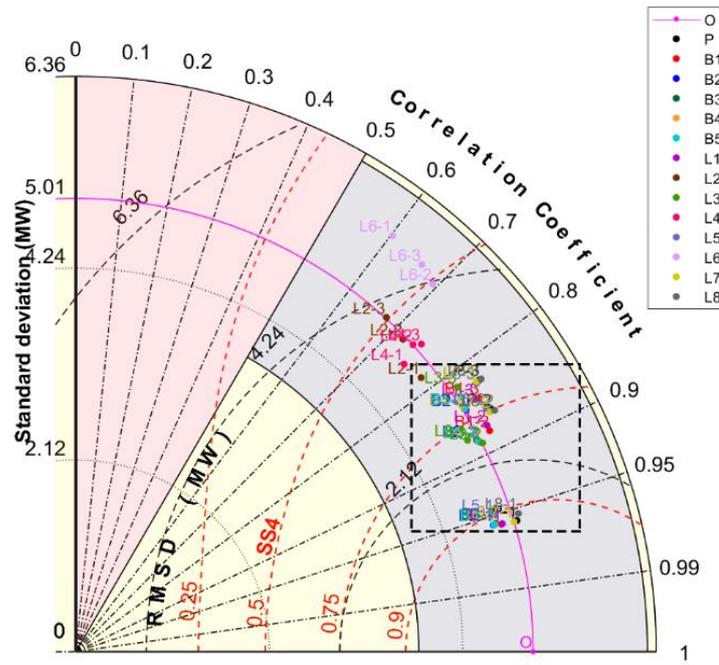
- Grupo C - Central G8

Figura 69 - Diagrama de Taylor sobre as rampas de subida de G8



Fonte: Própria.

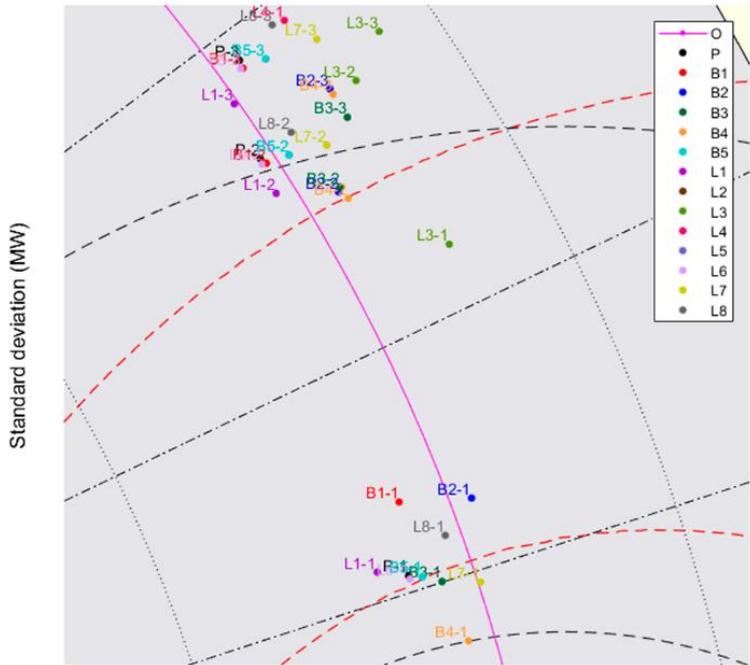
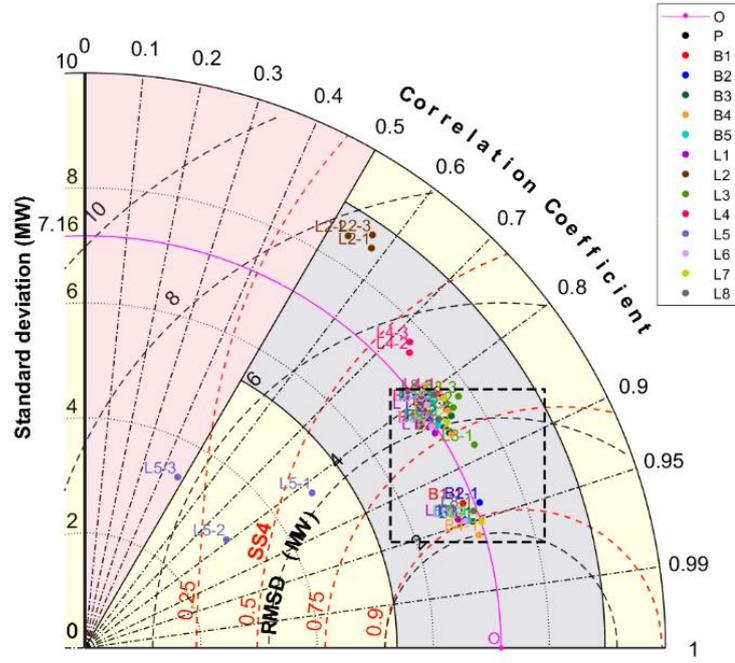
Figura 70 - Diagrama de Taylor sobre as rampas de descida de G8



Fonte: Própria.

- Grupo D - Central G7

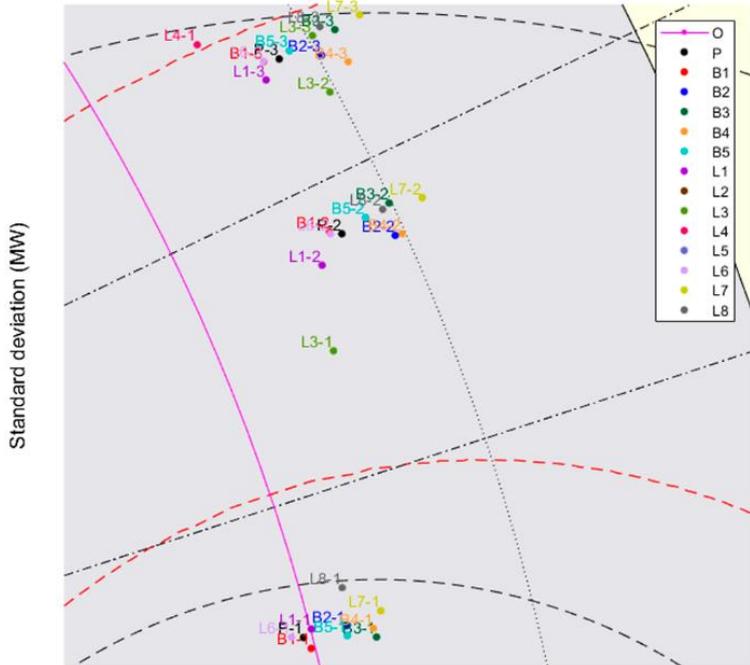
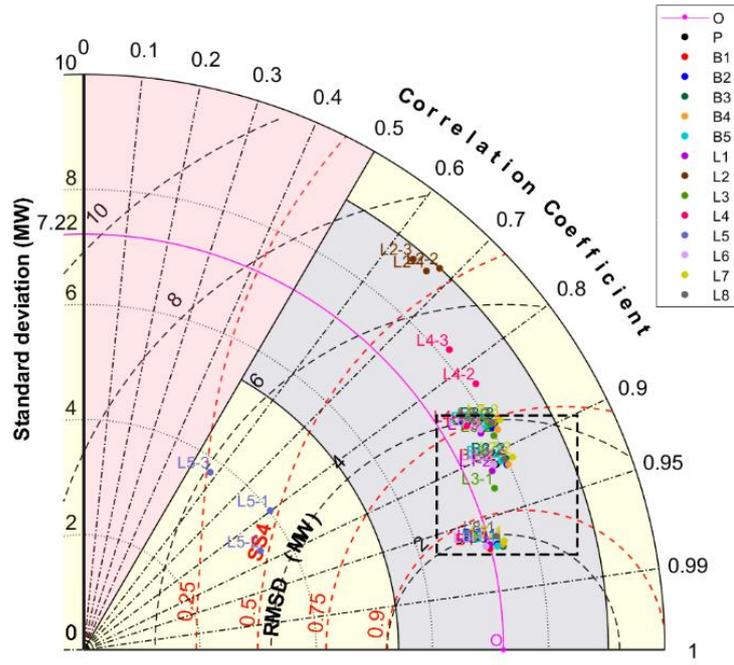
Figura 71 - Diagrama de Taylor sobre as rampas de subida de G7



2

Fonte: Própria.

Figura 72 - Diagrama de Taylor sobre as rampas de descida de G7



Fonte: Própria.

APÊNDICE D - RESULTADOS ESTATÍSTICOS

Nesta seção são apresentados os estatísticos obtidos a partir das previsões dos modelos, propostos quando aplicados a cada grupo de centrais, e utilizados na geração dos gráficos de Melhora sobre a Persistência (IoP), a qual utiliza o erro médio quadrático (MSE), e Diagramas de Taylor, que, por sua vez, utiliza a correlação (ρ), a raiz do erro médio quadrático das diferenças (RMSD), o *skill score* de Taylor (SS4) e os desvios padrão da previsão (σ_m) e da observação (σ_o), representados, aqui, pela sua razão ($\hat{\sigma}_m$).

Em cada tabela, o melhor resultado de cada estatístico está destacado em negrito, discriminando o tipo de rampa, o horizonte de previsão e o modelo de previsão.

- Grupo A - Central G4

Tabela 4 – Resultados estatísticos de cada modelo para a central G4

Estatístico	Rampa	Horizonte	Modelos														
			P	B1	B2	B3	B4	B5	L1	L2	L3	L4	L5	L6	L7	L8	
IoP (%)	Subida	1	-	5,19	4,13	3,63	4,12	2,95	8,42	4,88	-1,97	3,31	-238,39	4,36	7,85	-7,00	
		2	-	13,44	13,26	13,23	12,19	12,90	13,57	14,03	10,93	14,33	55,42	-14,10	7,62	-1,43	
		3	-	15,41	12,66	17,09	13,47	13,25	13,83	18,08	22,22	12,17	-22,50	-20,79	5,35	-2,42	
	Descida	1	-	-4,53	-20,15	-14,99	-17,61	-16,06	3,42	-32,51	-37,44	-37,14	-	1188,81	-3,77	5,72	20,47
		2	-	4,31	-6,65	-3,25	-3,65	-4,36	3,58	-36,55	-20,36	-16,57	-224,88	-23,23	5,03	14,34	
		3	-	3,88	-4,25	0,03	-1,97	-7,39	-2,09	-15,62	-4,49	-18,74	-525,79	-31,41	2,12	10,20	
ρ (%)	Subida	1	93,15	93,15	93,31	93,49	93,25	93,26	93,29	86,01	79,03	84,78	91,92	93,14	94,80	94,29	
		2	80,50	81,21	81,56	81,90	81,52	81,49	81,19	74,32	70,10	72,17	72,47	70,79	82,92	82,60	
		3	73,26	74,01	73,61	75,49	74,43	73,82	73,80	65,92	61,71	62,76	73,78	53,18	74,93	74,57	
	Descida	1	92,00	91,97	91,98	92,38	92,41	92,51	92,59	86,56	77,63	84,09	90,97	91,97	92,83	92,77	
		2	77,67	79,50	80,17	80,29	80,73	80,71	79,04	69,74	67,82	76,42	67,03	68,96	80,33	79,39	
		3	70,15	73,01	73,74	74,60	73,73	73,33	70,50	70,18	67,72	68,39	73,58	57,97	73,48	72,46	

$\hat{\sigma}_m$	Subida	1	0,9744	0,9673	0,9882	0,9861	0,9842	0,9856	0,9690	1,0351	1,0433	1,0176	0,9242	0,9675	0,9659	0,9529
		2	1,0085	0,9874	1,0092	1,0098	1,0062	1,0025	0,9839	1,0848	1,1498	1,0561	0,9138	0,9851	1,0083	0,9957
		3	1,0039	0,9865	1,0104	1,0047	1,0123	1,0064	0,9996	1,0715	1,1113	1,0669	0,9655	1,0206	1,0042	0,9919
	Descida	1	1,0247	1,0232	1,0390	1,0323	1,0367	1,0374	1,0247	1,0708	1,0587	1,0578	0,9721	1,0252	1,0336	1,0212
		2	1,0987	1,0537	1,0872	1,0734	1,0820	1,0801	1,0660	1,1851	1,1441	1,0834	1,0532	1,1609	1,0981	1,0817
		3	1,1833	1,1344	1,1581	1,1313	1,1539	1,1577	1,1520	1,1771	1,1502	1,1652	1,1547	1,2798	1,1767	1,1632
RMSD	Subida	1	7,29	7,28	7,25	7,14	7,26	7,27	7,21	10,74	13,20	11,09	7,85	7,28	6,35	6,64
		2	12,49	12,14	12,15	12,05	12,15	12,13	12,12	14,96	16,78	15,31	14,23	15,11	11,69	11,73
		3	14,60	14,27	14,55	13,98	14,33	14,46	14,42	17,08	18,51	17,81	14,19	19,48	14,13	14,15
	Descida	1	7,63	7,63	7,71	7,48	7,49	7,45	7,34	10,18	12,99	10,96	7,89	7,64	7,27	7,24
		2	13,30	12,40	12,46	12,31	12,24	12,23	12,63	16,30	16,36	13,53	15,70	16,25	12,49	12,65
		3	16,17	14,93	14,96	14,47	14,92	15,07	15,76	16,10	16,45	16,43	14,97	20,20	15,22	15,36
SS4 (%)	Subida	1	86,93	86,88	87,26	87,59	87,15	87,16	87,16	74,72	64,09	72,83	84,27	86,88	89,90	88,85
		2	66,33	67,38	67,90	68,41	67,85	67,81	67,34	57,33	51,32	54,75	54,85	53,16	69,96	69,48
		3	56,32	57,29	56,77	59,28	57,85	57,05	57,03	47,15	42,27	43,68	56,94	34,39	58,53	58,04
	Descida	1	84,89	84,84	84,78	85,52	85,55	85,72	85,93	75,35	62,02	71,55	83,06	84,83	86,32	86,27
		2	61,74	64,71	65,39	65,70	66,27	66,26	63,96	50,41	48,68	60,15	48,52	49,82	65,52	64,33
		3	50,93	55,12	55,74	57,20	55,78	55,22	51,77	51,05	48,50	49,10	55,57	36,65	55,13	54,05

- Grupo B - Central G13

Tabela 5 – Resultados estatísticos de cada modelo para a central G13

Estatístico	Rampa	Horizonte	Modelos													
			P	B1	B2	B3	B4	B5	L1	L2	L3	L4	L5	L6	L7	L8
IoP (%)	Subida	1	-	11,06	2,67	3,16	2,81	2,84	9,54	-89,71	-2,93	-2,96	1158,31	9,62	-10,73	-2,14
		2	-	16,31	10,18	8,69	10,37	11,09	15,62	-56,42	6,86	4,98	-963,49	14,53	-3,32	3,08
		3	-	20,02	16,01	15,83	15,96	16,30	19,39	-35,47	16,63	11,06	-359,19	18,63	-1,59	3,91
	Descida	1	-	-11,59	4,06	6,77	3,74	2,22	-0,03	101,74	6,91	-6,61	2084,90	-9,87	16,79	11,14
		2	-	-15,71	-2,31	0,84	-2,76	-4,15	-6,86	-63,45	2,92	-9,00	1543,24	-13,78	7,05	1,96
		3	-	-19,60	-7,95	4,53	-6,83	-7,37	-13,44	-60,06	5,93	-16,00	-914,88	-18,03	3,84	-2,12
ρ (%)	Subida	1	91,05	91,07	91,65	91,64	91,65	91,49	90,85	47,73	80,21	86,11	36,90	91,05	92,20	92,04
		2	81,39	81,39	81,97	81,79	82,01	81,87	81,65	46,24	76,25	78,20	27,54	81,39	81,93	82,11
		3	74,78	74,76	75,40	77,06	74,94	75,36	75,10	45,11	74,95	70,13	56,73	74,79	75,16	75,36
	Descida	1	91,36	91,36	91,30	92,01	91,17	91,17	92,74	41,81	84,36	84,98	39,87	91,36	91,54	92,22
		2	73,49	73,47	73,86	74,18	73,21	73,08	75,01	40,15	68,76	69,57	15,79	73,48	72,68	73,70
		3	66,33	66,34	66,13	68,61	66,67	66,42	67,26	38,85	58,83	63,43	58,36	66,37	64,99	65,62

$\hat{\sigma}_m$	Subida	1	1,0292	1,0280	1,0121	1,0165	1,0091	1,0107	1,0243	1,1948	1,0429	1,0299	1,1491	1,0279	1,0042	1,0166
		2	1,1139	1,1083	1,0906	1,1012	1,0905	1,0938	1,0974	1,2070	1,1273	1,1017	0,9935	1,1090	1,0963	1,1081
		3	1,1284	1,1167	1,1047	1,1066	1,1073	1,1086	1,1124	1,2093	1,1292	1,1248	0,9167	1,1189	1,1170	1,1262
	Descida	1	0,9698	0,9708	0,9529	0,9565	0,9500	0,9518	0,9657	1,1646	0,9909	0,9756	1,0319	0,9690	0,9614	0,9759
		2	0,9945	0,9906	0,9605	0,9750	0,9616	0,9633	0,9883	1,1780	1,0006	0,9855	1,2251	0,9913	0,9663	0,9823
		3	1,0468	1,0400	1,0057	1,0014	1,0151	1,0090	1,0356	1,1870	1,1089	1,0348	0,9943	1,0401	1,0158	1,0325
RMSD	Subida	1	4,17	4,16	3,98	4,00	3,98	4,02	4,20	10,99	6,24	5,19	11,75	4,16	3,83	3,90
		2	6,33	6,31	6,14	6,21	6,13	6,17	6,22	11,21	7,19	6,79	11,62	6,31	6,17	6,19
		3	7,41	7,36	7,21	6,98	7,29	7,24	7,29	11,34	7,39	8,03	8,66	7,37	7,30	7,32
	Descida	1	4,12	4,12	4,11	3,95	4,14	4,14	3,77	11,80	5,59	5,44	11,18	4,12	4,07	3,92
		2	7,29	7,28	7,12	7,13	7,21	7,24	7,05	12,05	7,94	7,77	14,59	7,28	7,30	7,22
		3	8,44	8,41	8,28	7,96	8,26	8,26	8,27	12,24	9,65	8,74	9,13	8,40	8,46	8,46
SS4 (%)	Subida	1	83,20	83,23	84,31	84,29	84,30	84,02	82,87	28,84	65,79	74,91	21,53	83,21	85,29	84,98
		2	66,87	66,95	68,02	67,63	68,08	67,83	67,46	27,60	59,45	62,43	16,54	66,94	67,90	68,02
		3	57,48	57,59	58,58	60,80	57,94	58,48	58,09	26,73	57,70	51,64	37,43	57,61	58,11	58,27
	Descida	1	83,73	83,74	83,51	84,78	83,25	83,27	86,14	24,70	72,19	73,14	23,90	83,73	83,99	85,27
		2	56,61	56,59	57,01	57,49	56,17	56,00	58,62	23,48	50,69	51,67	10,79	56,60	55,50	56,88
		3	47,73	47,77	47,61	50,51	48,22	47,94	48,85	22,56	39,35	44,54	39,30	47,81	46,31	46,97

- Grupo C - Central G8

Tabela 6 – Resultados estatísticos de cada modelo para a central G8

Estatístico	Rampa	Horizonte	Modelos													
			P	B1	B2	B3	B4	B5	L1	L2	L3	L4	L5	L6	L7	L8
IoP (%)	Subida	1	-	32,74	27,37	28,55	27,16	27,26	30,21	0,54	23,47	-9,85	-85,04	-90,07	-10,57	2,16
		2	-	30,61	28,10	27,74	22,83	25,62	26,72	-3,92	44,06	1,58	-210,34	-63,67	-7,53	3,69
		3	-	32,89	32,93	29,31	31,47	29,72	32,66	-0,93	34,53	15,51	-248,32	-30,51	-6,83	2,66
	Descida	1	-	-11,00	8,71	8,91	9,73	7,26	-7,39	-33,84	5,50	-33,10	-	-95,63	13,91	-8,18
		2	-	-26,57	-11,87	-9,94	-4,09	-8,87	-24,27	-59,75	3,32	-56,83	-	-94,32	9,63	-4,85
		3	-	-41,06	-22,88	-18,72	-19,81	-18,03	-40,40	-62,12	-26,78	-48,17	-	-	8,44	-4,42
ρ (%)	Subida	1	94,35	94,14	93,89	93,70	93,91	93,97	93,90	78,84	81,58	72,02	93,66	53,45	94,34	93,44
		2	82,82	84,35	84,45	84,32	84,19	84,03	84,20	69,85	84,53	70,85	82,81	62,16	82,89	82,85
		3	77,82	78,54	78,98	78,68	79,01	79,03	78,68	62,07	75,29	68,03	77,54	59,96	77,85	77,83
	Descida	1	95,78	95,73	95,62	95,57	95,61	95,62	95,71	78,06	87,82	74,92	94,98	60,23	95,81	95,37
		2	86,26	88,03	88,32	88,52	88,41	88,48	87,44	72,00	88,80	73,65	85,84	69,34	86,33	86,44
		3	82,70	84,44	84,79	84,59	84,57	84,63	84,27	67,76	81,97	74,40	82,86	66,33	82,68	82,74

$\hat{\sigma}_m$	Subida	1	0,9902	0,9960	0,9795	0,9681	0,9736	0,9734	0,9951	1,0314	1,0279	1,0305	0,9974	1,1624	0,9882	1,0033
		2	1,0930	1,0638	1,0298	1,0377	1,0279	1,0316	1,0709	1,0624	1,0192	1,0459	1,0717	1,1489	1,0869	1,0992
		3	1,1229	1,0913	1,0551	1,0567	1,0533	1,0558	1,0860	1,0830	1,0632	1,0663	1,0718	1,1579	1,1150	1,1271
	Descida	1	1,0071	0,9726	0,9551	0,9612	0,9587	0,9564	0,9744	0,9674	0,9754	0,9580	0,9648	1,1495	1,0003	1,0145
		2	1,0551	1,0279	0,9930	0,9960	0,9940	0,9956	1,0286	0,9934	1,0016	1,0012	1,0456	1,1255	1,0491	1,0595
		3	1,0663	1,0443	1,0057	1,0041	1,0034	1,0063	1,0343	1,0025	1,0182	1,0156	1,0571	1,1410	1,0592	1,0712
RMSD	Subida	1	1,66	1,69	1,72	1,74	1,71	1,70	1,73	3,28	3,05	3,77	1,76	5,22	1,66	1,80
		2	3,07	2,88	2,81	2,83	2,83	2,85	2,91	3,98	2,79	3,88	3,03	4,68	3,05	3,08
		3	3,55	3,42	3,31	3,34	3,31	3,31	3,40	4,51	3,61	4,11	3,46	4,84	3,53	3,56
	Descida	1	1,46	1,45	1,47	1,48	1,47	1,47	1,46	3,27	2,45	3,48	1,57	4,85	1,45	1,54
		2	2,71	2,49	2,41	2,40	2,41	2,40	2,55	3,74	2,37	3,64	2,74	4,21	2,69	2,70
		3	3,06	2,87	2,77	2,79	2,79	2,79	2,86	4,03	3,04	3,61	3,03	4,45	3,05	3,07
SS4 (%)	Subida	1	89,16	88,79	88,29	87,89	88,30	88,41	88,35	63,87	67,89	54,68	87,91	33,88	89,13	87,51
		2	69,26	71,91	72,27	72,04	71,88	71,61	71,61	51,82	72,44	53,15	69,47	42,40	69,44	69,25
		3	61,65	63,03	63,95	63,51	64,00	64,01	63,27	42,85	58,78	49,62	61,80	40,05	61,80	61,61
	Descida	1	91,83	91,65	91,33	91,28	91,35	91,34	91,62	62,76	77,74	58,41	90,22	40,41	91,88	91,05
		2	75,00	78,07	78,60	78,95	78,76	78,88	77,08	54,70	79,41	56,83	74,40	50,68	75,17	75,27
		3	69,35	72,19	72,88	72,56	72,53	72,62	71,97	49,50	68,50	57,81	69,67	47,01	69,38	69,37

- Grupo D - Central G7

Tabela 7 – Resultados estatísticos de cada modelo para a central G7

Estatístico	Rampa	Horizonte	Modelos															
			P	B1	B2	B3	B4	B5	L1	L2	L3	L4	L5	L6	L7	L8		
IoP (%)	Subida	1	-	17,18	13,82	25,23	20,52	16,91	21,26	-94,28	17,30	-4,20	-7919,91	12,53	1,58	3,21		
		2	-	20,55	22,61	26,47	25,34	17,11	23,38	-94,74	24,76	-0,62	-723,29	18,46	3,41	3,16		
		3	-	24,44	26,60	35,02	29,70	21,65	26,24	-62,46	39,21	13,08	-8637,05	23,00	3,31	2,01		
	Descida	1	-	-12,16	-4,70	-12,43	-4,23	-7,14	-8,83	-	197,00	-12,65	-97,72	-	17329,37	-17,40	-7,38	-16,22
		2	-	-31,72	-21,79	-37,32	-25,76	-26,51	-27,35	-	242,34	-40,98	-	-2626,60	-27,59	-7,72	-10,83	
		3	-	-35,55	-29,04	-44,59	-31,02	-29,42	-32,00	-	198,58	-27,41	-	-	18135,22	-32,62	-7,91	-10,06
ρ (%)	Subida	1	94,69	93,29	93,72	94,99	96,06	94,80	94,45	57,89	88,48	80,80	82,33	94,76	95,20	94,21		
		2	83,88	84,10	85,89	85,80	86,18	84,25	85,01	53,46	83,49	73,64	79,14	84,05	84,60	83,73		
		3	81,00	81,27	83,28	84,24	83,46	81,44	82,03	56,77	82,69	72,46	47,35	81,24	81,85	80,69		
	Descida	1	96,83	96,99	96,82	97,04	96,93	96,94	96,76	66,73	92,94	86,14	79,86	96,79	96,75	96,35		
		2	91,07	90,94	91,49	90,91	91,51	90,97	91,45	67,85	88,46	82,50	87,08	90,98	91,07	90,97		
		3	87,33	87,22	87,70	87,36	88,08	87,28	87,60	64,10	87,24	76,99	57,62	87,21	87,34	87,15		

$\hat{\sigma}_m$	Subida	1	0,9650	0,9741	1,0119	0,9814	0,9856	0,9720	0,9495	1,1897	1,0581	1,0468	0,6628	0,9652	1,0013	0,9914
		2	0,9927	0,9942	1,0194	1,0214	1,0221	1,0070	0,9897	1,1832	1,0602	1,0591	0,4299	0,9918	1,0274	1,0148
		3	1,0140	1,0130	1,0457	1,0452	1,0454	1,0261	0,9978	1,2173	1,0858	1,0772	0,4706	1,0119	1,0552	1,0400
	Descida	1	0,9957	0,9980	1,0171	1,0301	1,0296	1,0165	1,0004	1,2234	1,0531	1,0595	0,5561	0,9901	1,0352	1,0201
		2	1,0792	1,0742	1,1024	1,1062	1,1058	1,0929	1,0641	1,2494	1,1044	1,1323	0,4832	1,0741	1,1219	1,1021
		3	1,0906	1,0834	1,1094	1,1211	1,1192	1,0969	1,0800	1,2244	1,1102	1,1313	0,5225	1,0834	1,1351	1,1154
RMSD	Subida	1	2,31	2,60	2,56	2,25	2,00	2,29	2,36	7,30	3,56	4,56	4,23	2,29	2,22	2,43
		2	4,05	4,03	3,85	3,86	3,81	4,04	3,90	7,63	4,26	5,37	5,09	4,03	4,04	4,12
		3	4,45	4,42	4,25	4,13	4,23	4,43	4,29	7,52	4,44	5,55	6,31	4,42	4,45	4,55
	Descida	1	1,81	1,77	1,84	1,80	1,83	1,81	1,84	6,71	2,81	3,94	4,69	1,82	1,89	1,98
		2	3,22	3,23	3,22	3,33	3,22	3,28	3,12	6,72	3,72	4,65	4,52	3,22	3,35	3,31
		3	3,85	3,85	3,86	3,94	3,83	3,88	3,78	6,96	3,93	5,30	5,92	3,85	3,99	3,96
SS4 (%)	Subida	1	89,69	87,18	88,01	90,31	92,33	89,92	89,11	37,69	78,62	66,65	58,59	89,82	90,74	88,91
		2	71,46	71,79	74,61	74,45	75,06	72,03	73,22	33,70	70,61	56,63	33,90	71,70	72,53	71,20
		3	67,07	67,47	70,38	71,87	70,66	67,69	68,62	36,33	69,15	54,98	17,50	67,42	68,15	66,52
	Descida	1	93,82	94,11	93,77	94,13	93,93	94,00	93,67	46,38	86,38	74,78	47,19	93,73	93,55	92,87
		2	82,82	82,65	83,24	82,18	83,23	82,48	83,65	47,23	78,07	68,26	46,99	82,72	82,21	82,34
		3	76,40	76,30	76,75	76,02	77,23	76,24	76,95	43,51	75,99	60,41	26,00	76,29	75,76	75,76