

**UNIVERSIDADE FEDERAL DE PERNAMBUCO  
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**

**Dilcelia Andreza Da Silva Souza**

**Previsão de rampas de potência ativa de centrais eólicas  
baseada na combinação entre modelo atmosférico  
mesoescalar e modelos de séries temporais**

**Recife, PE  
março, 2025**

**UNIVERSIDADE FEDERAL DE PERNAMBUCO  
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**

**Dilcelia Andreza Da Silva Souza**

**Previsão de rampas de potência ativa de centrais eólicas  
baseada na combinação entre modelo atmosférico  
mesoescalar e modelos de séries temporais**

**Dissertação de mestrado apresentada como  
exigência para obtenção de título de Mestre  
em Tecnologias Energéticas e Nucleares pelo  
PROTEN.**

**Orientador: Profa. Dra. Olga de Castro Vilela**

**Co-orientador: Prof. Dr. Alexandre Carlos Araújo da Costa**

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Souza, Dilcelia Andreza da Silva.

Previsão de rampas de potência ativa de centrais eólicas baseada na combinação entre modelo atmosférico mesoescalar e modelos de séries temporais / Dilcelia Andreza da Silva Souza. - Recife, 2025.

78f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares, 2025.

Orientação: Olga de Castro Vilela.

Coorientação: Alexandre Carlos Araújo da Costa.

Inclui referências.

1. Energia eólica; 2. Previsão de rampas; 3. Combinação de previsões; 4. Modelos de séries temporais; 5. WRF; 6. Clustering. I. Vilela, Olga de Castro. II. Costa, Alexandre Carlos Araújo da. III. Título.

UFPE-Biblioteca Central

**DILCELIA ANDREZA DA SILVA SOUZA**

**PREVISÃO DE RAMPAS DE POTÊNCIA ATIVA DE CENTRAIS EÓLICAS  
BASEADA NA COMBINAÇÃO ENTRE MODELO ATMOSFÉRICO  
MESOESCALAR E MODELOS DE SÉRIES TEMPORAIS**

Dissertação Apresentada ao Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociência - CTG, como requisito para a obtenção do título de Mestre em Tecnologias Energéticas e Nucleares. Área de Concentração: Fontes Renováveis de Energia.

Aprovado em: 21/05/2025

**BANCA EXAMINADORA**

Documento assinado digitalmente



**TSANG ING REN**

Data: 21/05/2025 16:56:07-0300

Verifique em <https://validar.iti.gov.br>

---

**Dra. Tsang Ing Ren(Examinadora Externa)**  
**Universidade Federal de Pernambuco - UFPE**

Documento assinado digitalmente



**GUSTAVO DE NOVAES PIRES LEITE**

Data: 21/05/2025 18:16:56-0300

Verifique em <https://validar.iti.gov.br>

---

**Dr. Gustavo de Novaes Pires Leite (Examinador Externo)**  
**Instituto Federal de Pernambuco - IFPE**

Documento assinado digitalmente



**EMMANUEL DAMILANO DUTRA**

Data: 21/05/2025 16:50:16-0300

Verifique em <https://validar.iti.gov.br>

---

**Dr. Emmanuel Damilano Dutra**  
**Universidade Federal de Pernambuco - UFPE**

## Agradecimentos

O trabalho a seguir contou com apoio em diferentes frentes, sendo assim, gostaria de listar aqui meus agradecimentos.

Agradeço ao Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares da UFPE (PROTEN-UFPE) por todo o auxílio durante os últimos anos, permitindo que este trabalho se tornasse realidade; Ao Centro de Energias Renováveis da UFPE (CER-UFPE) pela estrutura fornecida e profissionais sempre dispostos a ajudar; Ao Projeto IBITU.INTELIPREV (no âmbito do Programa de P&D ANEEL) pelo apoio durante a graduação em Engenharia de Energia na UFPE fundamental para a execução do trabalho aqui apresentado, projeto cuja continuação vem sendo financiada pelas empresas CESC, JAURU e CEC, tendo sido modificado o acrônimo para GERIBÁ&CSN.INTELIPREV.

Também gostaria de agradecer a algumas pessoas especiais que me acompanharam durante essa jornada.

Agradeço imensamente a minha família, e a Deus, não sou uma pessoa religiosa, mas não há outra explicação para minha caminhada até aqui, a não ser um Ser muito bom que sempre me acompanhou.

Em seguida meus agradecimentos seguem para meus amigos, nominalmente (ordem alfabética pra não ter briga), Ana Reis e Filipe Guedes, que nos momentos mais difíceis seguraram a minha mão e não me deixaram nem cogitar a possibilidade de desistir. Aos demais amigos da Elétron, que fazem parte da equipe incrível de gestão, vocês são os motivos que me fizeram conseguir sustentar mestrado e vida profissional, muito obrigada!

Gostaria de agradecer a todas e todos do CER - UFPE, vocês são incríveis, cada aula, reunião, conversa, evento... tudo vale e valeu a pena, aprendi muito com cada um. Durante minha graduação e meu mestrado eu aprendi que fazer pesquisa não é fácil, é doloroso, é cansativo, e mesmo assim, eu conheci uma série de pessoas extraordinárias que dedicaram boa parte de suas vidas à pesquisa e ao meio acadêmico, e a vocês eu sou muito grata. Eu aprendi o quão importante é a pesquisa, e como ela nos faz nos sentirmos completos e realizados. Fazer pesquisa é viver no futuro, é procurar entender o desconhecido, é buscar o que ainda não foi encontrado. Sou muito grata à Universidade Federal de Pernambuco pela oportunidade, e à professora Olga e ao professor Alexandre que me orientaram nesses anos.

*Se avexe não  
Toda caminhada começa no primeiro passo  
A natureza não tem pressa, segue seu compasso  
Inexoravelmente chega lá  
Se avexe não  
Observe quem vai subindo a ladeira  
Seja princesa ou seja lavadeira  
Pra ir mais alto, vai ter que suar  
- Flavio Jose*

## LISTA DE FIGURAS

- Figura 1 - Exemplo de método K-Means
- Figura 2 - Extração de features
- Figura 3 - Rede Neural MLP
- Figura 4 - Destaque de evento de rampa
- Figura 5 - Definição de rampa conforme Zhang, 2017
- Figura 6 - Metodologia Ouyang et al., 2019
- Figura 7 - Metodologia Zhou et al., 2021
- Figura 8 - Metodologia Zucatelli et al., 2021
- Figura 9 - Metodologia de Clemente, 2018
- Figura 10 - Metodologia de Okada, et al., 2018
- Figura 11 - Fluxograma da metodologia
- Figura 12 - Avaliação da Qualidade de dados
- Figura 13 - Diagrama modelagem curva de potência
- Figura 14 - Diagrama representando o modelo G1
- Figura 15 - Diagrama representando o modelo G2
- Figura 16 - Diagrama representando o modelo G3
- Figura 17 - Diagrama representando modelo G4
- Figura 18 - Diagrama representando o modelo G5
- Figura 19 - Exemplo de agrupamento em central eólica
- Figura 20 - Exemplo de aplicação do método da Silhueta para estimativa de quantidade de Clusters
- Figura 21 - Diagrama representando o modelo L1
- Figura 22 - Diagrama representando o modelo L2
- Figura 23 - Diagrama representando o modelo L3
- Figura 24 - Diagrama representando o modelo L4
- Figura 25 - Combinação dos modelos
- Figura 26 - Coordenadas da central de interesse
- Figura 27 - Série de Potência
- Figura 28 - Previsão Persistência  $k=1$
- Figura 29 - Previsão Persistência  $k=4$
- Figura 30 - Diferença entre a Previsão e Observação - Persistência
- Figura 31 - Correlação dos modelos globais
- Figura 32 - Previsão modelos globais e observação
- Figura 33 - Divisão em clusters
- Figura 34 - Curva de potência da central e curva de potência WRF
- Figura 35 - Comparativo previsão L1, previsão WRF e Observação ( $k=1$ )
- Figura 36 - Comparativo previsão L2, previsão WRF e Observação ( $k=1$ )
- Figura 37 - Comparativo previsão L3, previsão WRF e Observação ( $k=1$ )
- Figura 38 - Comparativo previsão L4, previsão WRF e Observação ( $k=1$ )
- Figura 39 - Previsão de Potência Modelo L1  $K=1$  Cluster 1
- Figura 40 - Previsão de Potência Modelo L1  $K=1$  Cluster 2
- Figura 41 - Previsão de Potência Modelo L2  $K=1$  Cluster 1
- Figura 42 - Previsão de Potência Modelo L2  $K=1$  Cluster 2
- Figura 43 - Destaque de trecho previsão de L1 e L2

- Figura 44 - Destaque de trecho previsão de L3 e L4
- Figura 45 - Previsão do modelo L1 - WRF-C
- Figura 46 - Previsão do modelo L3 - WRF-C
- Figura 47 - Previsão Rampas de descida
- Figura 48 - Previsão rampas de subida
- Figura 49 - Correlação rampas de descida com modelo G4
- Figura 50 - Correlação rampas de subida com modelo G4
- Figura 51 - Correlação L1-WRF-C em comparativo com L1-WRF (rampa descida)
- Figura 52 - Correlação L4-WRF-C em comparativo com L4-WRF (rampa descida)
- Figura 53 - Eventos de rampa previstos e observados
- Figura 54 - Potência e velocidade local/WRF

## LISTA DE TABELAS

- Tabela 1 - Resumo revisão de literatura
- Tabela 2 - Configuração padrão do modelo WRF instalado no CER/UFPE
- Tabela 3- Modelo Persistência
- Tabela 4 - Correlação e NRMSE para os modelos globais
- Tabela 5 - Features comparativas - Modelos Globais
- Tabela 6 - Correlação para os modelos locais
- Tabela 7 - NRMSE para os modelos locais
- Tabela 8 - Correlação modelos locais por cluster (C1=Cluster 2, C2=Cluster 2)
- Tabela 9 - NRMSE modelos locais por cluster (C1=Cluster 2, C2=Cluster 2)
- Tabela 10 - Correlação modelos locais por cluster + WRF (C1=Cluster 2, C2=Cluster 2)
- Tabela 11 - NRMSE modelos locais por cluster + WRF (C1=Cluster 2, C2=Cluster 2)
- Tabela 12 - Correlação combinação modelos locais + WRF (L-WRF-C)
- Tabela 13 - NRMSE modelos locais-WRF-C
- Tabela 14 - Features comparativas Modelos Locais-WRF-C k=1
- Tabela 15 - Correlação e NRMSE L1-WRF-C
- Tabela 16 - Correlação e NRMSE L2-WRF-C
- Tabela 17 - Correlação e NRMSE L3-WRF-C
- Tabela 18 - Correlação e NRMSE L4-WRF-C
- Tabela 19 - Correlação e NRMSE G4
- Tabela 20 - Correlação e NRMSE para rampas de subida e descida para modelos locais
- Tabela 21 - Correlação e NRMSE para rampas de subida e descida para modelos locais com WRF (sem clusterização)
- Tabela 22 - Avaliação de resultados modelos L-WRF-C
- Tabela 23 - Índices de previsão
- Tabela 24 - Revisão de Literatura

# SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>9</b>
1.1 Objetivo Geral	10
1.2 Objetivos Específicos	10
<b>2 CONCEITOS PRELIMINARES</b>	<b>10</b>
2.1 <i>Clustering</i>	10
2.1.1 Features	11
2.2 MLP (Multilayer Perceptron)	12
2.3 WRF (Weather Research and Forecasting)	13
2.4 Ajuste Global e Ajuste Local	13
<b>3 REVISÃO DE LITERATURA</b>	<b>13</b>
3.1 Conceitos de rampa	14
3.2 Previsão de rampas em centrais eólicas	16
3.2.1 Modelos estatísticos	16
3.2.2 Modelos físicos	19
3.2.3 Síntese da revisão sobre previsão de rampas	22
<b>4 MATERIAIS E MÉTODOS</b>	<b>23</b>
4.1 Avaliação da qualidade dos dados observacionais	24
4.2 Modelagem mesoescalar com WRF	25
4.2.1 Modelagem da curva de potência	27
4.3 Modelo de referência	27
4.4 Modelos de previsão global	27
4.4.2 Modelo de previsão global com central à barlavento	28
4.5 <i>Clustering</i>	30
4.5.1 - K-Means	31
4.6 Modelos Locais	32
4.6.1 Mecanismo Identificador de Regime (IR)	33
4.6.2 Modelo Local I (Modelo L1)	33
4.6.3 Modelo Local utilizando central à barlavento (L2, L3 e L4)	34
4.7 Combinação de modelos	35
4.8 Avaliação de resultados	36
<b>5 ESTUDO DE CASO E DISCUSSÃO</b>	<b>37</b>
5.1 Desempenho do modelo de referência	38
<b>5.2 Modelos Globais</b>	<b>40</b>
5.3 Agrupamentos (clusters) formados	42
5.4 Modelos locais e WRF	43
5.4.1 Curva de potência e combinação de modelos	43
5.4.2 Previsão de rampas	54
5.4.3 Avaliação de resultados	60

5.5 Eventos de rampa e possíveis causas	62
5.6. Outras metodologias	63
<b>6 CONCLUSÕES</b>	<b>64</b>
<b>7 PERSPECTIVAS FUTURAS</b>	<b>65</b>
<b>8 REFERÊNCIAS</b>	<b>67</b>

## Resumo

Fontes de energia renovável como a eólica costumam ser um desafio para o operador do Sistema Interligado Nacional (SIN) devido à intermitência relativa à potência ativa de saída dos aerogeradores e, por consequência, das centrais eólicas. Para auxiliar na previsão da potência, buscando compreender padrões determinísticos que por vezes são ocultados em função da componente estocástica, diferentes ferramentas vêm sendo desenvolvidas considerando-se as particularidades da eólica, que tem tido uma influência substancial na matriz elétrica nacional nos últimos anos. Tais ferramentas têm feito uso de modelos físico-numéricos e/ou estatísticos. Particularmente, um dos fenômenos que mais dificulta a previsão de potência de uma central eólica são rampas (de subida ou de descida) da potência, tendo em vista que estas representam variações abruptas na potência da central. A previsão dessas rampas em eólica é uma questão desafiadora e vem recebendo grande atenção nos últimos anos. Nesse sentido, este trabalho busca contribuir ao estado da arte da previsão eólica propondo uma metodologia que visa auxiliar a previsão de rampas em centrais fazendo uso da combinação entre um modelo (físico-numérico) atmosférico mesoescalar e modelos (estatísticos) de séries temporais. Para os estudos de caso aqui apresentados, de forma geral, os modelos que fizeram uso do WRF (modelo físico-numérico) desempenharam melhor que os demais. Em tais estudos, a previsão de rampas em si foi realizada por meio de redes neurais do tipo multilayer perceptron auxiliadas por mecanismos identificadores de regime (modelo estatístico), que identificam as rampas nas séries temporais de potência. Quanto ao modelo físico-numérico, empregou-se o Weather Research and Forecasting Model para previsão de velocidade do vento. Tal previsão de velocidade foi convertida em previsão de potência por meio de uma modelagem de curva de potência implementada também com redes neurais do tipo multilayer perceptron. Com a obtenção de resultados para as duas classes de modelos, realizou-se a combinação entre estes fazendo-se uso do mesmo tipo de redes neurais. Para a clusterização dos aerogeradores, empregou-se o método K-Means. Foi possível verificar que com os dados de mesoescala houve uma melhora significativa na previsão de rampas de subida e descida, com destaque para horizontes de previsão mais distantes, superiores a  $k=3$  (90 minutos à frente).

Palavras chave: Energia Eólica; Previsão de Rampas; Combinação de Previsões; Modelos de Séries Temporais; WRF; *Clustering*.

## Abstract

Energy sources such as wind power are often a challenge for the operator of the National Interconnected System (SIN) due to the intermittency of the active output power of wind turbines and, consequently, of wind farms. To assist in power forecasting, seeking to understand deterministic patterns that are sometimes hidden due to the stochastic component, different tools have been developed considering the particularities of wind power, which has had a substantial influence on the national electricity grid in recent years. Such tools have made use of physical-numerical and/or statistical models. In particular, one of the phenomena that most hinders the forecasting of the power of a wind farm is ramps (up or down) in power, given that these represent abrupt variations in the power of the plant. Forecasting wind turbine ramps is a challenging issue that has received considerable attention in recent years. In this sense, this work aims to contribute to the state of the art of wind turbine forecasting by proposing a methodology that aims to assist in forecasting wind turbine ramps in power plants by combining a mesoscale atmospheric (physical-numerical) model and time series (statistical) models, evaluating the hypothesis that the combination of forecasts of wind turbine clusters in large wind power plants can lead to greater accuracy when compared to the forecast made for the plant as a whole, which is motivated by the characteristics of the geographic dispersion of wind turbines in large power plants. For the case studies presented here, in general, the models that used the WRF (physical-numerical model) performed better than the others. In such studies, the ramp forecast itself was performed using multilayer perceptron neural networks aided by regime identification mechanisms (statistical model), which identify the ramps in the power time series. As for the physical-numerical model, the Weather Research and Forecasting model was used to forecast wind speed. This speed forecast was converted into a power forecast using a power curve modeling also implemented with multilayer perceptron neural networks. After obtaining results for both classes of models, they were combined using the same type of neural networks. The K-Means method was used to cluster the wind turbines. It was possible to verify that with the mesoscale data there was a significant improvement in the prediction of up and down ramps, with emphasis on more distant prediction horizons, greater than  $k=3$  (90 minutes ahead).

Keywords: Wind Energy; Ramp Forecasting; Forecasts Combination; Time Series Modelling; WRF; *Clustering*.

# 1 INTRODUÇÃO

De acordo com a EPE (2024) (Empresa de Pesquisa Energética) através do Balanço Energético Nacional, a fonte hidráulica representou 58,9% da matriz elétrica brasileira em 2023. Esse cenário de predominância se repete ao longo dos anos, devido ao grande aproveitamento do potencial hídrico brasileiro. No entanto, de 2022 para 2023 houve uma redução quanto à representatividade das hidrelétricas na matriz. De acordo com a EPE, isso ocorreu devido ao aumento da representatividade de usinas eólicas e solares.

Segundo dados da ABEEólica (2024), em outubro de 2024 a fonte eólica já representava 16% da matriz elétrica brasileira, ficando atrás apenas da hidráulica. Esse percentual equivale à capacidade instalada de 32,9 GW, em comparativo, em 2010, a capacidade instalada da eólica não ultrapassava 1 GW.

Apesar dos vários benefícios associados à fonte eólica, o seu crescimento torna a operação do sistema elétrico ainda mais complexa, pois a potência ativa de saída das centrais eólicas apresenta um comportamento intermitente, não regulável e profundamente dependente das condições ambientais (Clemente, 2018). Devido a essa intermitência, é essencial o emprego de mecanismos de previsão de geração para esse tipo de fonte. A previsão de potência para fontes não reguláveis como a eólica auxilia o operador do Sistema Interligado Nacional (SIN) no despacho dos geradores reguláveis e é importante para o balanço de energia de todo o sistema.

As rampas são um dos fenômenos que mais preocupa o operador do sistema elétrico no que diz respeito às fontes intermitentes. Um evento de rampa pode ser descrito como uma mudança significativa e repentina (em um curto intervalo de tempo) na potência de saída de um sistema (Clemente, 2018; Ouyang et al., 2019; Eltohamy et al., 2020). Um regime de rampas pode ocasionar uma elevação na potência elétrica (rampas de subida) ou uma diminuição na potência (rampas de descida). Castillo (2013) apresenta algumas possíveis causas para esse evento, como fenômenos meteorológicos (e.g., tempestades, frentes) e causas operacionais (e.g., a reorientação dos aerogeradores por *yaw* e a perturbação induzida pelas esteiras dos aerogeradores).

Com o aumento da participação da energia eólica na matriz elétrica brasileira, as rampas se tornam um desafio para o Operador do Sistema Elétrico, despertando a necessidade da criação de modelos de previsão mais acurados, capazes de prever possíveis eventos de rampa, permitindo a necessária antecipação quanto à tomada de decisão por parte do operador.

A previsão de potência (e, conseqüentemente, a previsão de rampas de potência) pode ser feita por meio de modelos físico-numéricos baseados na modelagem da circulação atmosférica e de modelos estatísticos baseados em séries temporais (Castillo, 2013; Clemente, 2018; Ouyang et al., 2019; Dhiman et al., 2020; Zhou et al. 2021; Diallo et al. 2024). Conforme será visto nos tópicos seguintes, ambos tipos de modelo são amplamente utilizados, combinados de diferentes formas entre si, buscando a melhora da acurácia das previsões.

A escolha da metodologia de previsão dependerá dos dados disponíveis, do horizonte de previsão necessário e do background da equipe de desenvolvimento da ferramenta de

previsão. Nos trabalhos sobre o tema, alguns autores optam por prever a velocidade do vento e outros preveem diretamente a potência, o que dependerá da abordagem escolhida (Doan et al., 2018; Groch et al., 2021; Diallo et al. 2024). O trabalho atual aborda a previsão da potência (P), dado que é o produto final da central eólica. As variáveis de entrada aos modelos podem ser variáveis endógenas (e.g., podem-se utilizar  $P(t-1)$  e  $P(t)$  como variáveis regressoras, de entrada aos modelos, na previsão de  $P(t+1)$ ) e/ou variáveis exógenas que ajudem a explicar a variável de saída dos modelos (e.g., podem-se utilizar  $V(t-1)$  e  $V(t)$  como variáveis regressoras, de entrada aos modelos, na previsão de  $P(t+1)$ ). Neste trabalho, são utilizadas, como variáveis regressoras, a potência ativa de saída da central eólica de interesse, a velocidade do vento e a potência ativa de saída da central eólica à barlavento da central eólica de interesse.

## 1.1 Objetivo Geral

O trabalho busca aprimorar modelos de previsão de rampas de potência em centrais eólicas utilizando da combinação de um modelo físico-numérico com modelos estatísticos baseados em séries temporais clusterizadas espacialmente.

## 1.2 Objetivos Específicos

1. Realizar a previsão de potência e de rampas utilizando modelos (estatísticos) de séries temporais com ajuste global e com ajuste local respectivamente;
2. Realizar a previsão de rampas utilizando o modelo atmosférico regional (modelo físico-numérico) WRF combinado com os modelos (estatísticos) de séries temporais com ajuste local clusterizados;
3. Comparar as previsões de rampa dos diferentes modelos.

## 2 CONCEITOS PRELIMINARES

### 2.1 *Clustering*

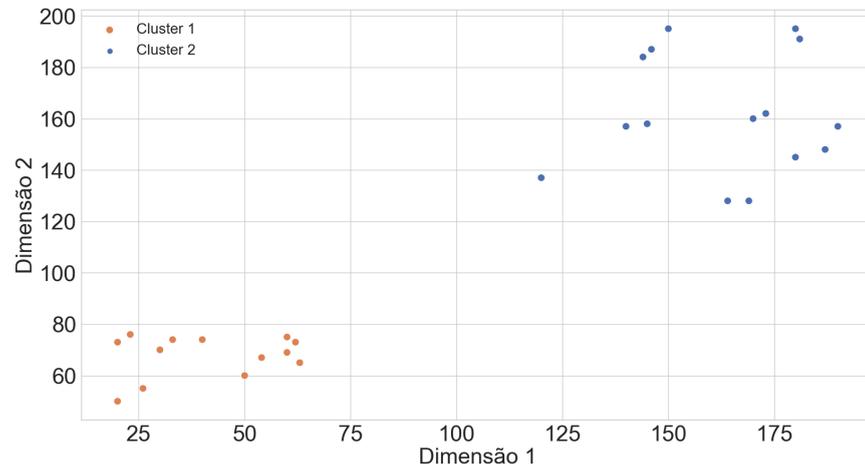
*Clustering* (ou agrupamento) é um método de aprendizagem não supervisionada que busca alocar dados em diferentes grupos de acordo com as similaridades entre as características desses dados (Lachi e Rocha, 2005; Irani et al., 2016; Ezugwu et al., 2022; Ünsalan et al., 2024). Os métodos de agrupamento podem ser divididos em duas classes principais, os métodos particionais e os métodos hierárquicos.

Métodos particionais dividem a série de dados em “k” partes, onde cada parte representa um cluster. A divisão é feita baseando-se em uma determinada função objetiva. Os clusters são povoados de forma que os dados dentro de um mesmo cluster sejam “similares” e os dados em diferentes clusters sejam “dissimilares” (Irani, 2016).

Dentre os métodos particionais, o K-Means é um dos métodos de agrupamento mais populares, dada a sua simplicidade e facilidade na implementação (Mendes, 2017).

Na Figura 1, é ilustrado um exemplo de um agrupamento por meio do K-Means. Esse método se baseia no cálculo, por exemplo, da distância euclidiana entre os dados e a média dos grupos formados, buscando distribuir todos os dados em “k” clusters. Para a série de dados bidimensional utilizada no exemplo, são formados 2 clusters, conforme pode ser observado na Figura 1.

**Figura 1 - Exemplo de método K-Means**

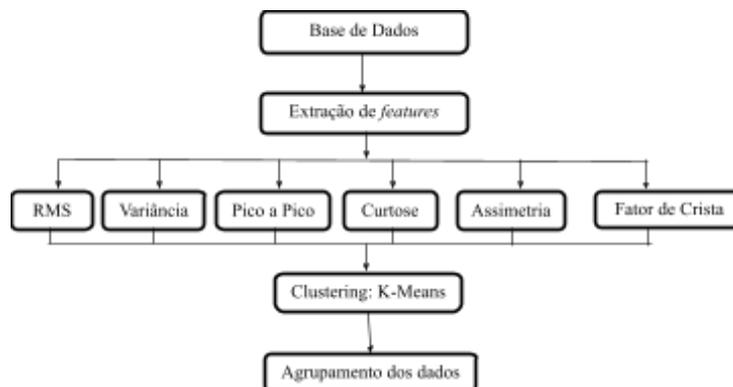


Fonte: Própria autora

### 2.1.1 Features

Uma feature é uma propriedade individual mensurável ou característica de um fenômeno observado (Anderson, 2019). A otimização da análise baseada em *clustering* pode ser realizada fazendo-se uso de features dos dados de interesse. Dentre as features mais utilizadas na literatura, podem-se citar: média, máximo, mínimo, pico a pico, fator de crista, RMS (Yaguo, 2017; Xu, Lei e Li, 2020). Na Figura 2, está disposto um exemplo do uso das features.

Figura 2- Extração de features



Fonte: Própria autora

## 2.2 MLP (Multilayer Perceptron)

De acordo com Graupe (2007), o perceptron (Rosenblatt, 1958) serve como um bloco de construção para a maioria dos modelos de redes neurais. Dentre estas, um dos modelos mais amplamente utilizado atualmente diz respeito à rede neural do tipo perceptron multicamadas (MLP, Multilayer Perceptron). A MLP é o exemplo fundamental de uma rede neural profunda. Sua arquitetura consiste em múltiplas camadas ocultas para capturar as relações mais complexas que existem em um conjunto de dados de treinamento (Taud et al., 2018). De acordo com Haykin (2001), esse tipo de rede é capaz de resolver diversos tipos de problemas, através do seu treinamento de forma supervisionada com um algoritmo de retropropagação de erro. Ainda de acordo com o autor, a MLP tem três características distintas:

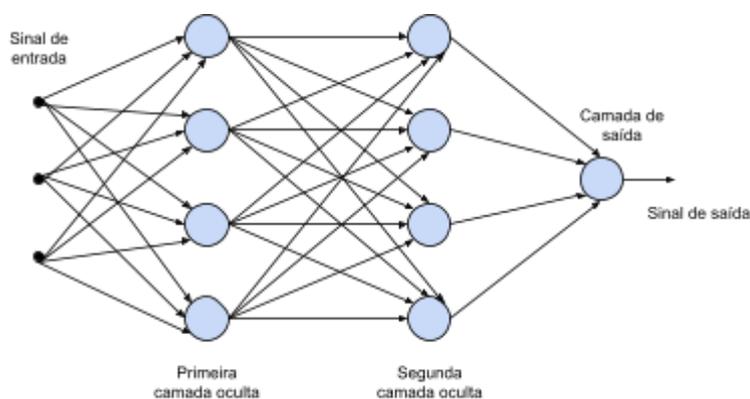
1. O modelo de cada neurônio inclui uma função de ativação não linear do tipo sigmoide (S-shaped function) como, por exemplo, a função logística (Equação 1):

$$y_j = \frac{1}{1 + \exp(-v_j)} \quad (1)$$

2. A rede contém uma ou mais camadas de neurônios ocultos, que não são parte da entrada ou da saída da rede. Esses neurônios ocultos capacitam a rede a aprender tarefas complexas, extraindo progressivamente as características mais significativas dos padrões de entrada.
3. A rede exibe um alto grau de conectividade, determinado por suas sinapses.

Uma rede neural do tipo MLP pode ser representada conforme a Figura 3. No exemplo, a rede tem duas camadas ocultas e uma camada de saída. O fluxo de sinal na rede é da esquerda para direita e de camada em camada e, conforme observado, a rede é inteiramente conectada.

**Figura 3 - Rede Neural MLP**



Fonte: Própria autora

## **2.3 WRF (Weather Research and Forecasting)**

O WRF (Weather Research and Forecasting) é um modelo atmosférico regional (i.e., mesoescalar) desenvolvido pelo National Center for Atmospheric Research (NCAR). De acordo com o NCAR (Skamarock et al. 2021), o WRF é um sistema de previsão numérica do tempo em mesoescala projetado tanto para pesquisa atmosférica quanto para aplicações de previsão operacional. Sendo um modelo físico-numérico ele realiza a previsão numérica do tempo (NWP, Numerical Weather Prediction) resolvendo equações baseadas em leis físicas de conservação. Este pode produzir simulações baseadas em condições atmosféricas reais ou condições idealizadas (Powers et al., 2017). O WRF contém dois núcleos dinâmicos: o ARW (Advanced Research WRF), desenvolvido pelo NCAR, e o NMM (Non-hydrostatic Mesoscale Model), desenvolvido por National Centers for Environmental Prediction (NCEP). Cada núcleo corresponde a um conjunto de solucionadores que operam em uma projeção de malha específica, escalonamento de malha e sistema de coordenadas verticais (Bernardet et al., 2009; Dodla et al., 2011).

## **2.4 Ajuste Global e Ajuste Local**

Este trabalho adota duas definições para categorizar as previsões realizadas: 1. previsões realizadas por modelos globais; 2. previsões realizadas por modelos locais. Considerando-se que uma previsão é realizada buscando minimizar seu erro com respeito ao que se toma como alvo e sendo o alvo (neste trabalho) o dado observacional (i.e., o dado medido), o que diferencia os tipos de previsão aqui apresentados é o conjunto de dados utilizado para o treinamento dos modelos. Para as previsões de ajuste global, os modelos são treinados visando minimizar o erro sobre toda a série histórica de dados. Por sua vez, nas previsões de ajuste local, os modelos são treinados visando minimizar o erro sobre trechos da série histórica que apresentam comportamentos particulares. Neste trabalho, os comportamentos locais de interesse são as rampas, de subida e descida. Portanto, os modelos locais são aqui treinados para a previsão destes comportamentos.

# **3 REVISÃO DE LITERATURA**

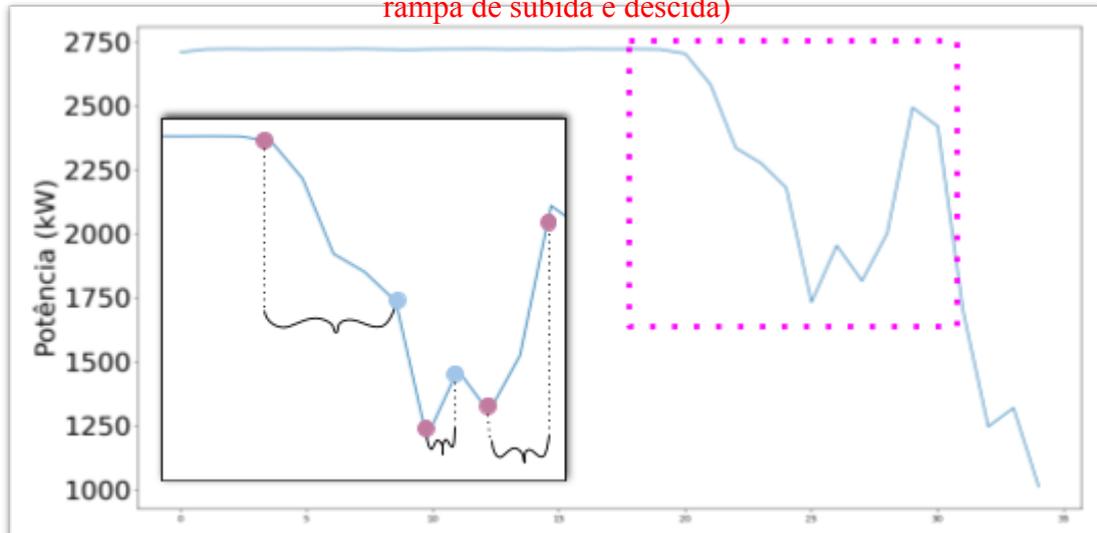
## **3.1 Conceitos de rampa**

A literatura aborda diferentes definições de rampa de potência. Os autores comumente caracterizam as rampas baseando-se em três propriedades principais (Castillo, 2013; Zhang, 2017; Ouyang et al., 2019; Diallo et al., 2024; He et al., 2024):

- Direção: Essa propriedade indica se está havendo um aumento na potência (rampa de subida) ou uma diminuição (rampa de descida);
- Duração ( $\Delta t$ ): Indica quanto tempo durou o evento de rampa;
- Magnitude: Caracteriza a mudança do gradiente local na série temporal de potência nos trechos da série em que se identificam um evento de rampa.

Na Figura 4, é possível observar o período destacado com ocorrência de eventos de rampa que exemplifica as propriedades principais citadas.

Figura 4 - Destaque de evento de rampa (sem unidade no eixo X - indicar o que é rampa de subida e descida)



Fonte: Própria autora

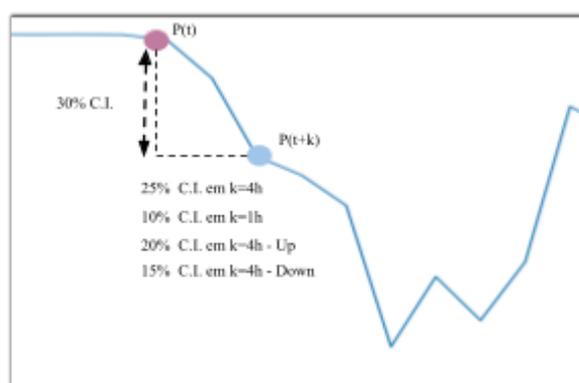
Baseando-se nessas características, alguns autores (Liu et al., 2019; Ouyang et al., 2019; Li et al., 2020; Couto et al., 2021, Zhou et al., 2021) utilizam diferentes definições de rampa:

1. Definição 1: Uma rampa ocorre quando a magnitude do gradiente do sinal da potência em um determinado intervalo de tempo  $\Delta t$  é maior que um limite predefinido;
2. Definição 2: Uma rampa ocorre quando a diferença entre o máximo e o mínimo de uma saída de potência em um determinado intervalo de tempo  $\Delta t$ , é maior que um limite predefinido;
3. Definição 3: Uma rampa ocorre quando o valor absoluto do sinal filtrado da potência em um determinado intervalo de tempo  $\Delta t$  excede um limite predefinido;
4. Definição 4: Uma rampa ocorre quando a razão entre a diferença absoluta da potência em um determinado intervalo de tempo  $\Delta t$  é maior que um valor de referência predefinido.

No trabalho desenvolvido por Zhang et al., (2017), também são aplicadas quatro definições de rampa, no entanto, os autores estabeleceram limiares para estas definições, conforme descrito a seguir (Figura 5):

1. Definição 1: Pode ser considerado um evento de rampa quando o gradiente da potência de saída é superior a 30% da capacidade instalada, não levando em consideração a duração da rampa;
2. Definição 2: Pode ser considerado um evento de rampa quando o gradiente da potência de saída é superior a 25% da capacidade instalada no intervalo de tempo de 4 horas ou menos;
3. Definição 3: Pode ser considerado um evento de rampa quando o gradiente da potência de saída é superior a 10% da capacidade instalada no intervalo de uma hora;
4. Definição 4: Um evento de rampa de subida pode ser definido quando o gradiente da potência de saída é superior a 20% da potência instalada no intervalo de 4 horas ou menos; E um evento de rampa de descida pode ser definido quando o gradiente da potência de saída é maior que 15% da potência instalada no intervalo de 4 horas ou menos.

Figura 5 - Definição de rampa conforme Zhang, 2017



Fonte: Própria autora

Há um consenso entre os autores quanto às propriedades principais que devem ser levadas em consideração quando se trata de rampa (direção, duração e magnitude), no entanto, os limites considerados para cada uma dessas variará com o tipo de dado utilizado e a aplicação do trabalho. Pois, a caracterização como rampa precisa de uma especificidade quanto ao conjunto de dados analisados. Por exemplo, quando se trata de potência ativa, a rampa se caracteriza pela magnitude e pela duração do evento. A direção apenas indicará qual tipo de rampa observada (se de subida ou descida). Quanto aos limiares, devem ser estabelecidos especificamente para cada conjunto de dados.

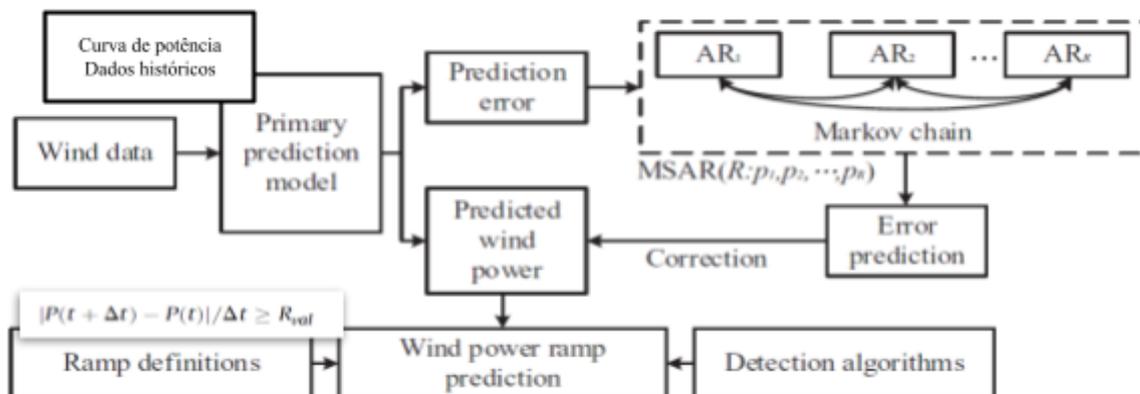
Os eventos de rampa podem ocorrer devido a fenômenos meteorológicos e/ou causas operacionais. Mas, independentemente da causa, resultam em uma variação abrupta da potência de saída da máquina, podendo perturbar a operação do sistema interligado nacional. Diversos trabalhos focam na previsão de rampas de potência para fontes intermitentes devido à importância da previsibilidade destas para o balanceamento do sistema (Clemente, 2018; Okada et al., 2018; Lima, 2019; Ouyang et al., 2019; Cheneka et al., 2020; Li et al., 2020; Zhou et al., 2021; Diallo et al, 2024; He et al., 2024). (separar as referencias pra cada tema)

## 3.2 Previsão de rampas em centrais eólicas

### 3.2.1 Modelos estatísticos

No trabalho desenvolvido por Ouyang et al. (2019), a previsão de rampas segue a metodologia destacada na Figura 6, e esta divide a previsão de rampas em previsão de potência e posterior detecção da rampa, desta forma, os autores realizam a previsão em duas etapas, inicialmente é feita a previsão de potência eólica, fazendo uso da série histórica de velocidade do vento, baseando-se na curva de potência da máquina. No trabalho são destacadas as diferentes formas de modelagem de curva de potência e os autores optam por realizar a modelagem baseando-se nos dados históricos. Após a previsão da potência, é extraído o erro da previsão, o qual passa por modelos de correção, para tornar a previsão mais acurada. Após esse processo, a previsão de eventos de rampas é realizada usando algoritmos de detecção e a seguinte definição de rampa: uma rampa ocorre quando a razão entre a diferença absoluta da potência em um determinado intervalo de tempo  $\Delta t$  é maior que um valor de referência predefinido.

Figura 6 - Metodologia Ouyang et al., 2019



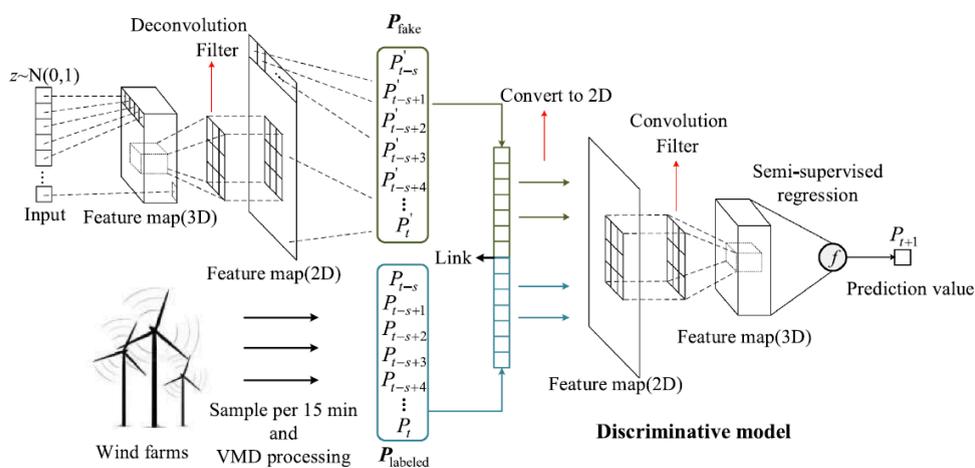
Fonte: Ouyang et al., 2019

Zhou et al. (2021), desenvolveram um trabalho baseando-se no uso de redes adversárias generativas (do inglês, Generative Adversarial Network - GAN) e no método de regressão semi-supervisionada, realizando previsão a curto prazo de potência eólica e de eventos de rampa. A estrutura de previsão proposta pelos autores, exemplificada na Figura 7, combina diferentes técnicas de decomposição do sinal. Inicialmente, é utilizada a decomposição do modo variacional (VMD - variational mode decomposition) para decompor a série temporal de potência eólica bruta em várias funções de modo intrínsecas. Em seguida, o modelo generativo GAN é utilizado com camadas lineares, camadas de pooling e camadas de deconvolução para gerar séries temporais virtuais de potência eólica para captar as características de distribuição dos dados. Além disso, o modelo discriminativo GAN utiliza operações de convolução e agrupamento para extrair características não lineares ocultas nas séries temporais, e a regressão semi-supervisionada é utilizada para prever a potência eólica

nos horizontes seguintes. Por fim, é realizada a atualização dos parâmetros da rede buscando minimizar os erros de previsão.

Para identificar os eventos de rampa, os autores se utilizaram da seguinte definição de rampa, “Uma rampa ocorre quando a razão entre a diferença absoluta da potência em um determinado intervalo de tempo  $t$  é maior que um valor de referência predefinido”. Baseando-se em dois limiares, os autores descrevem 5 tipos de evento que podem ocorrer: Grandes eventos de rampa de subida, pequenos eventos de rampa de subida, sem eventos de rampa, pequenos eventos de rampa de descida e grandes eventos de rampas de descida. Os limiares estabelecidos correspondem a 5% e 10% da potência instalada.

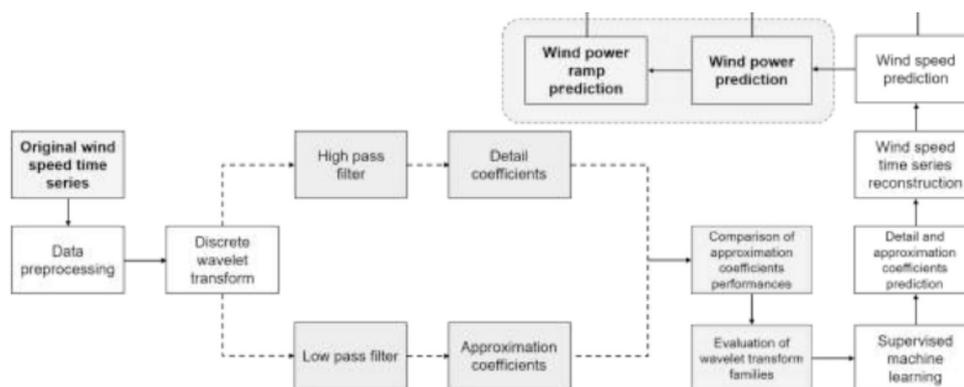
Figura 7 - Metodologia de Zhou et al., 2021



Fonte: Zhou et al. (2021)

Dentre os trabalhos que têm por objetivo a previsão de rampas, Zucatelli et al. (2021) desenvolveram uma metodologia para prever potência eólica e rampas de potência nas regiões tropicais e subtropicais da América do Sul (Figura 8). A base de dados utilizada no estudo é proveniente de torres anemométricas instaladas em Soriano - Uruguai e na Bahia - Brasil. O trabalho aborda uma combinação de modelos de RNN (Rede Neural Recorrente, do inglês *Recurrent Neural Network*) e transformadas de envelope, a partir dos quais, a Rede Neural formada da combinação foi treinada para realizar a previsão de velocidade do vento 1h à frente e, utilizando a rede treinada, inferir recursivamente a previsão para as próximas horas. O trabalho realiza a previsão de velocidade do vento e, a partir desta, calcula a potência de saída através das equações de conservação de energia. A previsão de rampas é feita utilizando as definições estabelecidas por Zhang et al. (2017), posterior ao cálculo da potência.

Figura 8 - Metodologia de Zucatelli et al. (2021)

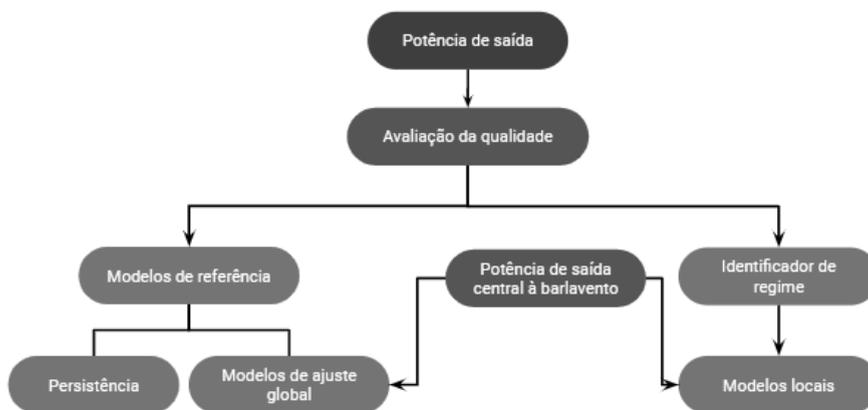


Fonte: Zucatelli et al., 2021

No trabalho desenvolvido por Cheneka et al. (2020), foi utilizada uma base de dados de 2 anos de uma central offshore da Bélgica. Neste, é descrita uma metodologia utilizando-se da transformada de envelope para detectar e classificar eventos de rampa. O método baseado na transformada de ondaleta (*wavelet-surrogate*) considera 4 níveis de discriminação em diferentes intervalos de tempo. Os autores compararam os resultados obtidos através da transformada de envelope com o método de mínimos e máximos desenvolvido por Bianco et al (2016). Nesse método é estabelecida uma janela móvel e é feita a diferença entre a potência máxima e mínima dentro da janela, se a mesma é superior a um determinado limiar, é considerado um evento de rampa. Para a maior parte dos cenários observados, o método de envelope detectou mais eventos de rampa quando comparado ao método de mínimos quadrados. No trabalho também foi observado que para a base de dados utilizada, a maioria das rampas duravam menos que 15 horas, com média de duração de 8 horas e que rampas com duração maior que 24 horas eram raras.

No trabalho desenvolvido por Clemente (2018), foi desenvolvido um modelo de previsão da potência de saída de centrais eólicas a curtíssimo prazo (Figura 9). Uma ferramenta identificadora de regime foi desenvolvida e utilizada para definir onde existem rampas de subida e rampas de descida. Para auxiliar o mecanismo de previsão de rampas, também foram utilizados dados de centrais eólicas à barlavento da central de interesse. A autora fez o uso de redes neurais artificiais do tipo MLP, com as quais criou diferentes modelos de previsão, considerando o comportamento local da potência de saída, onde é utilizado o identificador de regime, e o comportamento global. Como modelo de referência foi utilizada a persistência e modelos de minimização de erro global.

Figura 9 - Metodologia de Clemente, 2018



Fonte: Própria autora

O trabalho desenvolvido por Li et al. (2020) foca na previsão de rampas de velocidade do vento, mostrando a relação entre a velocidade do vento e a potência de saída da central. Os autores definem que o limiar para classificar um evento como rampa será de aumentos acima de 30% da capacidade nominal num intervalo de 15 minutos. No artigo é proposto o algoritmo TECI (*Typical Event Clustering Identification*, Identificação típica de agrupamento de eventos), que se utiliza do EB-K *clustering*, o qual faz o agrupamento de eventos de rampa em diferentes categorias a depender da amplitude, intervalo de tempo e taxa de ocorrência. A partir desse agrupamento, o algoritmo procura por eventos semelhantes fazendo uso de uma janela móvel na base histórica de dados, extraindo a probabilidade máxima de ocorrência daquele evento de rampa, considerando um indicador de similaridade.

### 3.2.2 Modelos físicos

Em 2018, o ONS (referência) divulgou uma nota técnica com o desenvolvimento metodológico para previsão de geração eólica. Na nota, o Operador descreve a metodologia utilizada para previsão de geração eólica no Nordeste e Sul do país. No documento, é detalhado o tratamento dos dados históricos que serão utilizados como dados de entrada para os modelos de previsão. São eles: dados de geração verificada, dado de vento verificado e dados de vento previsto. Cada um destes possui diferentes características e, portanto, tratamentos diferentes. Após o tratamento dos dados, é realizado o ajuste da previsão do vento, pois a mesma possui um desvio em relação ao vento verificado. Para previsão da geração eólica, o ONS aborda duas metodologias: a primeira é baseada em séries temporais, onde um modelo autorregressivo de média móvel integrada com variável exógena (ARIMAX) (CAMELO, 2018) fornece o valor esperado da geração em função do vento previsto e da geração verificada; a segunda metodologia baseia-se na estimação da curva de potência, fornecendo o valor esperado da geração em função do vento previsto. Em ambas metodologias é necessária a previsão de vento. Na nota técnica, o ONS destaca que foram utilizados diferentes modelos para previsão de vento (ETA, GFS, ECMWF e BAM) e esses modelos foram combinados por meio de combinação linear com pesos distintos para obtenção de melhores resultados.

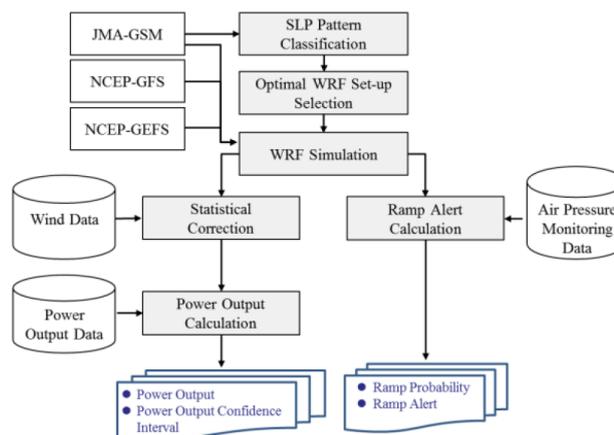
No trabalho desenvolvido por Li et al. (2016), o foco está na previsão de potência e rampas de potência para um dia à frente. Na metodologia desenvolvida pelos autores, as variáveis meteorológicas (velocidade do vento, pressão, direção do vento, direção do gradiente de pressão) obtidas através do WRF, são agrupadas em clusters a depender de suas características, por exemplo, os dados de velocidade do vento são divididos em 3 clusters: Velocidades de 0 a 7 m/s no primeiro, de 7 m/s a 12 m/s no segundo, e acima de 12 m/s no terceiro. A partir dos clusters formados, é realizada a previsão da potência utilizando uma MLP-NN (Multilayer Perceptron Neural Network) para cada cluster individual, e é feita a comparação com a previsão realizada utilizando toda a série de dados. Para o comparativo

entre as previsões, o artigo utiliza-se do RMSE (Root Mean Square Error) variando-o no horizonte de previsão. Para a previsão e identificação de eventos de rampa, os autores utilizam a definição de que um evento de rampa ocorre quando a potência varia em pelo menos 35% da potência nominal no intervalo de 4 horas.

Okada, et al. (2018), desenvolveram um trabalho voltado para previsão de rampas com abordagem numérica (Figura 10). Os autores utilizaram o WRF para a previsão de velocidade do vento, com dados de entrada disponibilizados pelo JMA-GSM, NCEP-GFS, NCEP-GEFS, e dados coletados do Projeto NEDO (*New Energy and Industrial Technology Development Organization*). Após a previsão pelo modelo mesoescalar, foi realizada a correção estatística dos dados considerando o local de interesse, e posteriormente a previsão de potência. A conversão foi realizada fazendo uso de uma curva de potência empírica, gerada a partir de dados históricos.

A identificação de rampa foi baseada na previsão do WRF e pressão do ar no local de interesse. No estudo, foram definidas como rampas flutuações acima de 30% da capacidade instalada e flutuações médias de 5% por hora, ou mais, durante o mesmo período de tempo.

Figura 10 - Metodologia de Okada, et al. (2018)



No trabalho produzido por Diallo et al. (2024), os autores elaboraram um modelo de previsão buscando melhorar a acurácia de previsão de rampas, com horizonte de 6 horas à frente. Os autores fizeram uso de dados de medição do SCADA (*Supervisory Control and Data Acquisition System*) com as previsões do WRF. A metodologia desenvolvida aplica uma técnica de assimilação de dados, chamada de “*nudging*”, fazendo uso de informações das estações para que o WRF corrija erros futuros baseando-se em informações passadas, o que demonstrou reduzir o erro absoluto nos dados previstos e aumentou a probabilidade de detecção de rampa de acordo com os autores. Para essa detecção, foi utilizado um algoritmo de janela móvel que aplica um método linear por parte com um limiar de parâmetro, para identificação das rampas.

Semelhante à metodologia proposta neste trabalho, Groch et al. (2021), propuseram um modelo de previsão híbrido unindo o WRF à Redes neurais para previsão de velocidade do vento na altura da turbina. O trabalho busca prever e alertar a respeito de eventos extremos, utilizando o termo *High Wind Speed Shutdown* para tratar de altas velocidades de

vento que podem representar algum risco. Diferentemente deste trabalho, o modelo híbrido desenvolvido usa como dados de entrada diferentes modelos do WRF como amostra de previsão mesoescalar, a partir disso a rede neural desenvolvida é utilizada para realizar a redução de escala da previsão do WRF, individualizando-a por aerogerador.

O trabalho produzido por Doan et al. (2018) também utiliza o WRF para previsão de velocidade do vento, mais especificamente de rampas dessa variável. Os autores detalham que no estudo realizado foi escolhida a velocidade como variável, pois a potência sofre interferências devido a fatores humanos e rampas de potência não necessariamente são resultados de rampas de velocidade. Foram classificadas como rampas de velocidade alterações de até 5 m/s em intervalo de 6 horas e foi utilizado das mesmas premissas apresentadas por Okada et al. (2018), dado que ambos autores fizeram uso do projeto NEDO.

Conforme observado na literatura, as rampas de potência ou de velocidade do vento têm sido um tema comum e recorrente nos últimos anos, e a previsão destas se torna cada vez mais necessária com o aumento da representatividade da energia eólica na matriz elétrica nacional e mundial. A revisão de literatura focou nos dois tipos de abordagem de previsão que podem ser utilizadas e que serão aplicadas na metodologia deste trabalho. Na abordagem levando em consideração os modelos estatísticos, é possível observar a utilização de diferentes tipos de redes neurais (GAN, MLP, RNN), além de técnicas de *clustering* e de envelope para previsão de rampas. Na abordagem numérica, os autores fazem uso de dados do GFS, ECMWF, WRF, SCADA, dentre outras bases de dados, e também utilizando esses dados combinados com o uso de redes neurais. Tendo em vista as diferentes aplicações na literatura, este trabalho busca unir a abordagem numérica e a abordagem estatística, realizando os dois tipos de previsão para agrupamentos de aerogeradores, realizando uma combinação do resultado final de ambas, buscando maior acurácia.

### 3.2.3 Síntese da revisão sobre previsão de rampas

A Tabela 1 traz um resumo do atual estado da arte no que se refere a previsão de rampas, explicitando algumas características importantes deste trabalho e verificando se e como os demais trabalhos empregam estas. A primeira característica trata do tipo de previsão empregada no trabalho, se é voltado para rampas, ou se prevê a variável como um todo. Em seguida foi verificado se os trabalhos diferenciam rampas de subida e de descida, ou seja, se a previsão é realizada/avaliada separadamente, dado que há diferenciação no comportamento da série nos diferentes regimes. As características seguintes tratam dos modelos utilizados (modelos numéricos, estatísticos e clusterização). E por fim, as variáveis de entrada utilizadas para a previsão. Na última linha, encontram-se as características dos modelos desenvolvidos durante este trabalho de mestrado.

Tabela 1 - Resumo da revisão de literatura

Autores	Rampas	Descida/ Subida	Modelos Numéricos	Modelos Estatísticos	<i>Clustering</i>	Variáveis de entrada		
						V	P(t)	Pb

Li et al., 2016*	x	x	x	x	x	x		
Clemente, 2018	x	x		x			x	x
Doan et al., 2018	x			x		x		
Okada et al., 2018	x		x			x	x	
ONS, 2018			x	x		x	x	
Ouyang et al., 2019	x	x		x		x		
Li et al., 2020	x	x		x	x	x		
Groch et al., 2021**	x	x	x	x		x		
Zhou et al., 2021	x	x		x			x	
Zucatelli et al., 2021	x	x		x		x		
Diallo et al., 2024	x	x	x			x		
Souza, 2025***	x	x	x	x	x	x	x	x

V: Velocidade do vento

P: Potência da central de interesse

Pb: Potência da central à barlavento

\*No trabalho desenvolvido por Li (2016), há uma aplicação diferenciada dos modelos numéricos, estatísticos e clustering. No trabalho, os autores agrupam as variáveis meteorológicas obtidas através do WRF em clusters, baseando-se em suas magnitudes e uma MLP é utilizada para realizar a previsão por cluster;

\*\*Groch (2021) também faz uso de uma hibridização do WRF com redes neurais, no entanto as redes são utilizadas para realizar uma redução de escala e individualizar a previsão por aerogerador;

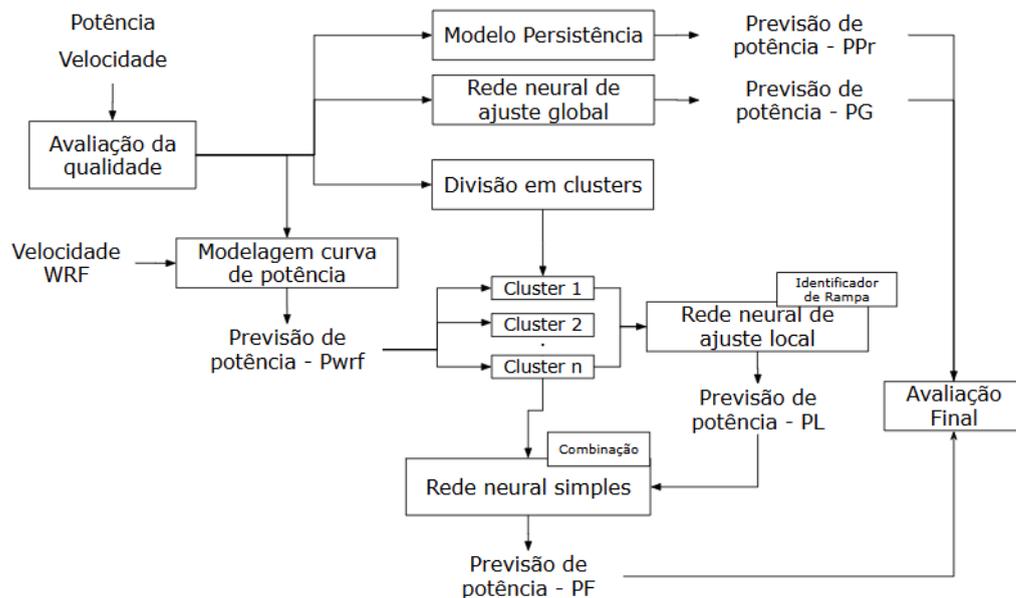
\*\*\*Trata-se desta monografia.

## 4 MATERIAIS E MÉTODOS

A metodologia desenvolvida neste trabalho está representada na Figura 11. Tal metodologia pode ser dividida em duas etapas, tendo em vista as duas abordagens consideradas. Sendo assim, a primeira etapa (abordagem numérica) consiste em utilizar dados de previsão de velocidade do vento obtidos através do WRF, para obtenção de dados de potência ativa, a conversão será realizada considerando a relação entre velocidade e potência dos dados observacionais da central de interesse. A etapa seguinte consiste na previsão fazendo uso de modelos estatísticos, para tal, foram utilizados modelos baseados em redes neurais que têm como saída as previsões globais da série, e modelos que tem como objetivo a previsão de rampas, este último é combinado com o agrupamento espacial da central. Para utilização dos modelos, os dados observacionais do local de interesse precisam passar por

uma avaliação da qualidade com vistas a excluir outliers das séries de treinamento, validação e teste para os modelos preditivos. Nesse procedimento, são observados os comportamentos de rampas de maneira a evitar a identificação das rampas como outliers. Em seguida, são extraídas features (para cada aerogerador) dos dados observacionais já tratados pelos testes de qualidade. A partir dessas features, são utilizadas as técnicas de agrupamento para reunir os aerogeradores em clusters, esperando-se que os aerogeradores espacialmente mais próximos venham a ser classificados em um mesmo cluster. Após esse agrupamento, são aplicados os modelos de previsão local (PL) em cada um dos clusters, a previsão por cluster é combinada, obtendo a previsão para a central. Este resultado é combinado com a previsão de potência clusterizada obtida através dos dados de previsão de velocidade mesoescalar (WRF). Paralelamente a esse processo, os modelos globais (PG), e o modelo de referência (PPr) também são aplicados aos dados da central como um todo. Por fim, é feita a comparação entre os resultados dos modelos propostos e o modelo de referência.

**Figura 11 - Fluxograma da metodologia**

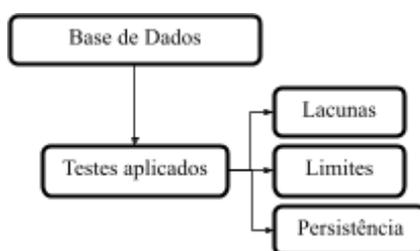


Fonte: Própria autora

#### 4.1 Avaliação da qualidade dos dados observacionais

Os testes de qualidade são um pré-requisito para a utilização futura de dados observacionais (MORAES, 2015). A avaliação da qualidade realizada neste trabalho se baseia na metodologia desenvolvida por Moraes (2015), conforme fluxograma disposto na Figura 12.

**Figura 12 - Avaliação da Qualidade de dados**



Fonte: Moras (2015) adaptado

Dado que o foco deste trabalho é a previsão de rampas, as quais consistem em mudanças bruscas no gradiente local da série temporal da potência, os testes de qualidade foram adaptados para que não identifiquem eventos de rampa como outliers. Tendo isso em vista, foram aplicados os testes de lacunas, de limites e de persistência. Outros testes, como os de consistência temporal, não se aplicam aos dados observados e ao foco deste trabalho.

- Teste de lacunas: Tem como objetivo identificar falhas na continuidade dos dados registrados, avaliando a descontinuidade e possível duplicidade de datas.
- Teste de limites: Busca identificar se há valores não condizentes com os limites estabelecidos para todos os parâmetros. Avaliando os limites de medição do sensor e a função densidade de probabilidade.
- Teste de persistência: Identifica se há sequências de dados repetidos que podem ser enquadrados como suspeitos ou anômalos.

## **4.2 Modelagem mesoescalar com WRF**

Conforme a metodologia descrita, o WRF é utilizado neste trabalho em conjunto com os modelos locais, visando realizar uma previsão na escala da central eólica. Tendo em vista que o foco da metodologia é a previsão de rampas de potência ativa, e a saída utilizada do WRF é velocidade do vento, foi elaborado um modelo visando converter a velocidade em potência, fazendo uso dos dados observacionais da central.

Para utilização do WRF, inicialmente é necessário definir a configuração do modelo a ser utilizada, como WRF-ARW ou WRF-NMM (Skamarock, *et al.*, 2021; Vemuri, A. *et al.*, 2022; MMM/NCAR - Mesoscale & Microscale Meteorology; Janjic, Z. I., 2003). O WRF-ARW é mais utilizado para simulações de pequeno e médio prazo, a configuração permite alta resolução espacial e é altamente configurável, permitindo diferentes tipos de parametrizações. O NMM é mais utilizado para previsões operacionais em larga escala,

também permite simulações em alta resolução e é mais focado em previsões de médio e longo prazo, quando comparado ao WRF-ARW.

Após a escolha da configuração do modelo, é feito o ajuste dos dados de entrada, incluindo condições iniciais e de contorno, e seleção dos parâmetros físicos relevantes. Os parâmetros físicos relevantes para o WRF incluem a parametrização da superfície, como o uso de modelos de cobertura do solo e umidade do solo, além de parametrizações de convecção, radiação, e turbulência. Também é considerada a interação entre a atmosfera e o solo, como o efeito de relevo e uso da terra. Esses parâmetros influenciam diretamente a precisão das previsões de velocidade do vento (Kirthiga et al., 2018; Souza et al., 2023; Aylas et al., 2020; Zha et al., 2019).

O modelo utilizado neste trabalho é o WRF-ARW. Os dados de entrada e de contorno são previsões obtidas através do modelo *Global Forecasting System* (GFS) com resolução de 0.25 grau, as quais são atualizadas a cada 6 horas, permitindo 4 lançamentos diários. Na Tabela 2, estão apresentadas as parametrizações do modelo.

Tabela 2 - Parametrizações do WRF adotadas para este trabalho.

<u>Módulo</u>	<u>Parametrização</u>
Microfísica	WSM6
Cumulus	Kain-Fritsch
Radiação OL/OC	RRTMG
Física de Superfície	Revised MM5 Scheme
Camada Limite Planetária	Shin-Hong
Física do solo	NOAH

Fonte: CER/UFPE

Os módulos e parametrizações estão resumidos abaixo e são detalhados na nota técnica do NCAR, 2019.

Microfísica de nuvens: responsável pelo cálculo dos processos de mistura na atmosfera, vapor de água, condensação, evaporação, precipitação e outros estados da água na atmosfera, incluindo chuvas não convectivas. No modelo existem diferentes tipos de parametrização possíveis, onde cada uma delas lida com os processos de mistura atmosférica de diferentes formas. A parametrização WSM6 se diferencia como sendo a mais adequada para resolução em grades de nuvem, considerando a eficiência e a fundamentação teórica.

Física de nuvens Cumulus: responsável pelos efeitos em escala interna à grade de nuvens convectivas e/ou rasas. Busca representar fluxos verticais devido a correntes ascendentes e descendentes não resolvidas internamente, compensando o movimento fora das nuvens.

Radiação de ondas Curtas e Longas: Fornecem tendências de temperatura atmosférica devido à divergência do fluxo radiativo e radiação de onda longa e onda curta descendente da

superfície para o balanço de calor do solo. A radiação de ondas longas inclui radiação infravermelha ou térmica absorvida e emitida por gases e superfícies. O fluxo radiativo ascendente de ondas longas vindo do solo é determinado pela emissividade da superfície que por sua vez depende do tipo de uso do solo, bem como da temperatura do solo. A radiação de ondas curtas inclui comprimentos de onda visíveis e circundantes que constituem o espectro solar.

Física de superfície: os esquemas de camada superficial calculam as velocidades friccionais e os coeficientes de troca para permitir o cálculo dos fluxos de calor e umidade pelos modelos de solo e de estresse em superfície no esquema de camada limite planetária;

Camada Limite Planetária: responsável pelos fluxos de vórtices turbulentos verticais em “subgrade” em toda a coluna atmosférica, não apenas na camada limite planetária;

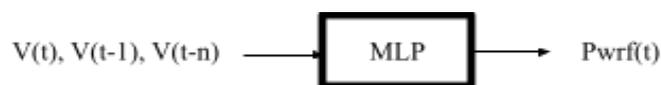
Física do Solo: o modelo de física de solo usa as informações provindas dos esquemas de superfície, as forçantes radiativas e as forçantes de precipitação, juntamente com as informações internas das propriedades e das variáveis de estado em superfície para fornecer fluxos de calor e umidade nos pontos em terra e gelos marinhos.

Dessa forma, o WRF fornecerá uma previsão de velocidade do vento (dentre outras variáveis) para diferentes pontos de malha de uma região. Para se adequar aos dados observacionais, foram selecionados os dados cuja latitude e longitude correspondem com os dados da central de interesse.

#### 4.2.1 Modelagem da curva de potência

Os dados de velocidade do vento previstos pelo WRF serão convertidos em potência fazendo uso dos dados observacionais da central de interesse. Para realizar a conversão de velocidade em potência, serão utilizadas variáveis regressoras da velocidade prevista do WRF tomadas em diferentes instantes de tempo e como alvo, a potência da central ou do cluster avaliado (Figura 13).

Figura 13 - Diagrama modelagem curva de potência



Fonte: Própria autora

#### 4.3 Modelo de referência

A persistência é um modelo de previsão amplamente utilizado como modelo de referência na literatura (Zeng et al., 2012; Kassa, et al., 2016; Clemente, 2018; Gao, et al., 2020; Nazare et al., 2020; Ogliari et al., 2021). O modelo baseia-se na premissa de que a

potência de saída em um determinado intervalo de tempo futuro, será a mesma observada no presente, quando a previsão é realizada (Kassa, et al., 2016) (Equação 2).

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

De acordo com Nielsen et al. (1998), a utilização da persistência como modelo de previsão se fundamenta no conceito de que a atmosfera terrestre pode ser considerada quasi-estacionária, ou seja, a mudança ocorre de forma muito lenta. Este método é o mais simples e mais econômico dos métodos de previsão e é comumente utilizado para previsão com o horizonte de 1 hora (Kassa, et al., 2016).

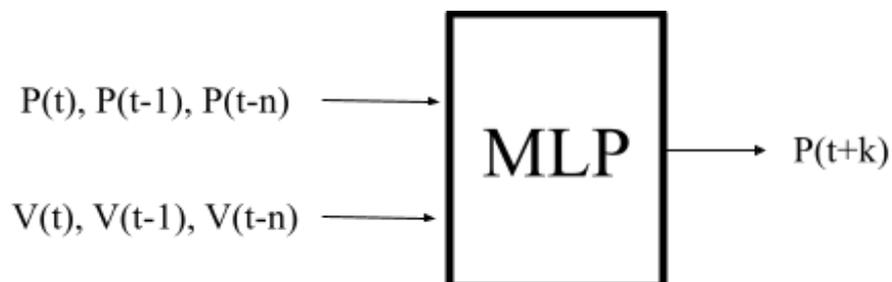
#### 4.4 Modelos de previsão global

Os modelos de ajuste global têm por objetivo a previsão de potência visando minimizar o erro de previsão sobre toda a série temporal, estes não são otimizados para a previsão de rampas, mas funcionam como uma aproximação visando o ajuste global da série. A seguir são apresentados modelos globais de previsão discutidos no trabalho de Clemente (2018), que serão também aplicados neste trabalho.

##### 4.4.1 Modelo de previsão global (G1)

Esse modelo é formado por uma rede neural do tipo MLP, na qual a entrada compreende uma janela de um passado recente contendo 'n' dados observacionais da própria série temporal de potência (P), incluindo o instante atual (t), assim como 'n' dados observacionais da velocidade do vento (V) no local de interesse, e a saída consiste na previsão da mesma série temporal de potência, em 'k' passos à frente, conforme descrito na Figura 14.

Figura 14 - Diagrama representando o modelo G1



Fonte: Própria autora

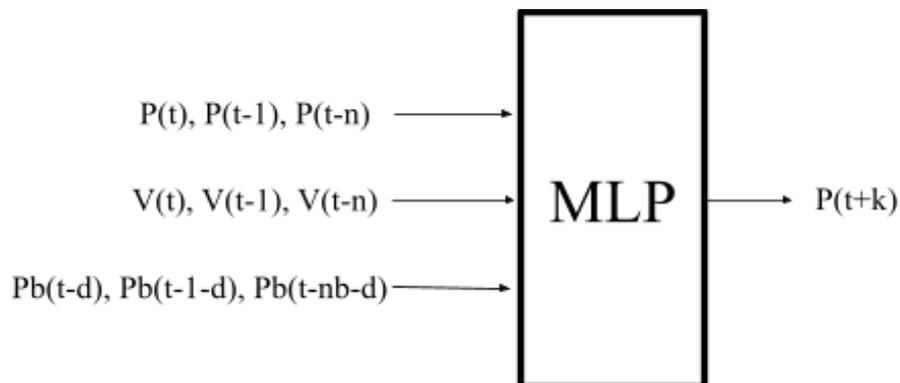
#### 4.4.2 Modelo de previsão global com central à barlavento

Esse modelo também visa o ajuste minimizando o erro de previsão sobre toda a série temporal, no entanto, utiliza, como dado de entrada, adicionalmente às séries temporais de potência ativa e de velocidade do vento da central de interesse, os dados observacionais de uma central a barlavento. Nos exemplos a seguir, “P” representa a central de interesse e “Pb” representa a central a barlavento. É utilizada uma única rede, contendo como entrada uma matriz de variáveis regressoras contendo ‘n’ dados observacionais de “P” e ‘nb’ observações de “Pb”.

Os dados da central à barlavento podem ser aplicados de diferentes formas, dado que sua influência sobre a central de interesse irá variar a depender da distância entre ambas. Alguns dos modelos utilizam de um delay entre as centrais. Para o cálculo do delay ideal, foi traçada a correlação variando esse delay, até obter o maior valor de correlação.

- Variante 1 (Modelo G2): As ‘nb’ variáveis regressoras utilizadas em “Pb” possuem um atraso d (delay) com relação ao instante atual ‘t’, como exemplificado na Figura 15:

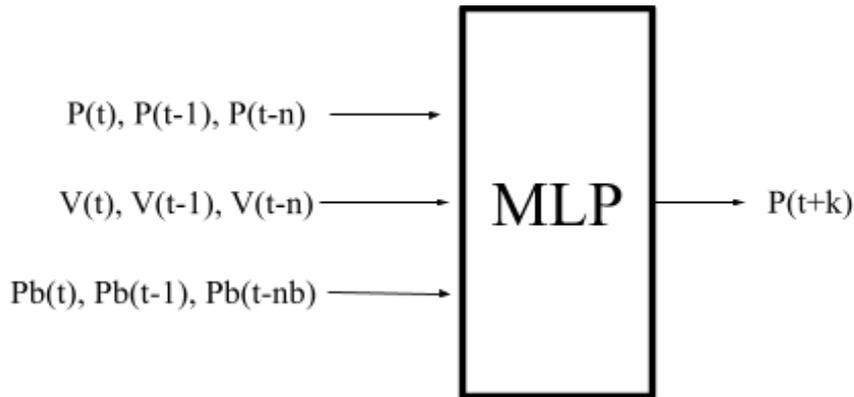
**Figura 15 - Diagrama representando o modelo G2**



Fonte: Própria autora

- Variante 2 (Modelo G3): Esta variante utiliza como entrada as mesmas séries temporais que as do modelo anterior (G2), entretanto, não leva em consideração o delay entre as centrais T2 e T1, sendo assim, a janela de variáveis regressoras de Pb possui ‘nb’ observações de um passado recente incluindo o instante atual  $t$ , como mostra a Figura 16.

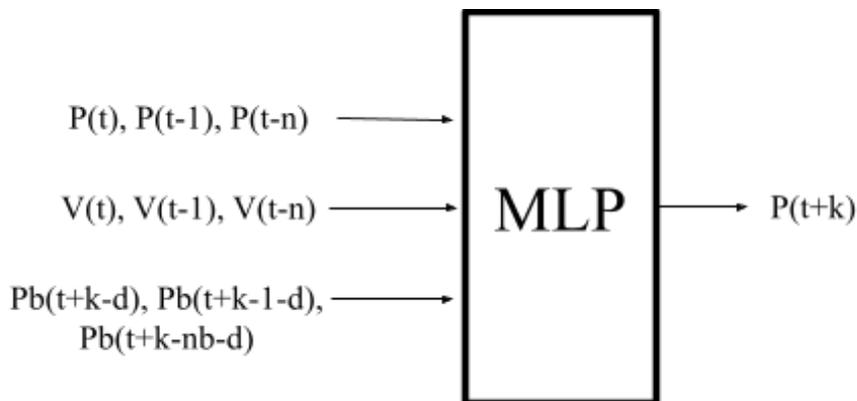
**Figura 16 - Diagrama representando o modelo G3**



Fonte: Própria autora

- Variante 3 (Modelo G4): A variante 3 considera que há um delay entre as centrais, no entanto, diferente da Variante 2, esse delay será em relação ao instante 't+k', onde 'k' é o horizonte de previsão. O Diagrama da rede neural pode ser observado na Figura 17.

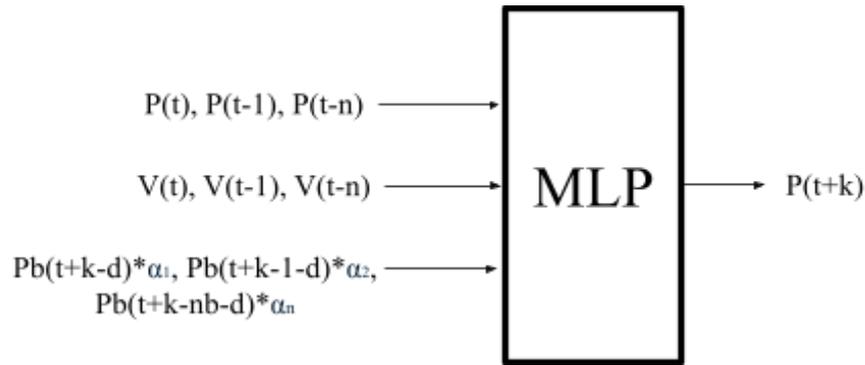
**Figura 17 - Diagrama representando modelo G4**



Fonte: Própria autora

- Variante 4 (Modelo G5): Da mesma forma que foi realizado na Variante 3, nesta variante do modelo, o delay também é considerado em relação ao instante 't+k', no entanto, para esse modelo cada variável regressora da central a barlavento será multiplicada por um peso  $\alpha$  que varia de 0,1 a 1, de acordo com a posição temporal da variável. O modelo pode ser ilustrado na Figura 18.

**Figura 18 - Diagrama representando o modelo G5**



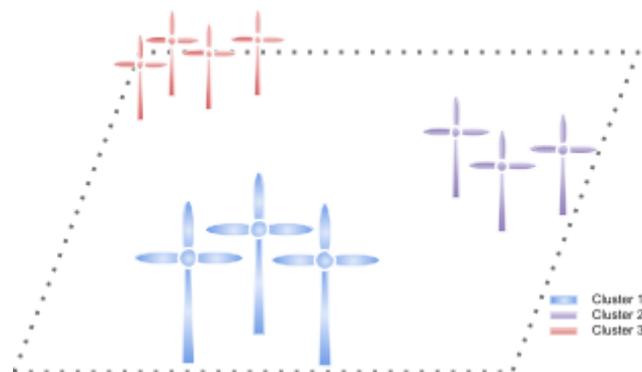
Fonte: Própria autora

#### 4.5 Clustering

As técnicas de *clustering* são utilizadas neste trabalho para auxiliar no agrupamento espacial dos aerogeradores, eliminando a necessidade de fazê-lo manualmente. Para cada central eólica avaliada, os 'X' aerogeradores têm suas potências de saída como dados de entrada para a extração de features e posterior agrupamento, na etapa de agrupamento é possível definir a qual cluster cada aerogerador pertence. Dentre as técnicas de *clustering* disponíveis, neste trabalho será utilizado o K-Means, uma das técnicas mais utilizadas na literatura (Verma et al., 2012; Mendes, 2017; Sreenivasulu, 2019; Ezugwu et., 2022).

Na Figura 19, é possível observar um esquema do que se espera de saída dos algoritmos de *clustering*.

**Figura 19 - Exemplo de agrupamento em central eólica**



Fonte: Própria autora

A Figura 19 ilustra como devem se comportar os agrupamentos formados dentro da central de interesse. No exemplo, a central possui 10 aerogeradores, os quais podem ser divididos espacialmente em 3 grupos. As técnicas de *clustering* irão realizar esse

agrupamento de forma automática, utilizando como dado de entrada a potência de saída dos aerogeradores.

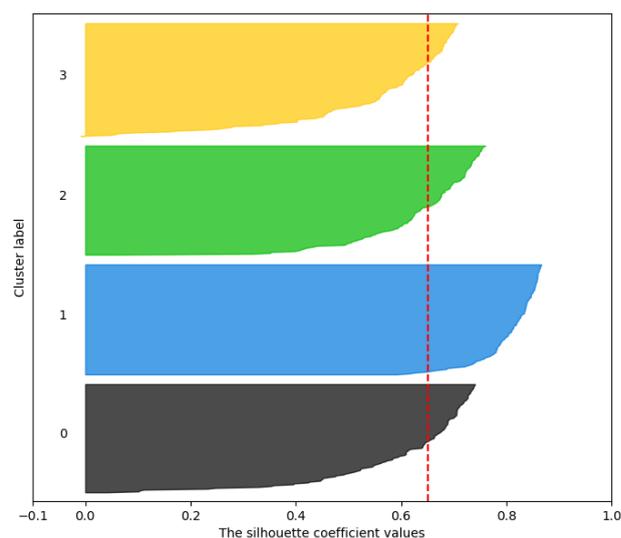
Neste trabalho, foi realizada uma avaliação para definir quais features melhor representam o conjunto de dados observado. Para a avaliação, foram testadas features como RMS, variância, pico a pico, curtose, dentre outras (Yagu, 2017; Xu et al., 2020).

As features são dados de entrada para os algoritmos de *clustering* para a realização do agrupamento dos aerogeradores, sendo assim, devem ser capazes de permitir a distinção entre as máquinas, ao mesmo tempo que encontram a similaridade entre as máquinas mais próximas fisicamente. Por fim, avalia-se qual conjunto de features conduz aos melhores resultados quanto à previsão de rampas.

### 4.5.1 - K-Means

Para utilização do método K-Means, define-se inicialmente a quantidade de clusters em que a amostra será particionada. Para tal, existem diferentes métodos que podem ser aplicados. Neste trabalho, foi utilizado o método da silhueta, desenvolvido por Rousseeuw (1986). Para este método, cada cluster é representado por uma silhueta, a qual mostra quais pontos se adequam bem dentro de determinado cluster e quais pontos estão entre clusters. A largura média da silhueta fornece uma avaliação da qualidade do particionamento e pode ser utilizada para determinar um número “ideal” de clusters (Rousseeuw, 1986). Na Figura 20, é exemplificado um conjunto de dados com distribuição em 4 clusters, de forma obter o melhor o coeficiente de silhueta (representado no eixo X).

Figura 20 - Exemplo de aplicação do método da Silhueta para estimativa de quantidade de Clusters



Fonte: scikit-learn

Para aplicação do K-Means ao conjunto de dados, foi utilizada a biblioteca Scikit-learn, em Python (Pedregosa et al., 2011). O K-Means é uma técnica que se baseia na média dos conjuntos de dados e na distância entre os pontos. Para realizar o agrupamento em 'K' clusters, o algoritmo define de forma aleatória 'K' pontos, que representam os centroides dos 'K' clusters. A seguir, o algoritmo calcula a distância euclidiana entre os pontos e os centroides, os pontos mais próximos são inseridos no mesmo cluster, após isso é calculada a média do agrupamento formado e definido o novo centroide a partir dessa média. Na sequência, a distância euclidiana é calculada novamente, e assim sucessivamente, até que a média não se altere tanto após sucessivas repetições (Verma et al., 2012).

Passo 1: calcula-se k pelo método da silhueta;

Passo 2: escolhe-se de forma aleatória k centroides;

Passo 3: calcula-se a distância entre cada centroide e todos os pontos do conjunto de dados;

Passo 4: atribui-se o ponto ao centroide cuja distância é a menor dentre todos os clusters;

Passo 5: calcula-se o novo centroide do cluster utilizando a média;

Passo 6: recalculam-se as distâncias euclidianas (Verma et al., 2012).

## 4.6 Modelos Locais

Os modelos de previsão local utilizam dos mesmos artifícios que os modelos de previsão global quando se trata das variáveis de entrada (potência e velocidade) e o tratamento destas, no entanto, o treinamento das redes neurais é realizado para cada cluster individual de aerogerador e para cada regime individual observado na série de potência (rampa de subida, descida e regime normal). Os clusters são formados fazendo uso do K-Means (técnica já descrita), e para identificação de rampas, foi utilizado o identificador de regime (IR).

Mediante o agrupamento dos dados em clusters e a identificação do regime, as redes são treinadas individualmente e posteriormente a previsão é realizada.

### 4.6.1 Mecanismo Identificador de Regime (IR)

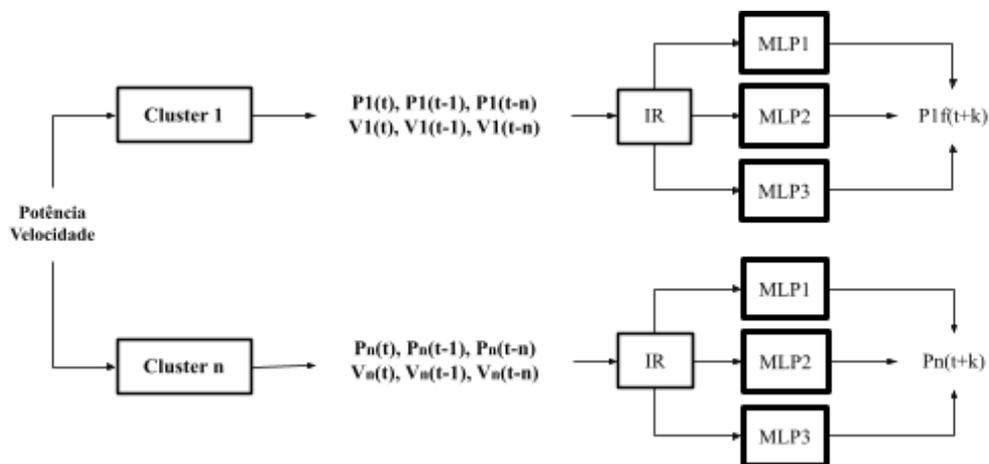
O IR foi utilizado para classificar eventos de rampas de subida, rampas de descida ou regime normal e se baseia na avaliação do gradiente local do sinal de potência em tempo real. Sempre que o valor absoluto do gradiente ' $gt$ ' permanece acima de um determinado limite ' $S_0$ ' durante um período de tempo suficientemente longo  $\Delta t$ , observa-se um regime de rampa, podendo ser de subida ou de descida a depender do sinal do gradiente. Essa definição de rampa utilizada para fundamentar o IR é utilizada por diversos autores Clemente, 2018; Ouyang et al., 2019; Liu et al., 2019, Li et al., 2020, Couto et al., 2021, Zhou et al., 2021, conforme já citado neste trabalho.

De acordo com Clemente (2018), os parâmetros ‘ $S_0$ ’ e  $\Delta t$  poderão variar a depender da localização da central e do tipo de central, sendo assim, o modelo também realiza a combinação dos parâmetros, com o objetivo de identificar a combinação entre eles que melhor descreve o comportamento das rampas naquele conjunto de dados.

#### 4.6.2 Modelo Local I (Modelo L1)

Após a clusterização e identificação de regime, esse modelo funciona de forma semelhante ao Modelo G1, considerando as variáveis regressoras da potência e da velocidade, iniciando em  $P(t)$  e  $V(t)$ . Na Figura 21 segue um diagrama de blocos exemplificando o modelo.

**Figura 21 - Diagrama representando o modelo L1**



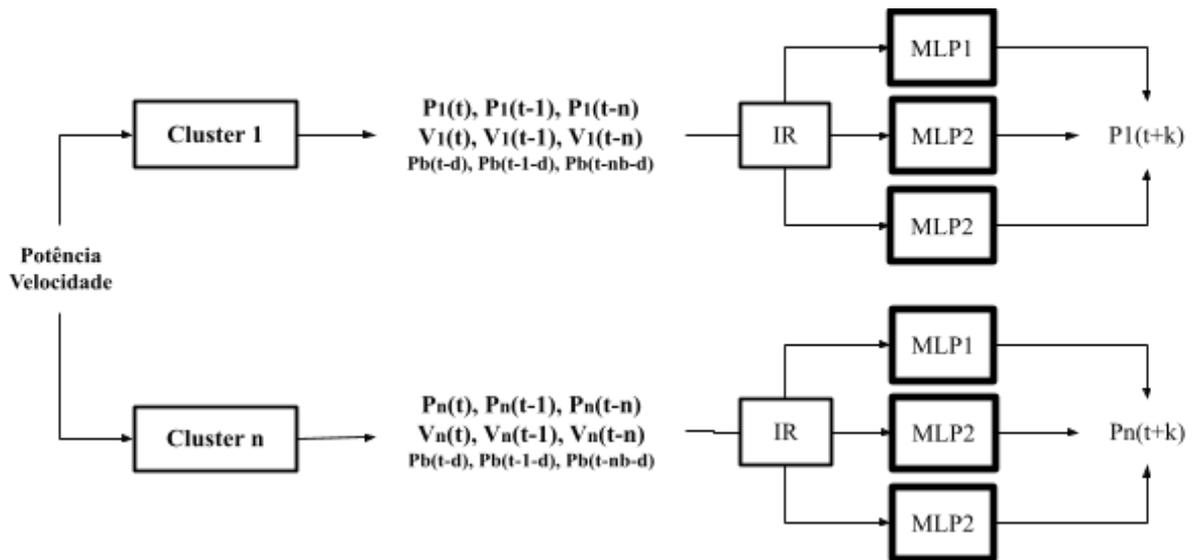
Fonte: Própria autora

#### 4.6.3 Modelo Local utilizando central à barlavento (L2, L3 e L4)

Assim como o modelo de ajuste global com dados a barlavento, os modelos locais também se utilizam de dados da central à barlavento ( $P_b$ ) da central de interesse. Esse modelo possui três variantes:

- Variante 1 (Modelo L2): Semelhante ao modelo G2, os dados a barlavento ( $T2$ ) contribuem com ‘ $nb$ ’ variáveis regressoras, as quais possuem um delay ‘ $d$ ’ em relação ao instante atual ‘ $t$ ’, conforme ilustrado na Figura 22:

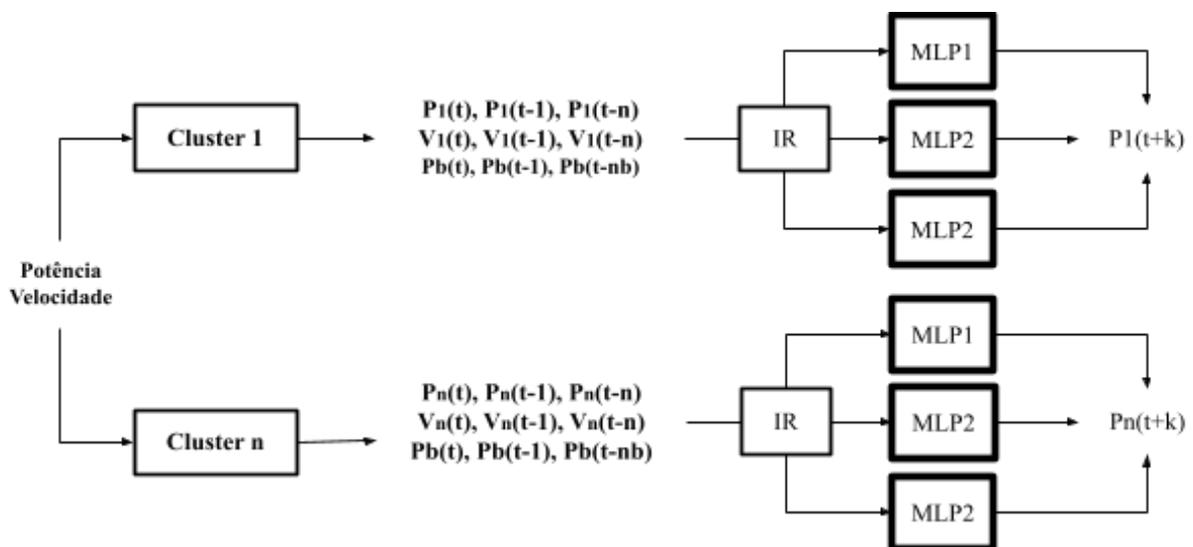
**Figura 22 - Diagrama representando o modelo L2**



Fonte: Própria autora

- Variante 2 (Modelo L3): Para essa variante do modelo, não é considerado delay entre os dados do local de interesse e dos dados a barlavento. O modelo pode ser ilustrado pela Figura 23:

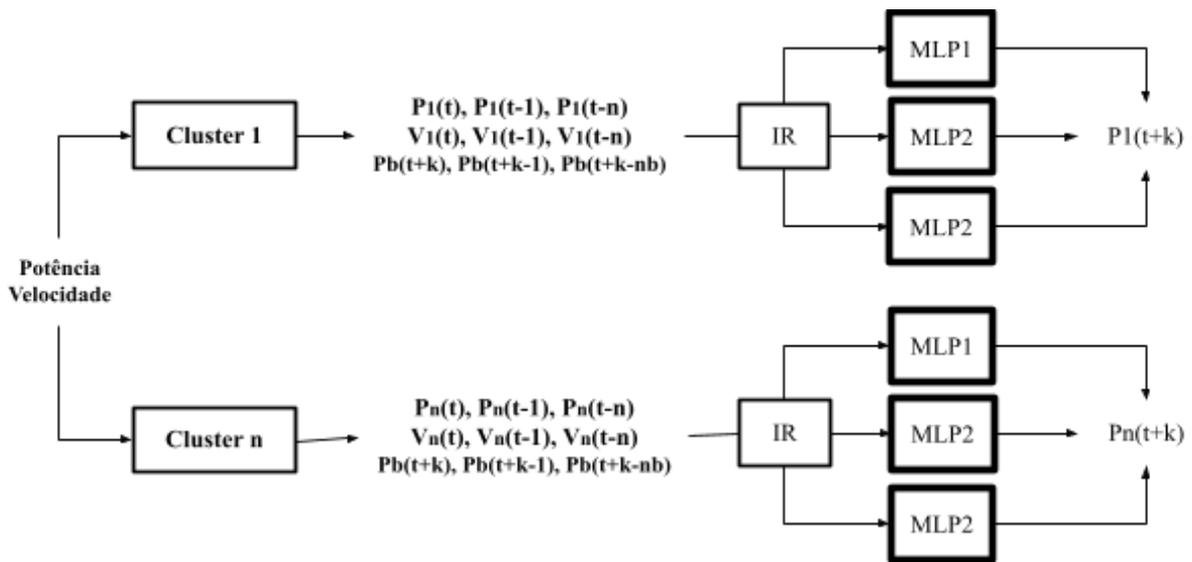
**Figura 23 - Diagrama representando o modelo L3**



Fonte: Própria autora

- Variante 3 (Modelo L4): Para esse modelo, é considerado o delay 'd', no entanto, semelhante ao modelo G4, o delay é em relação ao instante 't+k'. O modelo pode ser ilustrado na Figura 24.

**Figura 24- Diagrama representando o modelo L4**

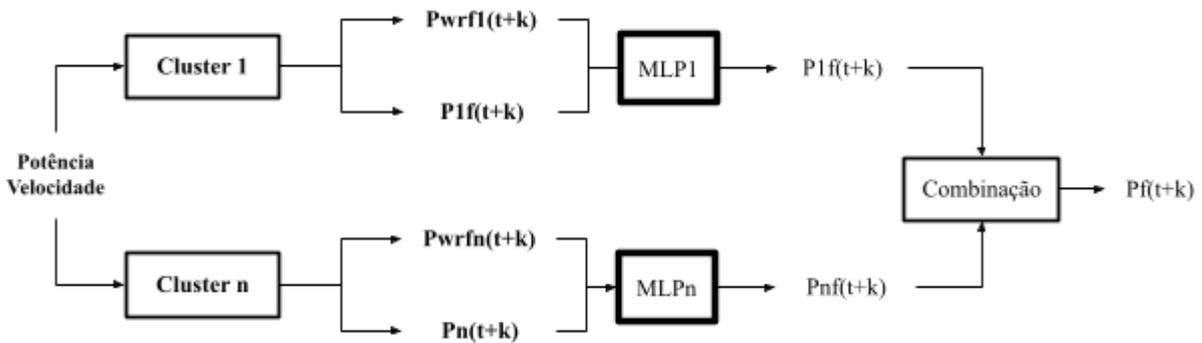


Fonte: Própria autora

## 4.7 Combinação de modelos

De acordo com a metodologia apresentada, são realizadas combinações das diferentes previsões de potência, obtidas através dos modelos numéricos (WRF) e estatísticos. Algumas técnicas podem ser utilizadas para a combinação, como a Análise de Componentes Principais, regressões lineares, ou diferentes tipos de redes neurais. Devido ao baixo custo computacional e elevada acurácia, neste trabalho será utilizada uma MLP simples.

Figura 25 - Combinação dos modelos



Fonte: Própria autora

## 4.8 Avaliação de resultados

Para realizar a avaliação da acurácia da previsão de rampas, este trabalho utilizará de métricas já utilizadas na literatura (Castillo, 2013; Han et al., 2020; Pereyra-Castro e Caetano,

2022). Quando é realizada uma previsão de rampas, existem três possibilidades de resultados para cada valor de rampa observado/previsto:

- Falso positivo (FP): Uma rampa foi prevista, mas não foi observada;
- Falso negativo (FN): Uma rampa foi observada, mas não foi prevista;
- Verdadeiro positivo (VP): Uma rampa foi prevista e observada;

Baseando-se nessas definições, é possível calcular alguns índices como a acurácia da previsão (FA) e a captura de rampa (RC), dispostos nas Equações 3 e 4:

$$FA = \frac{VP}{VP+FP} \quad (3)$$

$$RC = \frac{VP}{VP+FN} \quad (4)$$

Na Equação 5, Bs calcula o índice de Bias, que relaciona o número total de eventos de rampas previstos, dividindo-os pela quantidade real de ocorrências de rampa.

$$Bs = \frac{VP+FP}{VP+FN} \quad (5)$$

O Csi da Equação 6 calcula o índice de sucesso crítico. Esse fator relaciona os eventos de rampa previstos que ocorreram, com os eventos de rampa reais somados aos eventos que foram previstos, mas não ocorreram.

$$Csi = \frac{VP}{VP+FN+FP} \quad (6)$$

Na Equação 7 é calculada a taxa de alarme falso (FAR) relacionando o número de vezes que o evento de rampa foi previsto, mas não ocorreu (FP) com a soma de FP com VP (eventos onde a rampa foi prevista corretamente).

$$FAR = \frac{FP}{FP+VP} \quad (7)$$

Nas Equações 8 e 9, são calculadas as acurácias da previsão de rampas de subida e de descida.

$$RUP = \frac{Pup}{Tup} \quad (8)$$

$$RD = \frac{Pd}{Td} \quad (9)$$

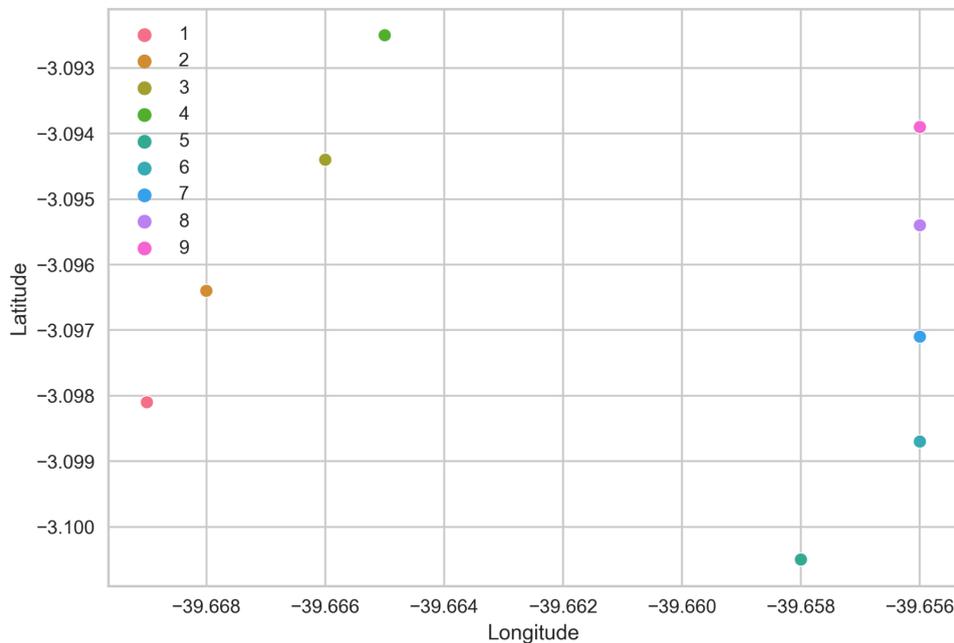
onde Pup e Pd representam respectivamente, o número de rampas de subida previstas corretamente, e Pd o número de rampas de descida previstas corretamente; Tup e Td, são respectivamente o número total real de rampas de subida e de descida.

## 5 ESTUDO DE CASO E DISCUSSÃO

Os dados observacionais utilizados no âmbito deste trabalho são provenientes de uma central eólica localizada no nordeste brasileiro. Os dados foram fornecidos através de parceria, e por questões de confidencialidade a fonte dos dados não será divulgada.

A central de interesse possui 9 aerogeradores, distribuídos conforme a Figura 26. A central à barlavento fica a cerca de 9 km, ao leste da central de interesse, e a 10 km da costa marítima. Os dados utilizados contemplam o período de 1 ano, e a previsão foi realizada utilizando o método de validação cruzada, onde  $\frac{2}{3}$  dos dados são utilizados para calibrar os modelos, e  $\frac{1}{3}$  é utilizado para validá-los, conforme Figura 27. As medições de potência e velocidades dos dados observacionais são realizadas a cada 30 minutos, e o horizonte de previsão considerado é de 3 horas (6 time-steps à frente).

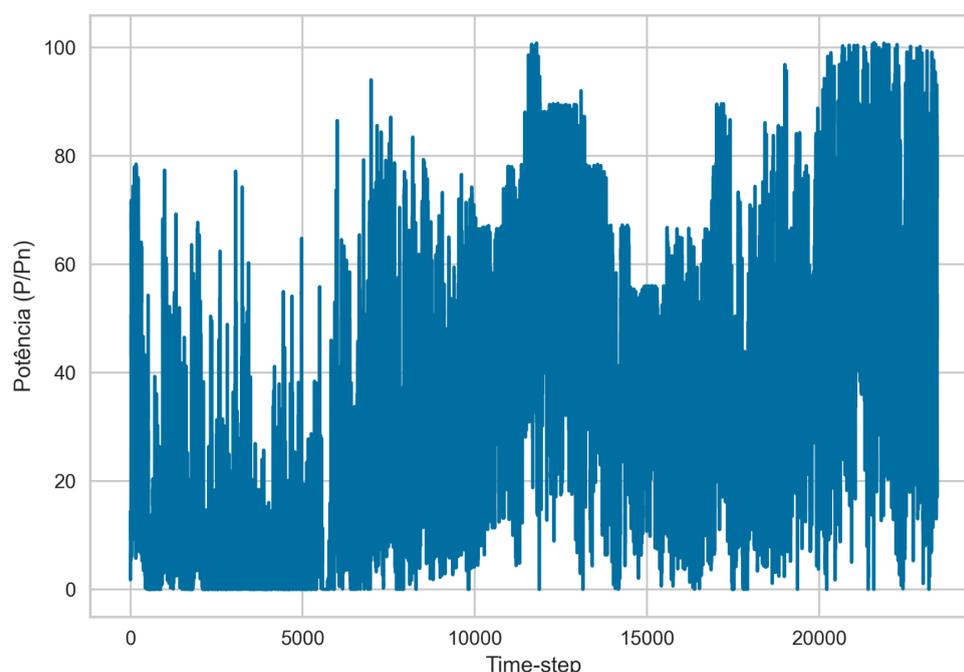
Figura 26 - Coordenadas da central de interesse



Fonte: Própria autora

Tendo em vista a confidencialidade sobre os dados apresentados, a potência da central foi normalizada pela potência nominal, representada por percentuais da potência nominal.

Figura 27 - Série de Potência



Fonte: Própria autora

## 5.1 Desempenho do modelo de referência

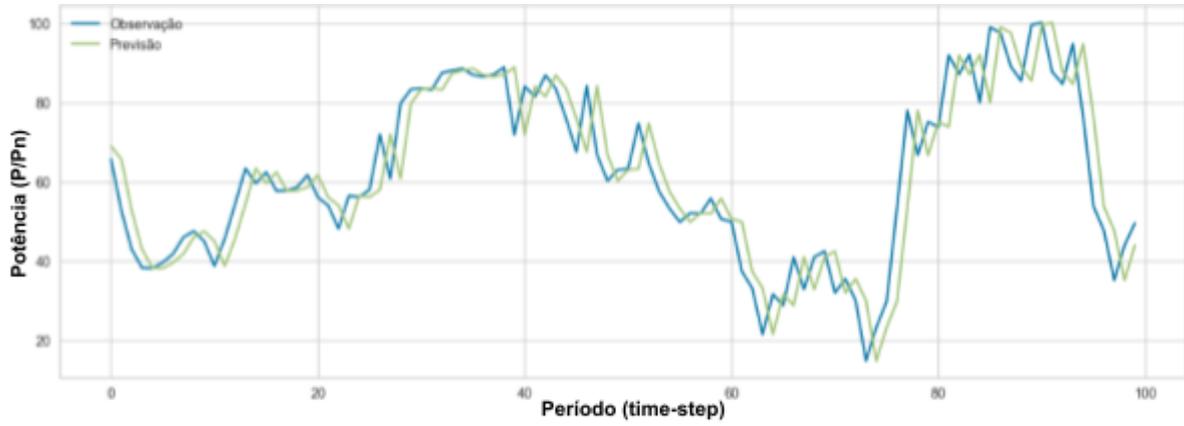
A persistência foi utilizada como modelo de referência. Na Tabela 3, são apresentados alguns comparativos considerando a previsão para os 6 horizontes de previsão avaliados, 3 horas à frente. As métricas utilizadas foram o coeficiente de correlação de Pearson e o erro médio quadrático normalizado pela média da observação.

Tabela 3- Desempenho do modelo de persistência

Horizonte	k=1	k=2	k=3	k=4	k=5	k=6
Correlação	0,93	0,84	0,76	0,68	0,60	0,53
NRMSE	0,16	0,22	0,27	0,31	0,34	0,38

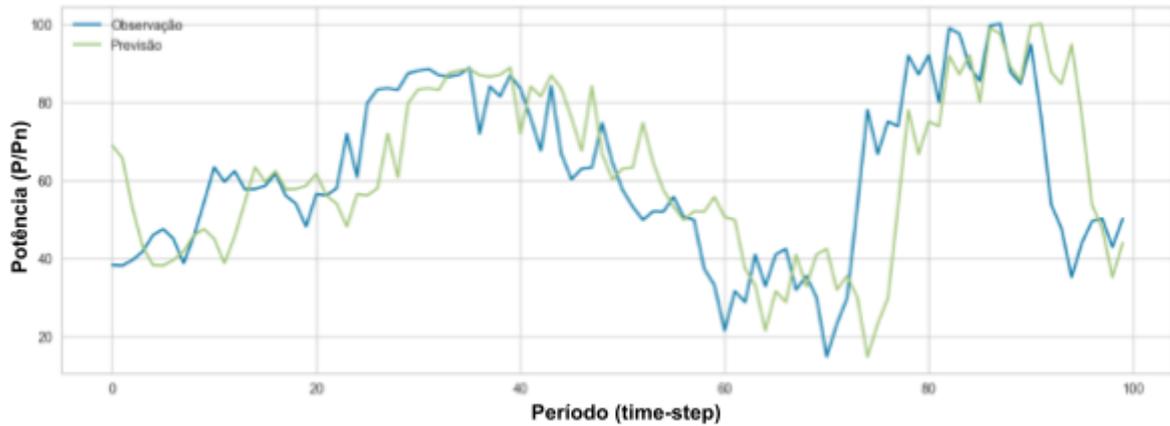
A persistência é um modelo mais simplificado para previsão, e parte do pressuposto que a medição irá se repetir “k” steps a frente. Para horizontes de previsão menores, possui uma boa correlação, no entanto, para horizontes maiores há uma queda significativa. Na Figura 28, é possível observar a comparação de um corte feito na série de observação e previsão para esse modelo, considerando k=1. Na Figura 29, é exibido o corte considerando k=4, ou seja, uma previsão de 2 horas à frente.

Figura 28 - Previsão Persistência k=1



Fonte: Própria autora

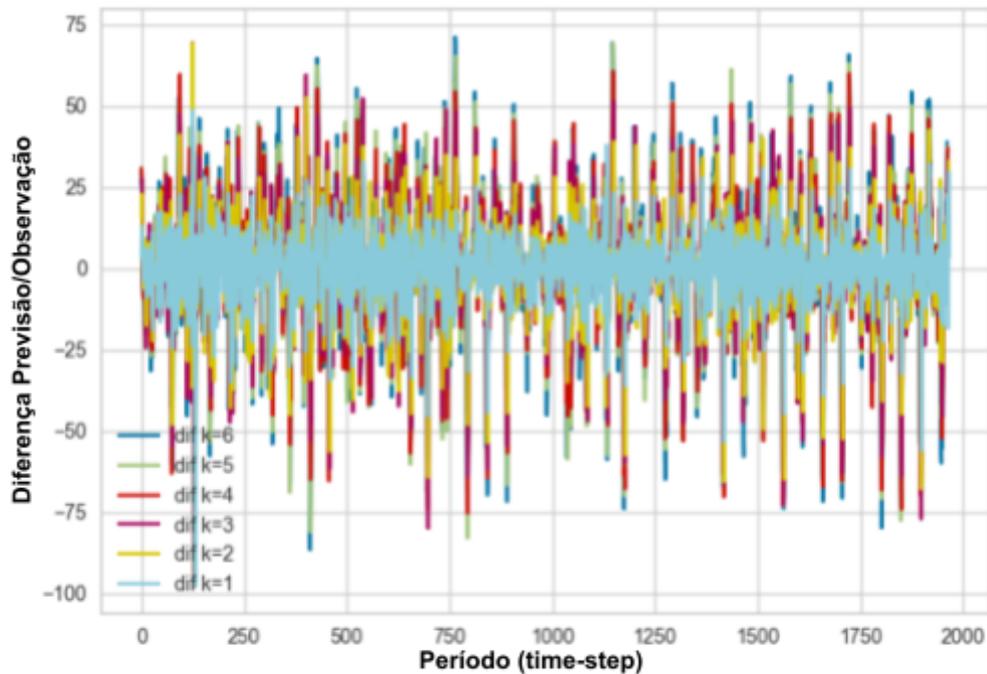
Figura 29 - Previsão Persistência k=4



Fonte: Própria autora

Ao observar a diferença ao longo do tempo entre o previsto e o observado, para os diferentes horizontes de previsão (Figura 30), é verificado o aumento significativo do erro a cada horizonte de previsão

Figura 30 - Diferença entre a Previsão e Observação - Persistência



Fonte: Própria autora

## 5.2 Modelos Globais

Os modelos globais são desenvolvidos para realizar a previsão reduzindo o erro global da série, sendo assim, não são especificamente para previsão de rampas. Mas trazem resultados consideravelmente superiores quando comparados ao modelo da persistência. A Tabela 4 mostra o comparativo entre a correlação e o NRMSE para todos os modelos globais analisados.

Tabela 4 - Correlação e NRMSE para os modelos globais

Modelo	Horizonte	k=1	k=2	k=3	k=4	k=5	k=6
G1	Correlação	0,94	0,86	0,79	0,73	0,67	0,62
	NRMSE	0,18	0,27	0,33	0,36	0,40	0,42
G2	Correlação	0,94	0,86	0,79	0,73	0,67	0,62
	NRMSE	0,18	0,27	0,33	0,37	0,40	0,42
G3	Correlação	0,94	0,86	0,79	0,73	0,67	0,61
	NRMSE	0,18	0,27	0,33	0,36	0,40	0,42
G4	Correlação	0,94	0,86	0,79	0,73	0,67	0,61
	NRMSE	0,18	0,27	0,33	0,37	0,40	0,42

G5	Correlação	0,94	0,86	0,79	0,73	0,66	0,61
	NRMSE	0,18	0,27	0,33	0,37	0,40	0,42

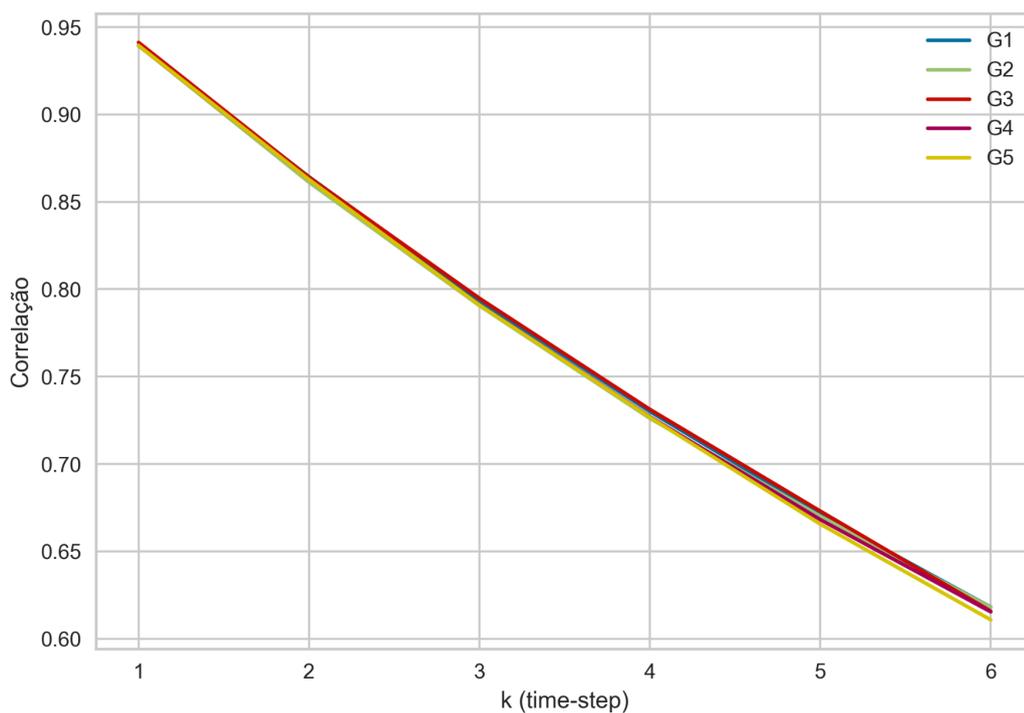
A Tabela 5 traz análise comparativa entre as previsões dos 5 modelos com a observação em  $k=1$  (primeiro horizonte de previsão) quando extraídas as features rms, variância, pico a pico, curtose, assimetria e mediana.

Tabela 5 - Features comparativas - Modelos Globais ( $k=1$ )

Modelos	RMS	Pico a pico	Curtose	Assimetria	Mediana
Observação	54,24	100	-0,93	0,15	47,18
G1	53,68	156,35	-0,85	0,15	47,13
G2	53,32	103,90	-0,90	0,13	46,88
G3	53,08	129,158	-0,91	0,13	46,88
G4	54,16	119,104	-0,89	0,14	47,73
G5	54,18	119,10	-0,89	0,14	47,80

Nas Tabelas 4 e 5, é possível observar que os modelos globais obtiveram resultados semelhantes, com o modelo G3 se destacando ligeiramente na correlação. Nas Figuras 32 e 33 é possível observar o comparativo do da correlação para todos os modelos. Quando compara-se com a persistência, é possível observar uma melhora significativa no parâmetro da correlação para os modelos globais em maiores horizontes de previsão.

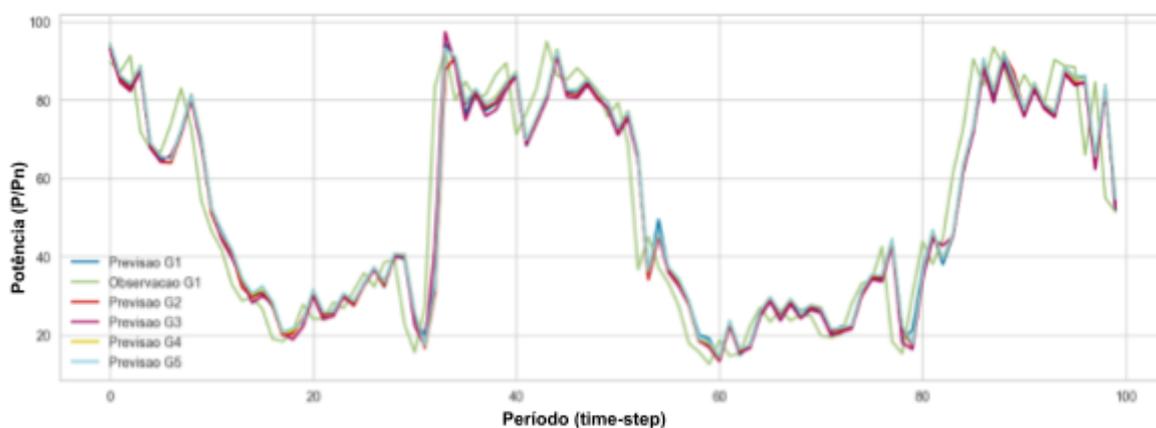
Figura 31 - Correlação dos modelos globais



Fonte: Própria autora

Analisando os modelos individualmente quanto às previsões, há uma coerência nos resultados obtidos, e estes se comportam de forma similar obtendo resultados bem semelhantes quando traçada a correlação e o NRMSE, no entanto, ao traçar algumas features é possível observar onde estes se diferenciam (Tabela 5), e alguns se destacam em relação a outros em pontos específicos. No ‘Anexo A’ foram traçados comparativos da previsão e observação para cada modelo, e na Figura 32 segue comparativo de todos os modelos em intervalo comum (no eixo X está representado apenas um intervalo de tempo da série, com time-step de 30 minutos).

Figura 32 - Previsão modelos globais e observação para k=1



Fonte: Própria autora

### 5.3 Agrupamentos (clusters) formados

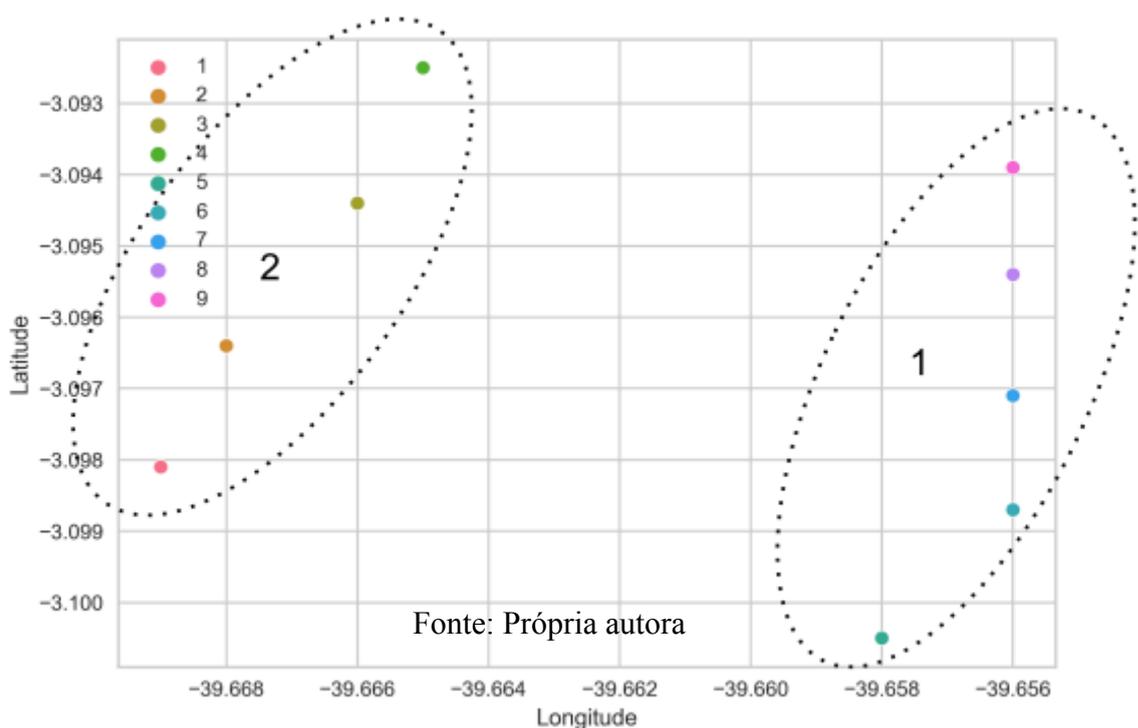
Para realizar a divisão por agrupamentos, foi utilizado o K-Means (devido à simplicidade e aplicabilidade nos dados de interesse). Conforme descrito na metodologia, o K-Means tem como dados de entrada a amostra (ou features desta) e a quantidade de clusters em que esta será particionada. Dado que o agrupamento é realizado na central, as amostras são as respectivas potências dos aerogeradores.

Foi verificada a extração de features (média, moda, mediana, máximo, mínimo) das séries de potência, no entanto, o quantitativo de dados não possibilita que o algoritmo de *clustering* realize o agrupamento de forma acurada, pois apenas as features não são suficientes para descrever o comportamento da série e caracterizá-la. Dessa forma, em lugar das features, foi utilizada a série de potência como dado de entrada no algoritmo de agrupamento.

O segundo parâmetro do K-Means é a quantidade de clusters que a amostra será dividida. Para o cálculo desse parâmetro foi utilizado o método da silhueta descrito na metodologia, que com os dados da amostra descreve qual a quantidade de clusters melhor se adequa aos dados (fornece menor erro). Para a amostra utilizada, esse valor é de 2 clusters.

Ao aplicar o algoritmo de agrupamento nos dados de potência considerando 2 clusters, a divisão dos aerogeradores segue o comportamento espacial observado na Figura 33, ou seja, os aerogeradores 1, 2, 3 e 4 formando o cluster 1, e os aerogeradores 5, 6, 7, 8 e 9 formando o cluster 2. Conforme é possível observar, espacialmente é notável o distanciamento entre os dois grupos de aerogeradores e essa divisão seria inferida facilmente apenas com a observação. No entanto, ao trabalhar com grandes conjuntos de dados, é necessário um mecanismo automatizado de auxílio.

Figura 33- Divisão em clusters

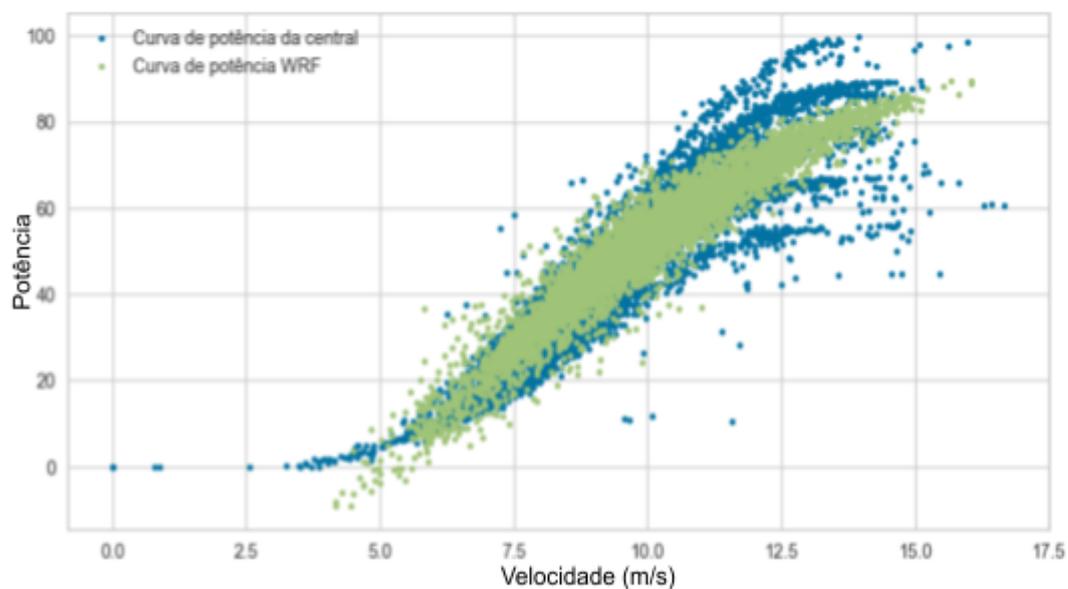


## 5.4 Modelos locais e WRF

### 5.4.1 Curva de potência e combinação de modelos

A velocidade extraída do WRF foi convertida em potência, fazendo uso dos dados observacionais da central, utilizando variáveis regressoras da velocidade para calibração. Na Figura 34 é exibida a potência versus velocidade da central de interesse comparando-a ao mesmo gráfico referente aos dados do WRF.

Figura 34 - Curva de potência da central e curva de potência WRF



Fonte: Própria autora

Com os dados de potência referente ao WRF calculados, é possível realizar a combinação com os dados de previsão dos modelos locais clusterizados. A configuração de combinação que obteve melhor desempenho foi a fazendo uso de uma MLP com 4 variáveis regressoras da potência do WRF combinadas com a previsão dos modelos locais. Na Figura 35 é possível exemplificar de forma visual quais valores são combinados para a previsão final, as curvas em vermelho e verde representam as previsões (WRF e modelo local, respectivamente), e a curva em azul é a observação.

Figura 35 - Comparativo previsão L1, previsão WRF e Observação (k=1)

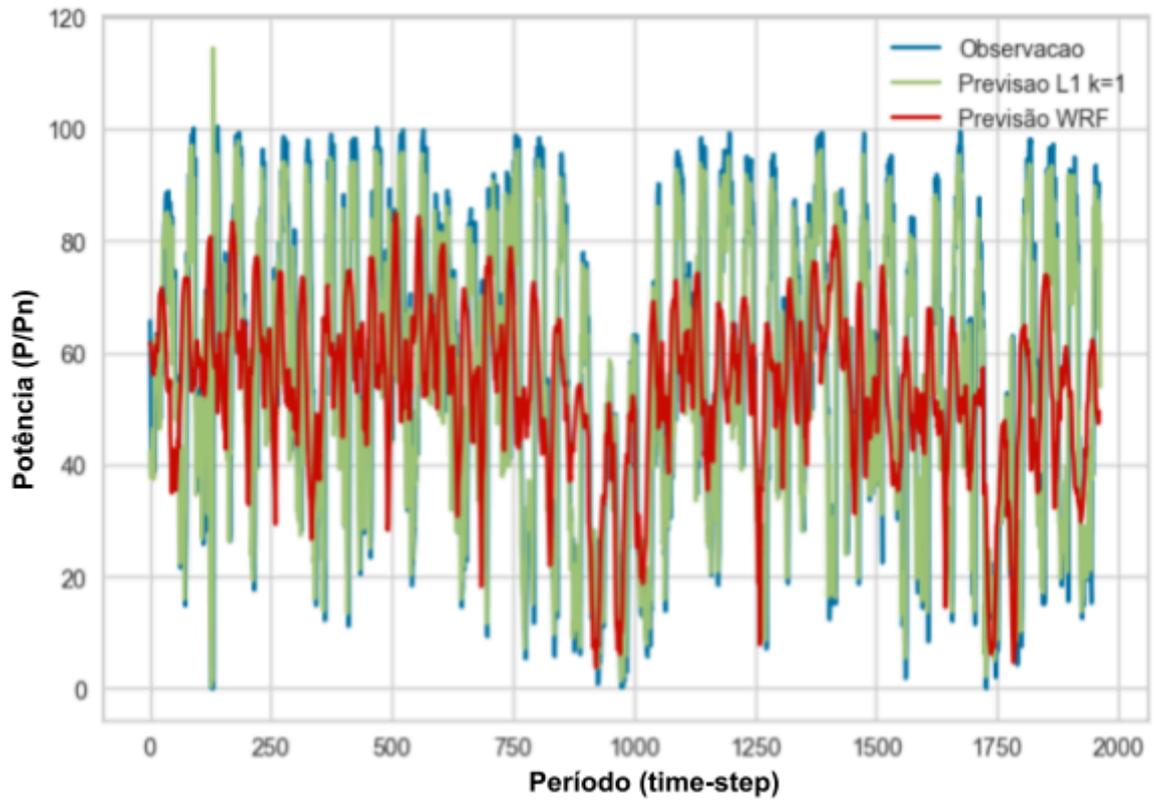
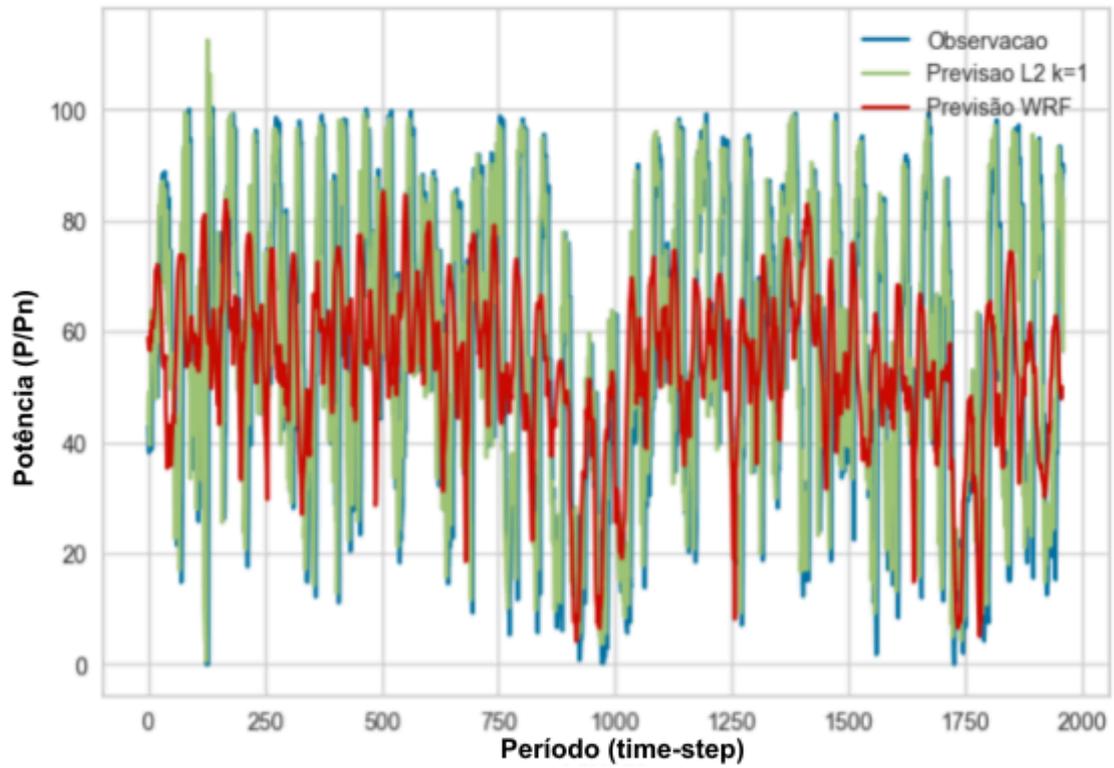


Figura 36 - Comparativo previsão L2, previsão WRF e Observação (k=1)



Fonte: Própria autora

Figura 37 - Comparativo previsão L3, previsão WRF e Observação (k=1)

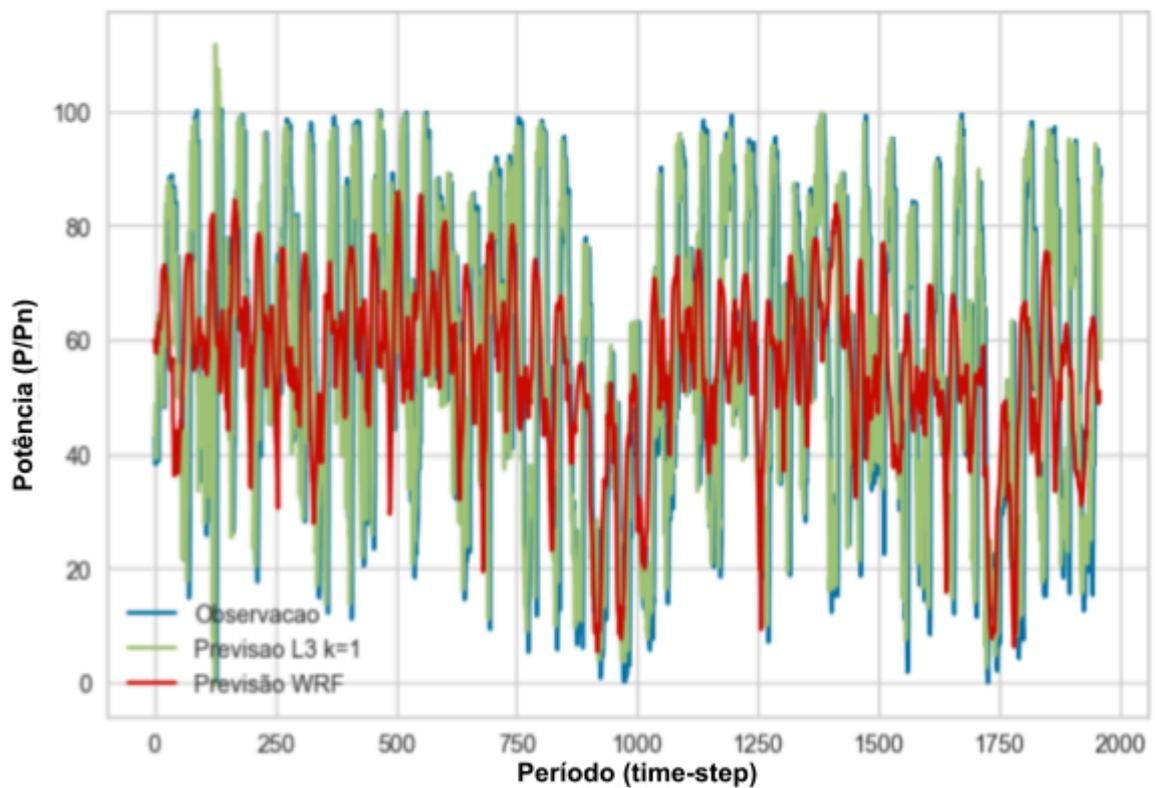
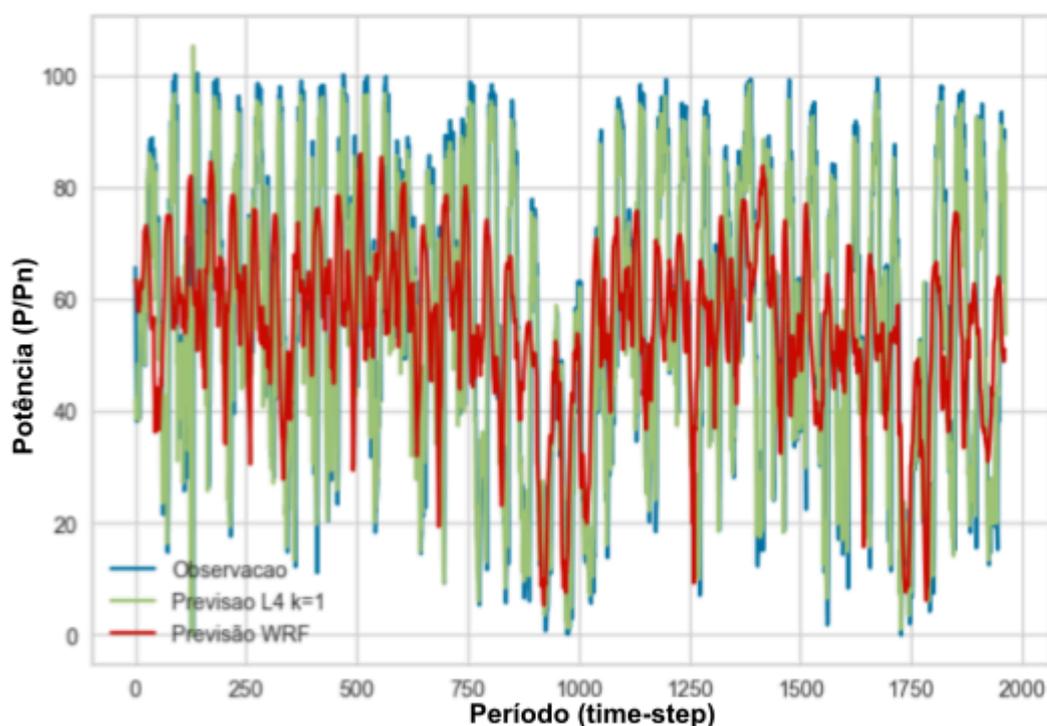


Figura 38 - Comparativo previsão L4, previsão WRF e Observação (k=1)



Fonte: Própria autora

As figuras 35, 36, 37 e 38 comparam a previsão de potência dos modelos locais, com a observação e a previsão de potência do WRF. Nas tabelas 6 e 7 é possível avaliar as métricas de correlação e NRMSE para essas previsões.

Tabela 6 - Correlação para os modelos locais

CORRELAÇÃO				
Horizonte	L1	L2	L3	L4
k=1	0,94	0,94	0,94	0,94
k=2	0,86	0,86	0,86	0,87
k=3	0,79	0,79	0,79	0,80
k=4	0,72	0,73	0,72	0,74
k=5	0,66	0,67	0,67	0,68
k=6	0,61	0,62	0,62	0,63

Tabela 7 - NRMSE para os modelos locais

NRMSE				
Horizonte	L1	L2	L3	L4
k=1	0,18	0,19	0,19	0,18
k=2	0,27	0,27	0,27	0,27
k=3	0,33	0,33	0,33	0,32
k=4	0,37	0,37	0,37	0,36
k=5	0,40	0,40	0,39	0,39
k=6	0,42	0,42	0,42	0,42

Conforme é possível observar, os modelos têm um comportamento semelhante quando avalia-se a correlação e NRMSE, e os resultados desses parâmetros também se assemelham aos obtidos para os modelos globais. Essa avaliação considera a junção das previsões realizadas para os regimes, mais a frente será avaliado o desempenho do modelo por regime (subida/descida).

- Modelo L1

Este modelo não leva em consideração os dados da central à barlavento, sendo assim, os dados de entrada são as variáveis regressoras da potência do cluster de interesse e as regressoras da velocidade média do cluster de interesse. As Figuras 39 e 40 ilustram a previsão de ambos os clusters formados, comparadas com a observação em um intervalo de tempo específico.

Figura 39 - Previsão de Potência Modelo L1 K=1 Cluster 1

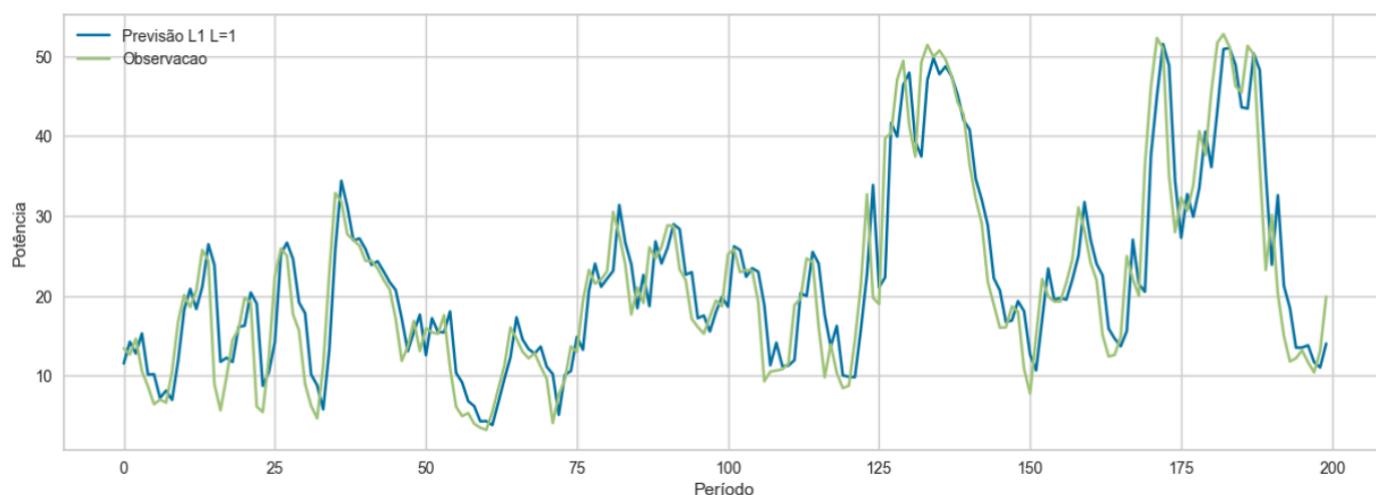
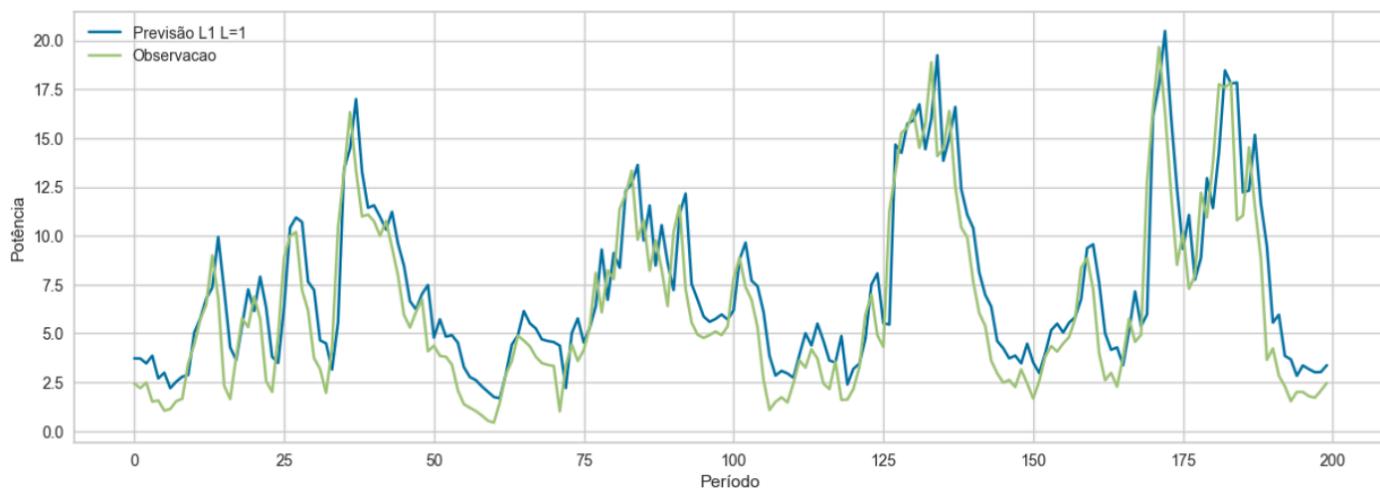


Figura 40 - Previsão de Potência Modelo L1 K=1 Cluster 2



- Modelo L2

Este modelo leva em consideração a central a barlavento, assim como as demais variáveis regressoras utilizadas no Modelo L1. As Figuras 41 e 42 apresentam as previsões dos clusters 1 e 2, respectivamente utilizando o Modelo L2.

Figura 41 - Previsão de Potência Modelo L2 K=1 Cluster 1

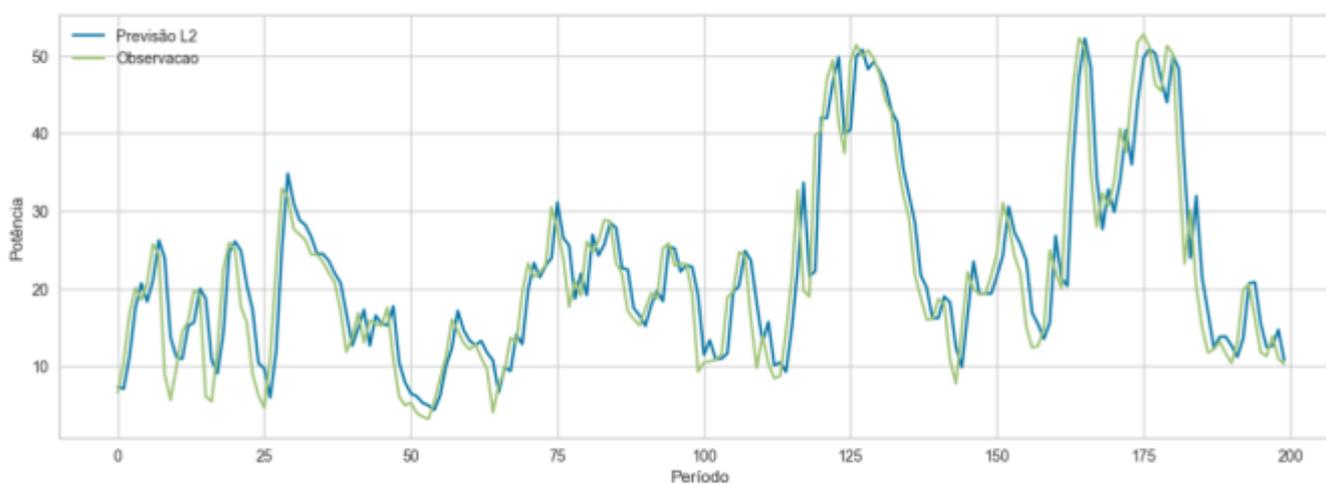
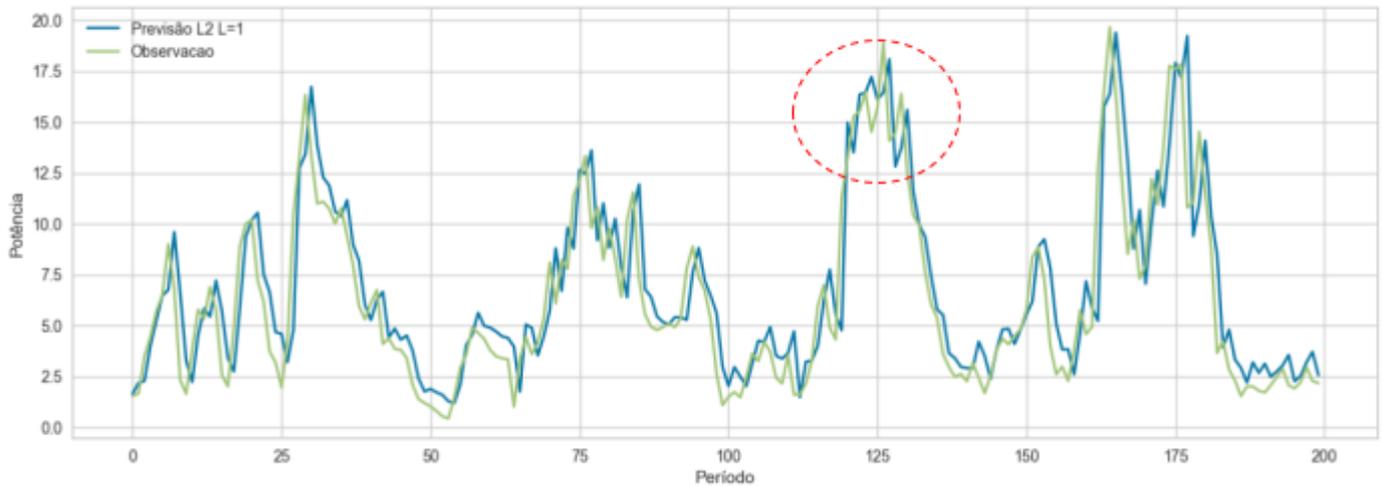
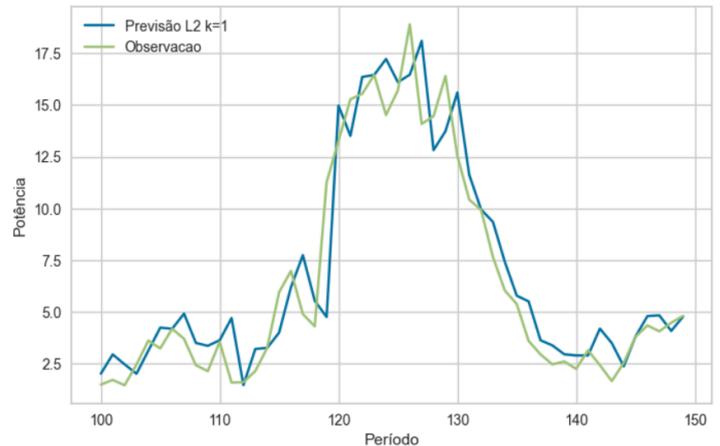
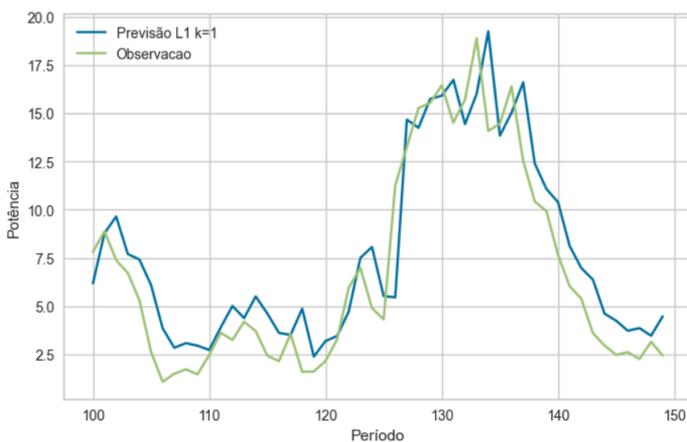


Figura 42 - Previsão de Potência Modelo L2 K=1 Cluster 2



Avaliando os gráficos, é possível observar alguns comportamentos das previsões e das interferências das variáveis regressoras nos modelos. Por exemplo, destacando a previsão para o cluster 2, para L1 e L2. No trecho destacado da Figura 42, é possível observar que enquanto L1 consegue reproduzir a curva da observação, o modelo L2 reproduz um comportamento diferente, conforme é verificado nas Figuras 43 (a e b).

Figuras 43 (a) e 43 (b) - Destaque de trecho previsão de L1 e L2 (respectivamente)



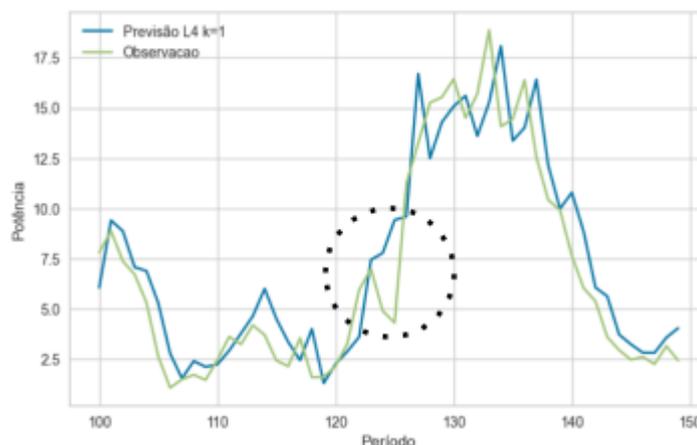
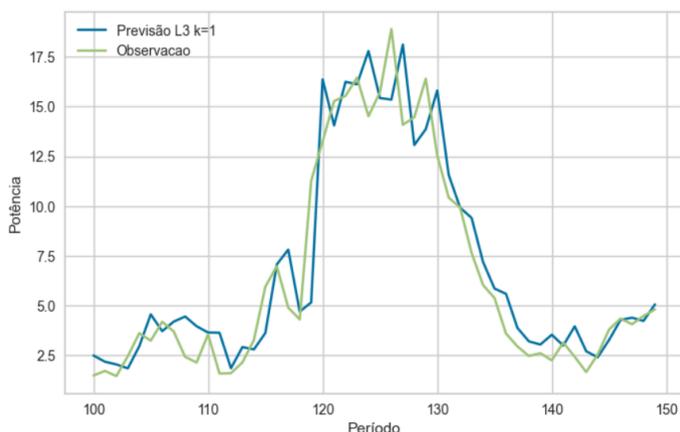
Fonte: Própria autora

- Modelos L3 e L4

As Figuras 44 (a e b), mostram o mesmo trecho apresentado anteriormente, agora apresentando os resultados para os modelos L3 e L4. Como é possível observar, o modelo L4

foi o único que não conseguiu reproduzir a rampa de descida/subida destacada na figura. Assim como L2 e L3, o modelo L4 também faz uso dos dados da central a barlavento, no entanto, atribui um peso para as variáveis regressoras de acordo com a distância no tempo, sendo assim, esse fator pode ter afetado a previsão nesse trecho específico. Apesar desse comportamento que difere dos demais, o modelo L4 foi o que obteve os melhores resultados de correlação.

Figuras 44 (a) e 44 (b) - Destaque de trecho previsão de L3 e L4 (respectivamente)



Fonte: Própria autora

Na Tabela 8 estão dispostas as correlações por cluster/modelo/horizonte de previsão. O cluster 2 obteve melhores valores de correlação quando comparados ao cluster 1, e ao avançar o horizonte de previsão, essa diferença se intensifica.

Tabela 8 - Correlação modelos locais por cluster  
(C1=Cluster 1, C2=Cluster 2)

Horizonte	CORRELAÇÃO			
	L1 C1	L2 C1	L3 C1	L4 C1
k=1	0,92	0,92	0,92	0,93
k=2	0,83	0,83	0,83	0,84
k=3	0,75	0,75	0,75	0,76
k=4	0,68	0,69	0,68	0,69
k=5	0,61	0,62	0,62	0,63
k=6	0,56	0,58	0,56	0,57
	L1 C2	L2 C2	L3 C2	L4 C2
k=1	0,94	0,94	0,94	0,94

k=2	0,87	0,87	0,87	0,87
k=3	0,81	0,81	0,81	0,81
k=4	0,75	0,75	0,74	0,76
k=5	0,69	0,70	0,69	0,70
k=6	0,64	0,65	0,64	0,66

Tabela 9 - NRMSE modelos locais por cluster  
(C1=Cluster 2, C2=Cluster 2)

NRMSE				
Horizonte	L1 C1	L2 C1	L3 C1	L4 C1
k=1	0,18	0,19	0,19	0,18
k=2	0,26	0,27	0,27	0,26
k=3	0,32	0,32	0,32	0,31
k=4	0,35	0,35	0,35	0,35
k=5	0,38	0,38	0,38	0,38
k=6	0,40	0,40	0,40	0,40
NRMSE				
Horizonte	L1 C2	L2 C2	L3 C2	L4 C2
k=1	0,24	0,24	0,24	0,24
k=2	0,35	0,35	0,35	0,35
k=3	0,42	0,42	0,41	0,41
k=4	0,47	0,46	0,47	0,46
k=5	0,52	0,50	0,51	0,50
k=6	0,55	0,54	0,54	0,53

Após a avaliação das previsões dos modelos locais por clusters, será avaliada a previsão resultado da combinação destes com a previsão do WRF. As tabelas 10, 11 e 12, trazem respectivamente a correlação e o NRMSE referentes à previsão feita no cluster 1, cluster 2 e na junção das previsões para a central.

Tabela 10 - Correlação modelos locais por cluster + WRF  
(C1=Cluster 2, C2=Cluster 2)

CORRELAÇÃO - CLUSTER 1				
Horizonte	L1-WRF	L2-WRF	L3-WRF	L4-WRF
k=1	0,92	0,92	0,92	0,93

k=2	0,85	0,85	0,85	0,85
k=3	0,78	0,79	0,78	0,79
k=4	0,73	0,74	0,73	0,73
k=5	0,68	0,69	0,68	0,68
k=6	0,65	0,65	0,65	0,64
CORRELAÇÃO - CLUSTER 2				
Horizonte	L1-WRF	L2-WRF	L3-WRF	L4-WRF
k=1	0,93	0,93	0,93	0,93
k=2	0,86	0,86	0,86	0,86
k=3	0,80	0,80	0,80	0,81
k=4	0,74	0,75	0,72	0,75
k=5	0,69	0,70	0,69	0,71
k=6	0,65	0,66	0,66	0,66

Tabela 11 - NRMSE modelos locais por cluster + WRF  
(C1=Cluster 2, C2=Cluster 2)

NRMSE - CLUSTER 1				
Horizonte	L1-WRF	L2-WRF	L3-WRF	L4-WRF
k=1	0,17	0,17	0,17	0,17
k=2	0,25	0,23	0,23	0,23
k=3	0,28	0,27	0,28	0,29
k=4	0,30	0,31	0,31	0,31
k=5	0,33	0,33	0,32	0,33
k=6	0,35	0,34	0,35	0,34
NRMSE - CLUSTER 2				
Horizonte	L1-WRF	L2-WRF	L3-WRF	L4-WRF
k=1	0,23	0,21	0,21	0,21
k=2	0,29	0,29	0,30	0,32
k=3	0,35	0,35	0,35	0,36
k=4	0,39	0,38	0,41	0,40
k=5	0,44	0,41	0,42	0,44
k=6	0,46	0,44	0,45	0,43

Assim como a correlação, o NRMSE também apresentou melhoras após a introdução do WRF, se destacando em todos os horizontes de previsão para ambos os clusters avaliados, quando compara-se a Tabela 9 e a Tabela 11.

Nas Figuras 45 e 46, está disposto o comportamento para k=1 em um período específico da série. Conforme é possível observar, após a inclusão do WRF, houve uma melhora na correlação para horizontes de previsão mais distantes. Por exemplo, a correlação

para o modelo G1 (que melhor desempenhou entre os globais) em  $k=4,5, 6$  foi de 0,73, 0,67 e 0,62, respectivamente. Para o modelo L4 no mesmo cenário, os valores foram de 0,74, 0,68 e 0,63, em contrapartida, para o modelo L2-WRF-C os valores foram 0,76, 0,71 e 0,67. Para os horizontes de previsão  $k=1,2$  e 3 também houveram ganhos na correlação, com resultados empatados para  $k=1$  e 2, e melhorias a partir de  $k=3$ .

Tabela 12 - Correlação combinação modelos locais + WRF (L-WRF-C)

CENTRAL - JUNÇÃO DAS PREVISÕES				
Horizonte	L1-WRF-C	L2-WRF-C	L3-WRF-C	L4-WRF-C
k=1	0,94	0,94	0,94	0,94
k=2	0,87	0,87	0,87	0,87
k=3	0,80	0,81	0,80	0,81
k=4	0,75	0,76	0,75	0,75
k=5	0,71	0,71	0,70	0,71
k=6	0,67	0,67	0,67	0,67

Figura 45 - Previsão do modelo L1 - WRF-C

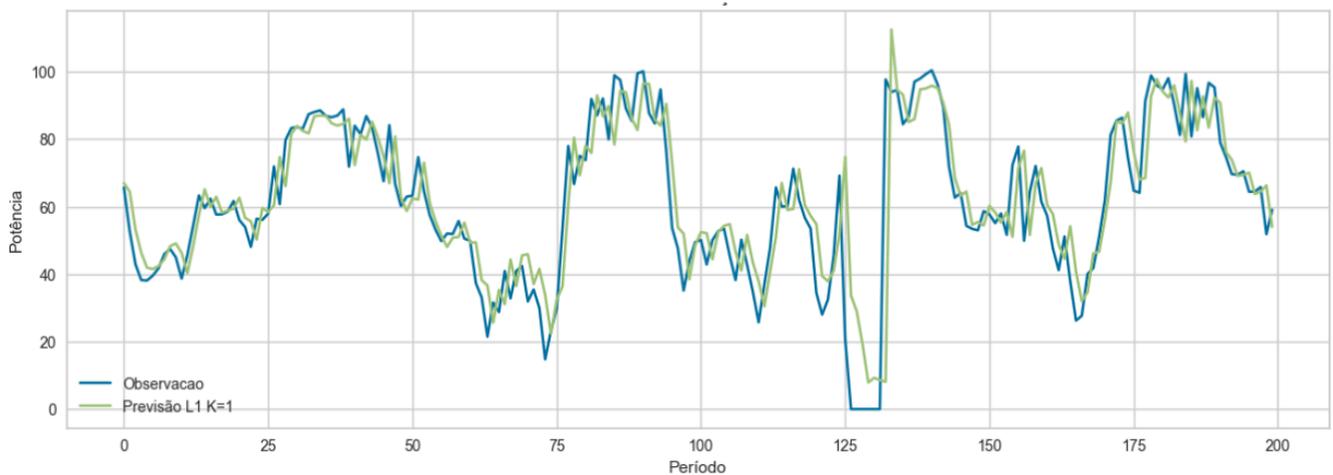
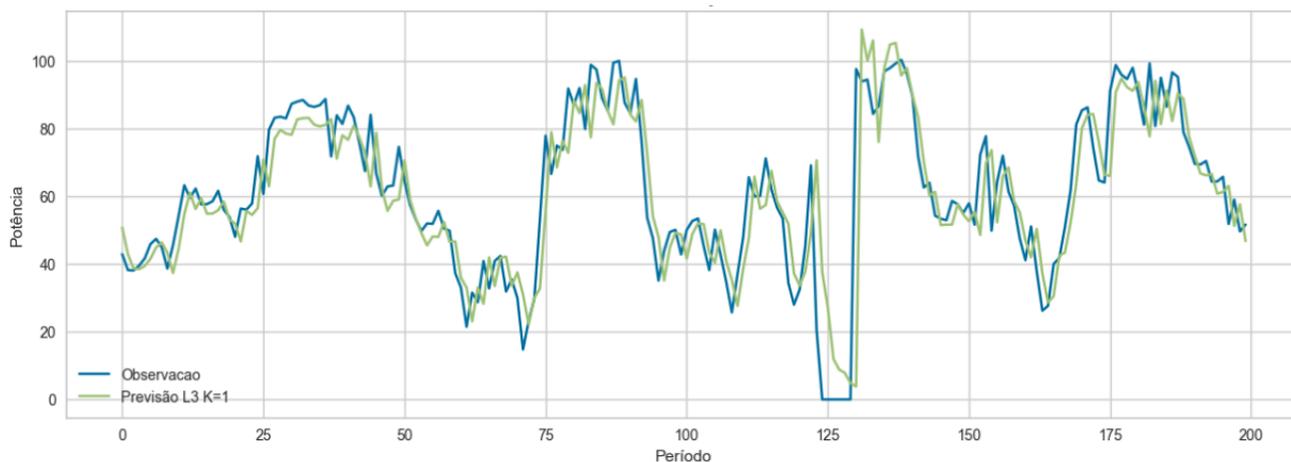


Figura 46 - Previsão do modelo L3 - WRF-C



Nos gráficos é possível observar um comportamento coerente por parte dos modelos, nas Tabelas 13 e 14 é apresentado o comparativo do NRMSE e das features, assim como realizado para os modelos globais. Os valores de NRMSE aumentam a cada horizonte de previsão, à medida que a qualidade da previsão cai, inverso do observado na correlação.

Tabela 13 - NRMSE modelos locais-WRF-C

NRMSE				
Horizonte	L1-WRF-C	L2-WRF-C	L3-WRF-C	L4-WRF-C
k=1	0,17	0,17	0,17	0,16
k=2	0,25	0,24	0,24	0,24
k=3	0,29	0,28	0,29	0,30
k=4	0,32	0,32	0,33	0,33
k=5	0,35	0,34	0,34	0,35
k=6	0,38	0,36	0,37	0,36

Tabela 14 - Features comparativas Modelos Locais-WRF-C k=1

Modelos	RMS	Pico a pico	Curtose	Assimetria	Mediana
Observação	61,71	100	-1,07	-0,12	56
L1-WRF-C	61,55	112,45	-1,02	-0,15	56,70
L2-WRF-C	59,44	109,51	-1,06	-0,10	54,08
L3-WRF-C	59,72	109,32	-1,05	-0,11	54,21
L4-WRF-C	58,90	102,23	-1,03	-0,15	54

## 5.4.2 Previsão de rampas

Os modelos locais são focados em previsão de rampas, e toda calibração do modelo é feita visando o melhor desempenho no que diz respeito à rampa. Tendo isso em vista, para esses modelos, é necessário adicionar um outro tipo de avaliação, voltada especificamente para a qualidade de previsão dessas variações na potência. Dessa forma, foi feita uma análise isolando apenas as regiões de rampa (subida e descida) e foram analisados os resultados das previsões para essas regiões utilizando os modelos locais-WRF-C .

Nas tabelas 15, 16, 17 e 18 estão os comparativos entre rampa de subida e descida, por modelo. Os modelos performaram de forma similar, com alguns se destacando em diferentes momentos. No entanto, é possível observar que em todos há diminuição significativa na correlação e aumento no erro ao passar os horizontes de previsão. O modelo L4 obteve resultados ligeiramente melhores nos primeiros horizontes de previsão, mas em seguida teve uma queda na correlação e aumento no erro.

Tabela 15 - Correlação e NRMSE L1-WRF-C

L1-WRF-C				
	Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE
k=1	0,90	0,19	0,82	0,09
k=2	0,79	0,34	0,66	0,15
k=3	0,67	0,34	0,53	0,23
k=4	0,63	0,37	0,47	0,24
k=5	0,58	0,37	0,44	0,26
k=6	0,53	0,39	0,46	0,32

Nas

Figuras 47 e 48 são exibidos os gráficos da previsão e observação referente ao modelo L1-WRF-C para k=1 para as rampas de descida e subida. Como é possível observar, o comportamento da previsão acompanha o comportamento da observação, no entanto, há erros atrelados à amplitude do valor previsto.

Figura 47 - Previsão Rampas de descida

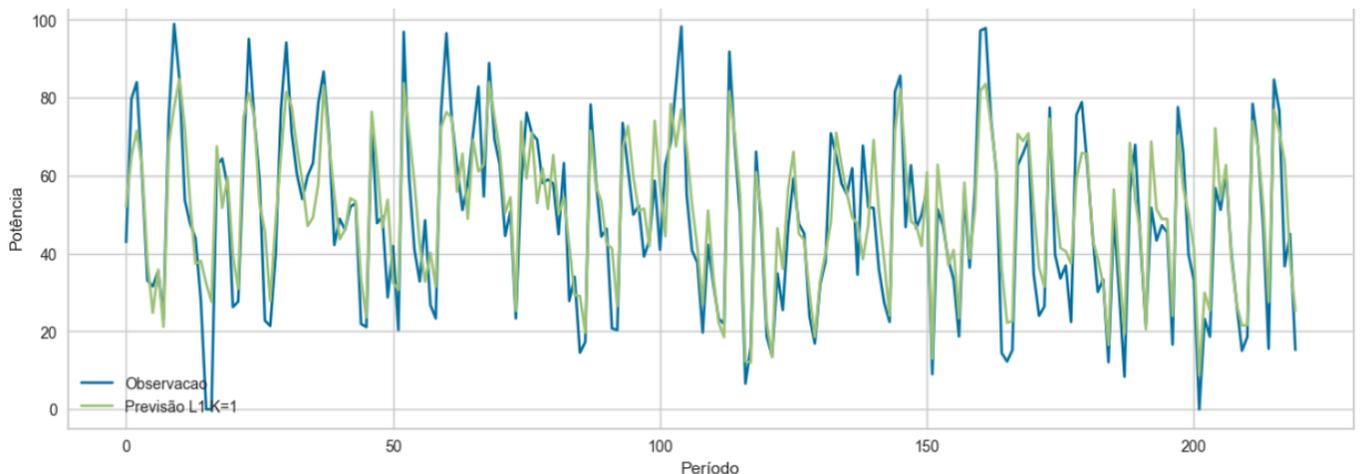
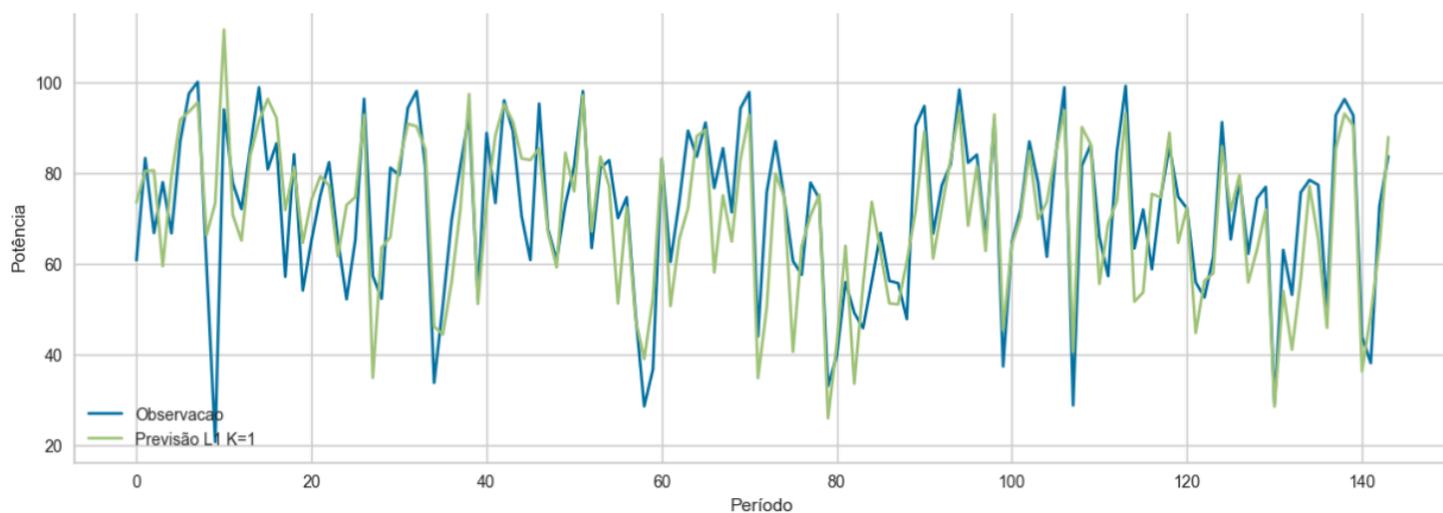


Figura 48 - Previsão rampas de subida



Fonte: Própria autora

Tabela 16 - Correlação e NRMSE L2-WRF-C

L2-WRF-C				
	Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE
k=1	0,89	0,19	0,82	0,10
k=2	0,79	0,31	0,66	0,16
k=3	0,69	0,34	0,54	0,17
k=4	0,65	0,37	0,48	0,21
k=5	0,59	0,35	0,47	0,27
k=6	0,54	0,41	0,48	0,28

Tabela 17 - Correlação e NRMSE L3-WRF-C

L3-WRF-C				
	Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE
k=1	0,89	0,19	0,82	0,11
k=2	0,78	0,29	0,67	0,17
k=3	0,68	0,33	0,53	0,19
k=4	0,63	0,34	0,48	0,29
k=5	0,58	0,35	0,46	0,27
k=6	0,52	0,38	0,48	0,27

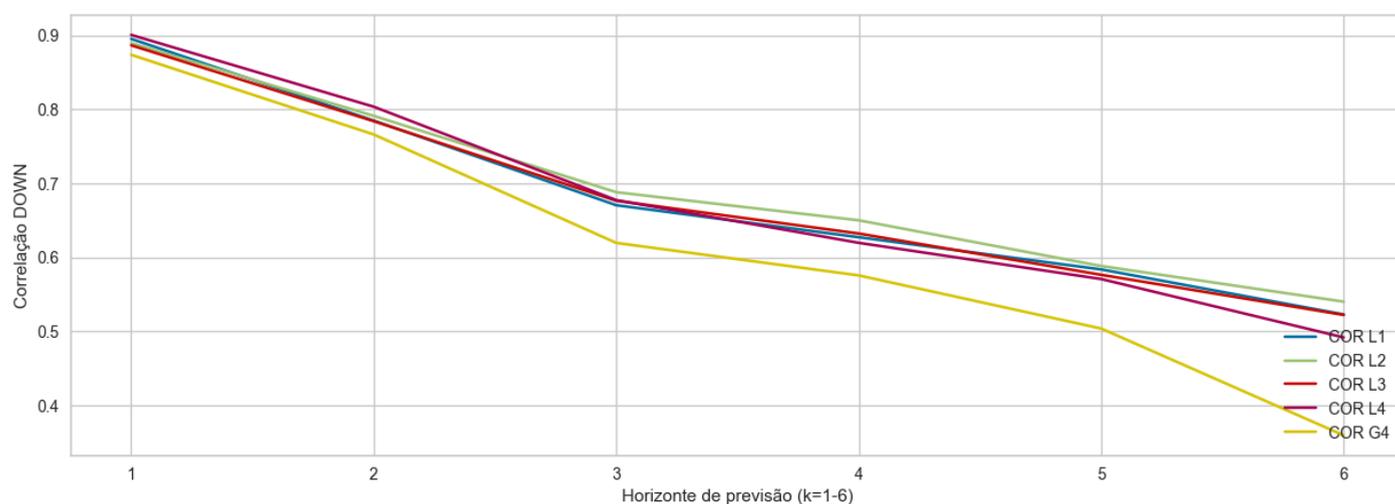
Tabela 18 - Correlação e NRMSE L4-WRF-C

L4-WRF-C				
	Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE
k=1	0,90	0,18	0,84	0,09
k=2	0,80	0,32	0,69	0,14
k=3	0,68	0,33	0,56	0,21
k=4	0,62	0,36	0,51	0,22
k=5	0,57	0,36	0,49	0,24
k=6	0,50	0,34	0,50	0,27

O erro maior está atrelado à previsão de rampas de descida em horizontes de previsão mais distantes, no entanto, a reação dos modelos é bem similar ao longo do tempo, com o erro variando de forma crescente.

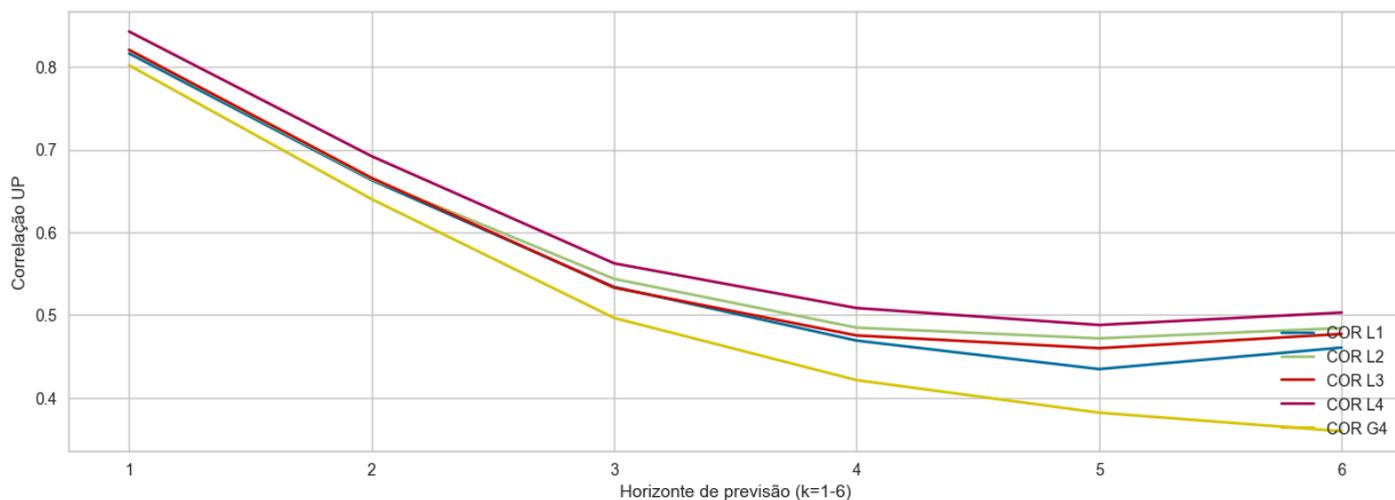
A avaliação de previsão de rampas também foi realizada para os modelos globais, para compreender qual o comportamento apresentado por eles nestes eventos. O modelo G4 foi o que melhor performou quando levado em consideração a correlação e NRMSE avaliando os regimes de subida e descida. Nas Figuras 49 e 50 é possível observar a comparação dos modelos locais-WRF-C com o modelo G4.

Figura 49 - Correlação rampas de descida com modelo G4



Fonte: Própria autora

Figura 50 - Correlação rampas de subida com modelo G4



Fonte: Própria autora

Tabela 19 - Correlação e NRMSE G4

G4				
	Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE
k=1	0,87	0,23	0,80	0,15
k=2	0,77	0,31	0,64	0,21
k=3	0,62	0,38	0,50	0,25
k=4	0,57	0,40	0,42	0,27
k=5	0,50	0,44	0,38	0,27
k=6	0,36	0,48	0,36	0,29

Conforme é possível observar, os modelos locais-WRF-C performaram melhor em quase todos os cenários no que diz respeito à previsão de rampas quando comparado ao modelo G4, com destaque para a previsão de rampas de descida. A correlação do modelo L4-WRF-C para as rampas de descida varia de 0,9 a 0,5, enquanto que no modelo G4 essa variação é de 0,87 a 0,36.

Adicionalmente aos comparativos, também é possível verificar o efeito da clusterização no que diz respeito à previsão de rampas. Sendo assim, pode-se avaliar nas Tabelas 20 e 21 o comportamento dos modelos locais, e dos modelos locais-WRF (sem a clusterização), no que diz respeito às previsões de rampa de subida e descida.

Tabela 20 - Correlação e NRMSE para rampas de subida e descida para modelos locais

	L1	L2

	Rampa de descida		Rampa de subida		Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE
k=1	0,89	0,23	0,82	0,16	0,88	0,23	0,81	0,16
k=2	0,76	0,33	0,65	0,24	0,76	0,34	0,65	0,24
k=3	0,55	0,42	0,50	0,27	0,64	0,41	0,52	0,27
k=4	0,47	0,46	0,41	0,30	0,59	0,44	0,45	0,30
k=5	0,38	0,48	0,38	0,32	0,49	0,46	0,43	0,32
k=6	0,25	0,51	0,35	0,34	0,36	0,48	0,40	0,34
	L3				L4			
	Rampa de descida		Rampa de subida		Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE
k=1	0,89	0,23	0,82	0,16	0,89	0,23	0,83	0,16
k=2	0,76	0,34	0,65	0,23	0,76	0,33	0,67	0,23
k=3	0,64	0,40	0,50	0,27	0,61	0,40	0,52	0,27
k=4	0,58	0,44	0,42	0,30	0,54	0,43	0,45	0,30
k=5	0,46	0,46	0,40	0,33	0,43	0,46	0,42	0,32
k=6	0,30	0,48	0,38	0,34	0,28	0,48	0,39	0,34

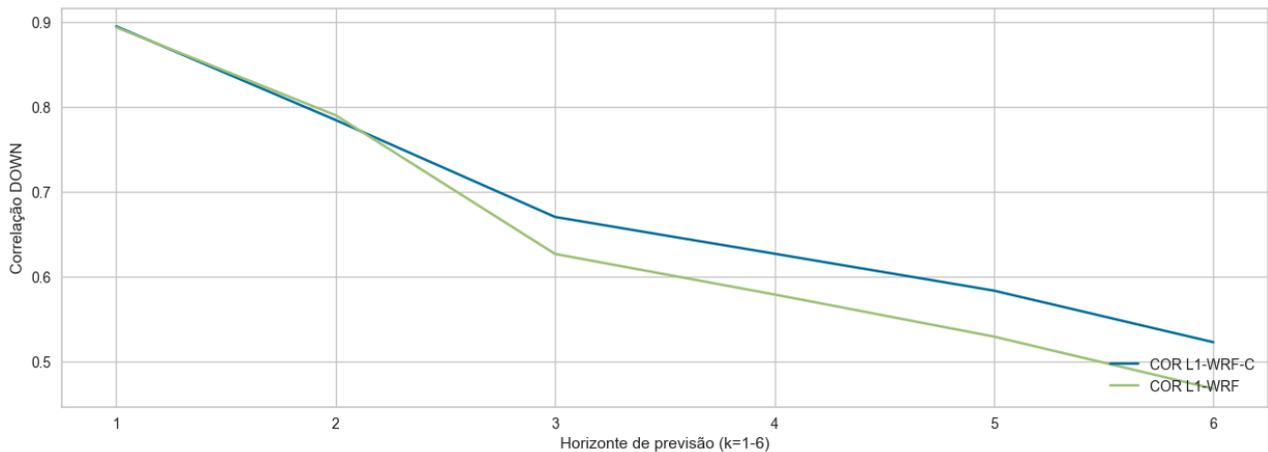
Tabela 21 - Correlação e NRMSE para rampas de subida e descida para modelos locais com WRF (sem clusterização)

	L1-WRF				L2-WRF			
	Rampa de descida		Rampa de subida		Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE
k=1	0,89	0,19	0,82	0,09	0,89	0,20	0,81	0,09
k=2	0,79	0,33	0,66	0,14	0,78	0,30	0,66	0,16
k=3	0,63	0,34	0,54	0,21	0,69	0,33	0,55	0,16
k=4	0,57	0,36	0,47	0,22	0,66	0,40	0,50	0,23
k=5	0,53	0,37	0,45	0,25	0,61	0,35	0,49	0,26
k=6	0,45	0,37	0,46	0,29	0,54	0,39	0,49	0,27
	L3-WRF				L4-WRF			
	Rampa de descida		Rampa de subida		Rampa de descida		Rampa de subida	
Horizonte	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE	Correlação	NRMSE
k=1	0,89	0,19	0,82	0,10	0,89	0,20	0,83	0,09
k=2	0,78	0,29	0,66	0,16	0,78	0,34	0,68	0,14
k=3	0,69	0,34	0,54	0,19	0,67	0,35	0,56	0,22

k=4	0,64	0,35	0,48	0,29	0,63	0,39	0,50	0,23
k=5	0,56	0,35	0,46	0,27	0,57	0,38	0,47	0,25
k=6	0,50	0,39	0,47	0,27	0,48	0,38	0,48	0,29

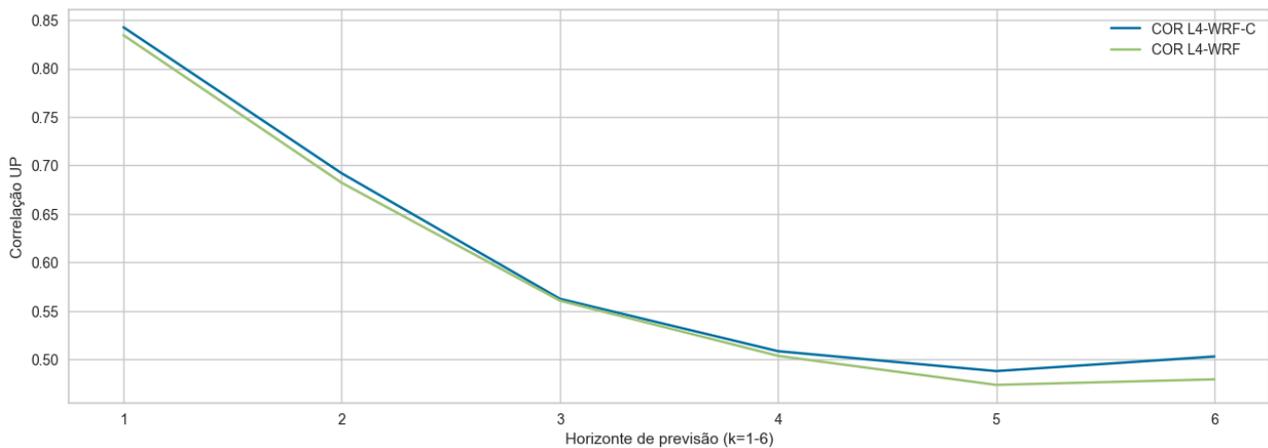
Como é possível observar, os modelos locais-WRF têm melhor desempenho que os modelos locais, especialmente em horizontes de previsão superiores. Com relação à clusterização, foi plotado o gráfico nas Figuras 51 e 52 para melhor visualização do comparativo entre os modelos locais-WRF com e sem clusterização.

Figura 51 - Correlação L1-WRF-C em comparativo com L1-WRF (rampa descida)



Fonte: Própria autora

Figura 52 - Correlação L4-WRF-C em comparativo com L4-WRF (rampa subida)



Fonte: Própria autora

### 5.4.3 Avaliação de resultados

Após a obtenção de todos os resultados, é possível realizar uma avaliação mais específica voltada apenas para previsão de rampas. Conforme detalhado na metodologia, segue abaixo as siglas a serem utilizadas:

- Falso positivo (FP): Uma rampa foi prevista, mas não foi observada;
- Falso negativo (FN): Uma rampa foi observada, mas não foi prevista;
- Verdadeiro positivo (VP): Uma rampa foi prevista e observada.
- Acurácia da previsão (FA);
- Captura de rampa (RC);
- Índice de Bias (Bs);
- Índice de sucesso crítico (Csi);
- Taxa de alarme falso (FAR);
- Acurácias da previsão de rampas de subida e de descida (RUP, RD).

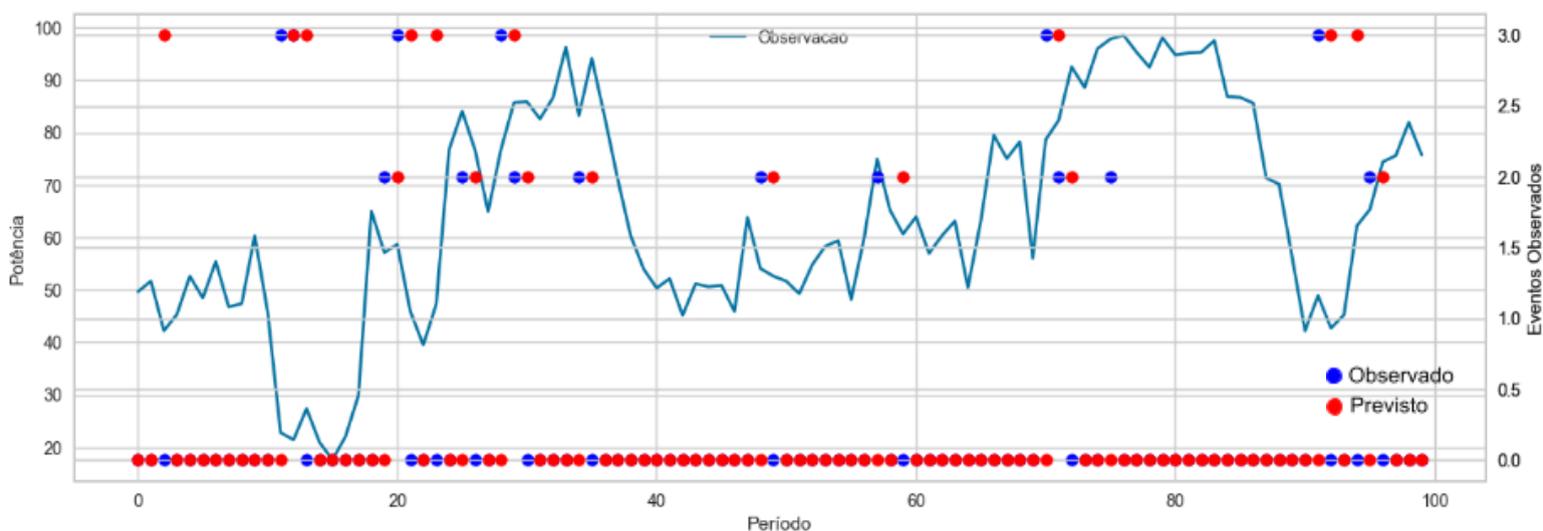
Ao avaliar os valores calculados para FP, FN e VP, foram plotados alguns gráficos, de diferentes momentos para observar as sinalizações de rampa, e foi possível verificar que boa parte dos valores indicados como falso positivo são delays da previsão, ou seja, o modelo indicou que haveria rampa, no entanto, com um ou dois time-steps de atraso.

Tabela 22 - Avaliação de resultados modelos L-WRF-C

	L1-WRF-C	L2-WRF-C	L3-WRF-C	L4-WRF-C
FP	203	246	157	179
FN	201	196	210	208
VP	70	78	64	66

Na Figura 53 é destacado um trecho da série de observação com as sinalizações de rampa de subida ( $y_2=2$ ) e rampas de descida ( $y_2=3$ ), em azul são os eventos observados e em vermelho são os eventos previstos.

Figura 53 - Eventos de rampa previstos e observados



Fonte: Própria autora

Tabela 23 - Índices de previsão

Índices	L1-WRF-C	L2-WRF-C	L3-WRF-C	L4-WRF-C
FA	0,26	0,26	0,29	0,27
RC	0,25	0,25	0,23	0,24
Bs	0,97	0,97	0,81	0,89
Csi	0,15	0,15	0,15	0,14
FAR	0,74	0,74	0,71	0,73
RUP	0,17	0,20	0,18	0,20
RD	0,16	0,19	0,14	0,15

Dos modelos apresentados, o modelo L2-WRF-C obteve melhores resultados na avaliação quando observado a quantidade de verdadeiros positivos, ou seja, de previsões assertivas. Quando avalia-se a Tabela 23, os modelos desempenharam de forma bem semelhante, mas novamente o modelo L2-WRF-C obteve melhores resultados quando observada individualmente a previsão de rampas de subida e descida.

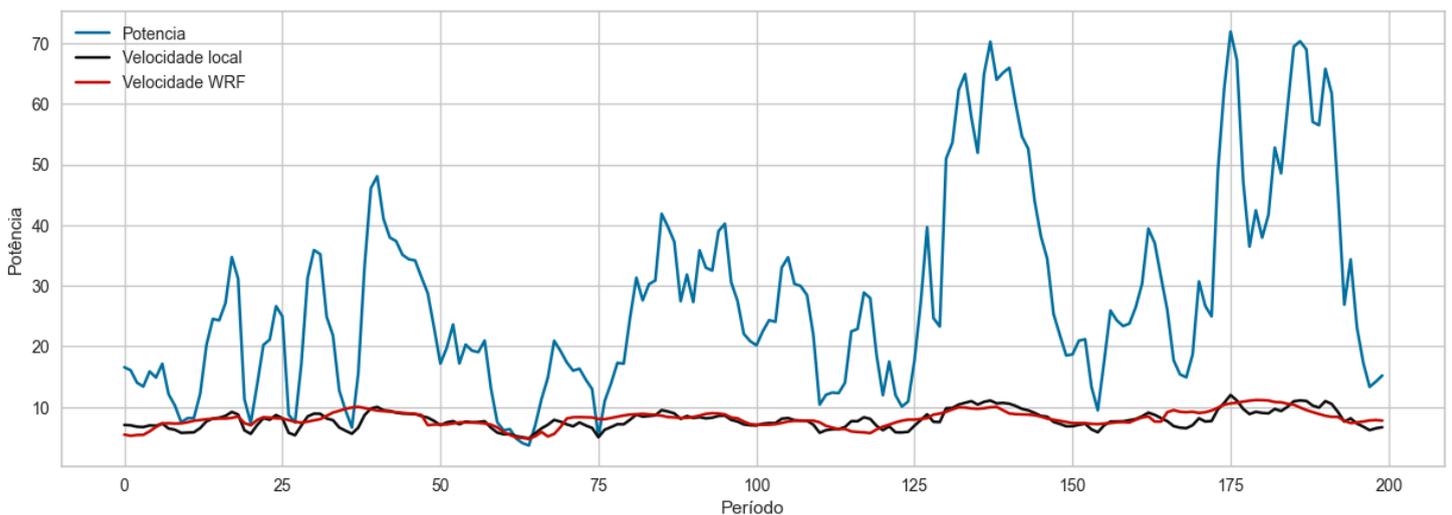
## 5.5 Eventos de rampa e possíveis causas

Com as previsões realizadas, é possível também se aprofundar nos dados trabalhados investigando possíveis causas para os eventos de rampa. Por exemplo, ao traçar a correlação entre a velocidade da central e a série de potência, e a velocidade do WRF e a série de potência, é possível concluir sobre qual variável influenciará mais a potência e qual terá maior contribuição nos eventos de rampa. Para ambos, o resultado foi semelhante, a

velocidade medida da central tem maior correlação com a potência mesmo em eventos de rampa de subida ou descida.

Apesar do WRF não contribuir notavelmente no aumento da correlação para horizontes de previsão recentes, ficou evidente a contribuição deste para horizontes de previsão mais distantes. Ao observar o gráfico na Figura 54, é possível verificar que a velocidade do vento do WRF apresenta menos perturbações no curtíssimo prazo, e em diferentes momentos acompanha as rampas, no entanto, de forma mais lenta. Pode-se concluir que algumas rampas são ocasionadas devido a eventos da grande escala, no entanto, há outras variações na microescala que causam impacto na potência. A correlação entre a velocidade do vento local e a potência é de 92% (para a série como um todo), de 93% para eventos de rampa de subida e de 94% para eventos de rampa de descida. Em comparativo, a correlação entre a potência medida e a velocidade do WRF é de 54%. Sendo assim, a maior parte dos eventos de rampa de potência no curto prazo são consequência das mudanças de velocidade na escala local.

Figura 54 - Potência e velocidade local/WRF



Fonte: Própria autora

## 5.6. Outras metodologias (levar pro referencial - adicionar parâmetros de resultados utilizados)

Na Figura 24 é feito um compilado comparativo dos trabalhos que constam na revisão de literatura, levando em consideração os tipos de previsão realizados, modelos e algumas características dos dados utilizados, como *time-step*, horizonte de previsão e as variáveis de entrada consideradas.

Tabela 24 - Revisão de Literatura

Demais autores					
Autor	Ajustes	Modelos	T. Step	horizonte	Variáveis
Li et al., 2016*	Global e Local	WRF+MLP	1 h	24 h	Velocidade e direção do vento, pressão e temperatura
Clemente, 2018	Global e local	MLP	10 min	30 min	velocidade
Doan et al., 2018	Local	WRF	30 min	24 h	velocidade
Okada et al., 2018	Local	WRF	30 min	48 h	velocidade, pressão
ONS, 2018	Global	GFS, ECMWF	30 min	24 h	velocidade
Ouyang et al., 2019	Global	MSAR (Markov-Switching -Auto-Regression)	15 min	10 h	velocidade e potência
Li et al., 2020	Local	<i>Typical event clustering identification (TECI)</i>	15 min	2 h	velocidade
Groch et al., 2021**	Global	WRF-ANN	10 min	24 h	velocidade
Zhou et al., 2021	Global	GAN	15 min	6 h	potência
Zucattelli et al., 2021	Global	RNN + WPD	1 h	6 h	velocidade
Diallo et al., 2024	Global	WRF	10 min	6 h	velocidade
Souza, 2025***	Global e local	MLP, MLP+WRF	30 min	3 h	potência, velocidade e velocidade barlavento

## 6 CONCLUSÕES

Foram apresentados diferentes métodos de previsão, com vistas a realizar a comparação com o método escolhido como sendo o foco deste trabalho. Dentre os métodos apresentados estão o da persistência, os modelos de previsão global, e os modelos de previsão local combinados com o WRF. Inicialmente foi avaliada a correlação e erro médio quadrático normalizado de todos os modelos, comparando estes valores com a análise visual dos dados. Para o modelo da persistência, tal como esperado, foi observado que o modelo desempenha bem para curtos horizontes de previsão, no entanto, à medida que aumenta-se o horizonte há

um diminuição na correlação e um aumento no erro. Os modelos globais se comportaram de forma semelhante entre si, a correlação dos modelos globais obteve resultados acima de 0,7 até  $k=4$  (2 horas a frente), superior ao obtido pelo modelo da persistência. Também foram traçados o NRMSE que se mostrou superior ao obtido para o modelo de referência (persistência). Tendo em vista a similaridade dos valores obtidos de correlação e erro entre os modelos avaliados, foram calculadas algumas features para verificar como a previsão se comportaria em relação à observação quando avaliadas essas características (RMS, pico a pico, curtose, assimetria e mediana). De maneira geral, os resultados foram similares, com uma ligeira superioridade para o modelo G2, que obteve features mais próximas à observação, com destaque para o valor do pico a pico.

Os agrupamentos formados na clusterização dos dados de potência da central reproduziram de forma assertiva o comportamento espacial da central, separando-a em dois clusters com 4 e 5 aerogeradores. Após a clusterização foi possível realizar a previsão fazendo uso dos modelos locais juntamente com a previsão do WRF. No entanto, antes da combinação, os resultados de previsão por cluster foram apresentados separadamente, com o cluster com menor quantidade de aerogeradores obtendo melhor resultado. Ao avaliar os dados, foi possível concluir que essa diferença está diretamente relacionada com a quantidade de dados por cluster e como é feita a separação de dados por agrupamento. No momento da formação dos clusters, a potência dos aerogeradores é somada a cada intervalo de tempo, e as máquinas com dados faltantes são desconsideradas apenas naquele time-step, no entanto as demais são somadas formando o valor de potência daquele intervalo. Sendo assim, clusters com menos aerogeradores têm menos impacto de dados incompletos e por sua vez, uma propagação de erro menor no momento da previsão. O modelo final leva em consideração a combinação entre a previsão realizada com os modelos locais clusterizados e o WRF, ao avaliar os resultados, foi possível verificar que houve uma melhora nas previsões clusterizadas quando combinadas com o WRF, principalmente para maiores horizontes de previsão, quando compara-se com o modelo de persistência ou os modelos globais.

A avaliação feita acima é focada nos resultados obtidos para a previsão de potência, no entanto, o foco principal do trabalho é a previsão de rampas. Os modelos locais são treinados para estes eventos, sendo assim, foi feita uma avaliação dos modelos nesses cenários específicos. Para tal foi observado que as previsões de rampa de descida obtiveram melhor correlação quando comparada às rampas de subida, no entanto, um erro médio superior em todos os horizontes de previsão.

A critério de comparação, foi avaliado como os modelos globais se comportavam em eventos de rampa. Entre os modelos globais, aquele que mais se destacou na previsão por regime foi o modelo G4. Ao compará-lo com os modelos locais foi possível verificar que apesar de apresentar resultados de erro com valores próximos, obteve valores de correlação bem abaixo do observado nos modelos locais, especialmente para horizontes de previsão mais distantes. Adicionalmente, foi feita uma análise dos resultados obtidos com os modelos locais e locais-WRF (sem clusterização) quanto à previsão de rampas de subida e descida. Nesta análise foi possível verificar quantitativamente a contribuição da clusterização e do WRF (individualmente e em conjunto) no modelo final proposto. Verificando, por exemplo, o modelo L2-WRF para as rampas de descida, a correlação variou de 0,89 a 0,54, enquanto que para o modelo L2 essa variação foi de 0,88 a 0,36. Também é possível observar que apesar do

WRF contribuir na melhora da previsão nos regimes de rampa de subida e descida, essa contribuição é mais significativa para as rampas de descida. Ao avaliar o efeito da clusterização, esta foi mais notável nos modelos locais 1 e 4, pode-se comparar os resultados obtidos para o LI-WRF-C e L4-WRF-C com o L1-WRF e L4-WRF, onde houve uma melhora na correlação, com maior impacto para rampas de descida.

Na avaliação de resultados, foram verificadas diversas métricas voltadas para a detecção de rampas. Ao avaliar os valores, e verificar os gráficos, foi possível concluir que em diversos momentos a detecção de rampa sofre um delay, ocasionando um grande número de falsos positivos. No que se refere às rampas de subida e descida, o modelo mostrou capturar melhor rampas de subida.

Dentre os modelos globais e locais utilizados, apenas um de cada grupo não faz uso dos dados da central à barlavento, o modelo G1 e o modelo L1. Ao avaliarmos os modelos locais e globais (sem WRF, sem cluster e sem separação de regime) os valores obtidos para correlação e erro são bem similares para modelos que consideram a central a barlavento e os que não consideram, com uma ligeira melhora na correlação para os modelos locais que fazem uso dos dados dessa segunda central (L2, L3 e L4). No entanto, ao avaliar os modelos que consideram o WRF, clusterização e os diferentes regimes, há uma mudança no cenário observado, o modelo L1-WRF-C parece desempenhar melhor na previsão de rampas de subida, enquanto que os demais modelos (que fazem uso da central a barlavento) parecem desempenhar melhor para previsão de rampas de descida.

Ao finalizar a avaliação de todos os modelos, é notável o desempenho dos modelos locais em junção com o WRF, quando comparados ao modelo de persistência e aos modelos globais. Foi possível verificar que com os dados de mesoescala houve uma melhora significativa na previsão de rampas, com destaque para horizontes de previsão mais distantes, superiores a  $k=3$  (90 minutos a frente) e com a junção da clusterização da central que também contribuiu na melhora dos resultados. Analisando em termos quantitativos essas contribuições, ao comparar-se o modelo L2-WRF-C com o L2 para previsão de rampas de descida 3 horas à frente, a correlação aumentou em 50% e o erro diminuiu em 15%. Para as rampas de subida, a correlação subiu em 20% e o erro diminuiu em 18%.

## **7 PERSPECTIVAS FUTURAS**

- Investigar de forma mais aprofundada os modelos mesoescalares;
- Avaliar a previsão de velocidade do vento;
- Correlacionar as rampas de potência com as rampas de velocidade do vento para detecção de falha;
- Utilização de dados mesoescalares para avaliação de sites offshore

## 8 REFERÊNCIAS

- ABBEólica (2022). InfoVento Setembro. 2022. Disponível em: <https://abeeolica.org.br/energia-eolica/dados-abeeolica/>;
- Anderson, B. (2019). Pattern Recognition: An introduction. Scientific e-Resources.
- Aylas, Y. G. R., de Souza Campos Correa, W., Santiago, A. M., Reis Junior, N. C., Albuquerque, T. T. D. A., Santos, J. M., & Moreira, D. M. (2020). Influence of land use on the performance of the WRF model in a humid tropical climate. *Theoretical and Applied Climatology*, 141, 201-214.
- Bernardet, L., Wolff, J., Nance, L., Loughe, A., Weatherhead, B., Gilleland, E., & Brown, B. (2009, June). Comparison between WRF-ARW and WRF-NMM objective forecast verification scores. In *Proceedings of the 23rd Conference on Weather Analysis and Forecasting/19th Conference on Numerical Weather Prediction*, Denver, CO, USA (pp. 1-5).
- Bilendo, F., Meyer, A., Badihi, H., Lu, N., Cambron, P., & Jiang, B. (2022). Applications and modeling techniques of wind turbine power curve for wind farms—A review. *Energies*, 16(1), 180.Soh
- Cheneka, B. R., Watson, S. J., & Basu, S. (2020). A simple methodology to detect and quantify wind power ramps. *Wind Energy Science*, 5(4), 1731-1741.
- Clemente, J. D. O. (2018). Previsão de rampas em séries temporais de potência de saída de centrais eólicas (Master's thesis, Universidade Federal de Pernambuco).
- Coelho-Barros, E. A., Simões, P. A., Achcar, J. A., Martinez, E. Z., & Shimano, A. C. (2008). Métodos de estimação em regressão linear múltipla: aplicação a dados clínicos. *Revista Colombiana de Estadística*, 31(1), 111-129.
- Couto, A., Costa, P., & Simões, T. (2021). Identification of extreme wind events using a weather type classification. *Energies*, 14(13), 3944.
- Dalton, A., Bekker, B., & Koivisto, M. J. (2021). Simulation and detection of wind power ramps and identification of their causative atmospheric circulation patterns. *Electric Power Systems Research*, 192, 106936.
- de Mattos Neto, P. S., de Oliveira, J. F. L., Júnior, D. S. D. O. S., Siqueira, H. V., Marinho, M. H. D. N., & Madeiro, F. (2020). A hybrid nonlinear combination system for monthly wind speed forecasting. *IEEE Access*, 8, 191365-191377.
- Diallo, M., Letang, L., Totel, B., & Poncet, P. (2024, April). Wind Speed Ramp Rate Predictions Using Wind Farm SCADA Data Assimilation and a WRF Ensemble. In *Journal of Physics: Conference Series* (Vol. 2745, No. 1, p. 012015). IOP Publishing.
- Dhiman, H. S., & Deb, D. (2020). Machine intelligent techniques for ramp event prediction in offshore and onshore wind farms. *arXiv preprint arXiv:2011.14220*.
- Doan, V. Q., Kusaka, H., Matsueda, M., & Ikeda, R. (2019). Application of mesoscale ensemble forecast method for prediction of wind speed ramps. *Wind Energy*, 22(4), 499-508.
- Dodla VB, Desamsetti S, Yerramilli A. A comparison of HWRF, ARW and NMM models in Hurricane Katrina (2005) simulation. *Int J Environ Res Public Health*. 2011 Jun;8(6):2447-69. doi: 10.3390/ijerph8062447. Epub 2011 Jun 23. PMID: 21776239; PMCID: PMC3138034.

Eltohamy, M. S., Moteleb, M. S. A., Talaat, H., Mekhemar, S. F., & Omran, W. (2020). Wind Power Ramps Analysis for High Shares of Variable Renewable Generation in Power Systems. *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, 8(2), 256-272.

EPE. Balanço Energético Nacional (2023) - Ano base 2021: Relatório Síntese. Rio de Janeiro, 2024.

Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996, August). A density-based algorithm for discovering clusters in large spatial databases with noise. In *kdd* (Vol. 96, No. 34, pp. 226-231).

Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., & Akinyelu, A. A. (2022). A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. *Engineering Applications of Artificial Intelligence*, 110, 104743.

Gallego Castillo, C. J. (2013). Statistical models for short-term wind power ramp forecasting (Doctoral dissertation, Aeronauticos).

Gao, J., Chongfuangprinya, P., Ye, Y., & Yang, B. (2020, August). A three-layer hybrid model for wind power prediction. In *2020 IEEE Power & Energy Society General Meeting (PESGM)* (pp. 1-5). IEEE.

Graupe, D. (2013). Principles of artificial neural networks (Vol. 7). World Scientific.

Groch, M., & Vermeulen, H. J. (2022). Forecasting wind speed events at a utility-scale wind farm using a WRF-ANN model. *Wind Engineering*, 46(1), 102-119.

Han, L., Qiao, Y., Li, M., & Shi, L. (2020). Wind power ramp event forecasting based on feature extraction and deep learning. *Energies*, 13(23), 6449.

Haykin, S. (2001). *Redes neurais: princípios e prática*. Bookman Editora.

He, Y., Zhu, C., & Cao, C. (2024). A wind power ramp prediction method based on value-at-risk. *Energy Conversion and Management*, 315, 118767.

Irani, J., Pise, N., & Phatak, M. (2016). Clustering techniques and the similarity measures used in clustering: A survey. *International journal of computer applications*, 134(7), 9-14.

Janjic, Z. I. (2003). A nonhydrostatic model based on a new approach. *Meteorology and Atmospheric Physics*, 82(1), 271-285.

Jolliffe, I. T., & Jolliffe, I. T. (1986). Generalizations and adaptations of principal component analysis. *Principal component analysis*, 223-234.

Kassa, Y., Zhang, J. H., Zheng, D. H., & Wei, D. (2016, August). A GA-BP hybrid algorithm based ANN model for wind power prediction. In *2016 IEEE Smart Energy Grid Engineering (SEGE)* (pp. 158-163). IEEE.

Kirthiga, S. M., & Patel, N. R. (2018). Impact of updating land surface data on micrometeorological weather simulations from the WRF model. *Atmosfera*, 31(2), 165-183.

Lachi, R. L., & da Rocha, H. V. (2005). Aspectos básicos de clustering: conceitos e técnicas. Núcleo de Informática Aplicada à Educação (Nied), UNICAMP-Instituto de Computação–Universidade Estadual de Campinas.

Li, J., Song, T., Liu, B., Ma, H., Chen, J., & Cheng, Y. (2020). Forecasting of wind capacity ramp events using typical event clustering identification. *IEEE Access*, 8, 176530-176539.

Li, Y., Dai, C., Wang, T., Zhou, Z., Zhou, S., Cai, L., ... & Lozowski, E. (2016, March). Separate wind power and ramp predictions based on meteorological variables and clustering method. In *2016 IEEE 6th International Conference on Power Systems (ICPS)* (pp. 1-6). IEEE.

Lima, F. H. D. A. (2019). Previsão de geração eólica de curto prazo em tempo real baseada em dados observacionais das centrais eólicas e da previsão numérica do tempo (Master's thesis, Universidade Federal de Pernambuco).

Liu, W., Gong, Y., Geng, G., & Jiang, Q. (2019). Refined ramp event characterisation for wind power ramp control using energy storage system. *IET Renewable Power Generation*, 13(10), 1731-1740.

Lydia, M.; Selvakumar, A.I.; Kumar, S.S.; Kumar, G.E.P. Advanced Algorithms for Wind Turbine Power Curve Modeling. *IEEE Trans. Sustain. Energy* 2013, 4, 827–835.

Marill, K. A. (2004). Advanced statistics: linear regression, part II: multiple linear regression. *Academic emergency medicine*, 11(1), 94-102.

Mark, H. (2007). Data analysis: Multilinear regression and principal component analysis. In *Handbook of near-infrared analysis* (pp. 169-206). CRC Press.

Mendes, J. C. (2017). Agrupamento de dados e suas aplicações.

National Center for Atmospheric Research, Mesoscale & Microscale Meteorology Laboratory, 2022. Weather Research & Forecasting Model (WRF), Disponível em: <https://www.mmm.ucar.edu/models/wrf>;

Nazaré, G., Castro, R., & Gabriel Filho, L. R. (2020). Wind power forecast using neural networks: Tuning with optimization techniques and error analysis. *Wind Energy*, 23(3), 810-824.

Ogliari, E., Guilizzoni, M., Giglio, A., & Pretto, S. (2021). Wind power 24-h ahead forecast by an artificial neural network and an hybrid model: Comparison of the predictive performance. *Renewable Energy*, 178, 1466-1474.

Okada, M., Ichizawa, T., Nakamura, Y., Yamaguchi, K., Kodama, R., Kato, H., ... & Ogasawara, N. (2018). Development of a wind power ramp forecast system by a statistical and meteorological approach. In *Grand Renewable Energy proceedings Japan council for Renewable Energy* (2018) (p. 130). Japan Council for Renewable Energy.

Olaofe, Z. O., & Folly, K. A. (2013). Wind energy analysis based on turbine and developed site power curves: A case-study of Darling City. *Renewable Energy*, 53, 306-318.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO – ONS, Nota técnica n.º 151/2018, Desenvolvimento metodológico para previsão de geração de fonte eólica – dezembro, 2018.

Ouyang, T., Zha, X., Qin, L., He, Y., & Tang, Z. (2019). Prediction of wind power ramp events based on residual correction. *Renewable Energy*, 136, 781-792.

Pereyra-Castro, K., & Caetano, E. (2022). Wind-Ramp Predictability. *Atmosphere*, 13(3), 453.

Powers, J. G., Klemp, J. B., Skamarock, W. C., Davis, C. A., Dudhia, J., Gill, D. O., ... Duda, M. G. (2017). The Weather Research and Forecasting Model: Overview, system efforts, and future directions. *Bulletin Of The American Meteorological Society*, 98, 1717-1737. doi:10.1175/BAMS-D-15-00308.1

International standard IEC 61400-12-1, Wind turbines- Power performance measurement of electricity producing wind turbines, 2005.

Rauber, T. W. (2005). *Redes neurais artificiais*. Universidade Federal do Espírito Santo, 29.

Reddy, C. K., & Vinzamuri, B. (2018). A survey of partitional and hierarchical clustering algorithms. In *Data clustering* (pp. 87-110). Chapman and Hall/CRC.

Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.

Rousseeuw, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, 20, 53-65.

Sander, J., Ester, M., Kriegel, H. P., & Xu, X. (1998). Density-based clustering in spatial databases: The algorithm gbscan and its applications. *Data mining and knowledge discovery*, 2(2), 169-194.

Scikit-learn: Machine Learning in Python, Pedregosa et al., *JMLR* 12, pp. 2825-2830, 2011.

Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Liu, Z., Berner, J., ... Huang, X. -yu. (2021). A Description of the Advanced Research WRF Model Version 4.3 (No. NCAR/TN-556+STR). doi:10.5065/1dfh-6p97

Sohoni, V., Gupta, S. C., & Nema, R. K. (2016). A critical review on wind turbine power curve modelling techniques and their applications in wind based energy systems. *Journal of Energy*, 2016(1), 8519785.

Souza, N. B., Nascimento, E. G., & Moreira, D. M. (2023). Performance evaluation of the WRF model in a tropical region: Wind speed analysis at different sites. *Atmósfera*, 36(2), 253-277.

Sreenivasulu, A. (2019). Evaluation of cluster based Anomaly detection.

Taud, H., & Mas, J. F. (2018). Multilayer perceptron (MLP). *Geomatic approaches for modeling land change scenarios*, 451-455.

Verma, M., Srivastava, M., Chack, N., Diswar, A. K., & Gupta, N. (2012). A comparative study of various clustering algorithms in data mining. *International Journal of Engineering Research and Applications (IJERA)*, 2(3), 1379-1384.

Vemuri, A., Buckingham, S., Munters, W., Helsen, J., & Van Beeck, J. (2022). Sensitivity analysis of mesoscale simulations to physics parameterizations over the Belgian North Sea using Weather Research and Forecasting–Advanced Research WRF (WRF-ARW). *Wind Energy Science*, 7(5), 1869-1888.

Veron, D. E., Brodie, J. F., Shirazi, Y. A., & Gilchrist, J. R. (2018). Modeling the electrical grid impact of wind ramp-up forecasting error offshore in the Mid-Atlantic region. *Journal of Renewable and Sustainable Energy*, 10(1).

Xu, X., Lei, Y., & Li, Z. (2019). An incorrect data detection method for big data cleaning of machinery condition monitoring. *IEEE Transactions on Industrial Electronics*, 67(3), 2326-2336.

Wilks, D. S. (2011). *Statistical methods in the atmospheric sciences*. Academic press.

Ünsalan, C., Höke, B., & Atmaca, E. (2024). Clustering. In *Embedded Machine Learning with Microcontrollers: Applications on STM32 Development Boards* (pp. 195-214). Cham: Springer International Publishing.

Yang, Q., Berg, L. K., Pekour, M., Fast, J. D., Newsom, R. K., Stoelinga, M., & Finley, C. (2013). 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*, 52(8), 1753-1763.

Zeng, J., & Qiao, W. (2012). Short-term wind power prediction using a wavelet support vector machine. *IEEE transactions on sustainable energy*, 3(2), 255-264.

Zha, J., Zhao, D., Wu, J., & Zhang, P. (2019). Numerical simulation of the effects of land use and cover change on the near-surface wind speed over Eastern China. *Climate Dynamics*, 53, 1783-1803.

Zhang, Jie., Cui, Mingjian., Hodge, Bri-Mathias., Florita, Anthony., Freedman, Jeffrey. (2017). Ramp Forecasting Performance from Improved Short-Term Wind Power Forecasting Over Multiple Spatial and Temporal Scales. *Energy*. 122. 10.1016/j.energy.2017.01.104.

Zhou, B., Duan, H., Wu, Q., Wang, H., Or, S. W., Chan, K. W., & Meng, Y. (2021). Short-term prediction of wind power and its ramp events based on semi-supervised generative adversarial network. *International Journal of Electrical Power & Energy Systems*, 125, 106411.

Zucatelli, P. J., Nascimento, E. G. S., Santos, A. Á. B., Arce, A. M. G., & Moreira, D. M. (2021). An investigation on deep learning and wavelet transform to nowcast wind power and wind power ramp: A case study in Brazil and Uruguay. *Energy*, 230, 120842.

## Anexo A - Figuras

Figura - Resultados G1 k=1

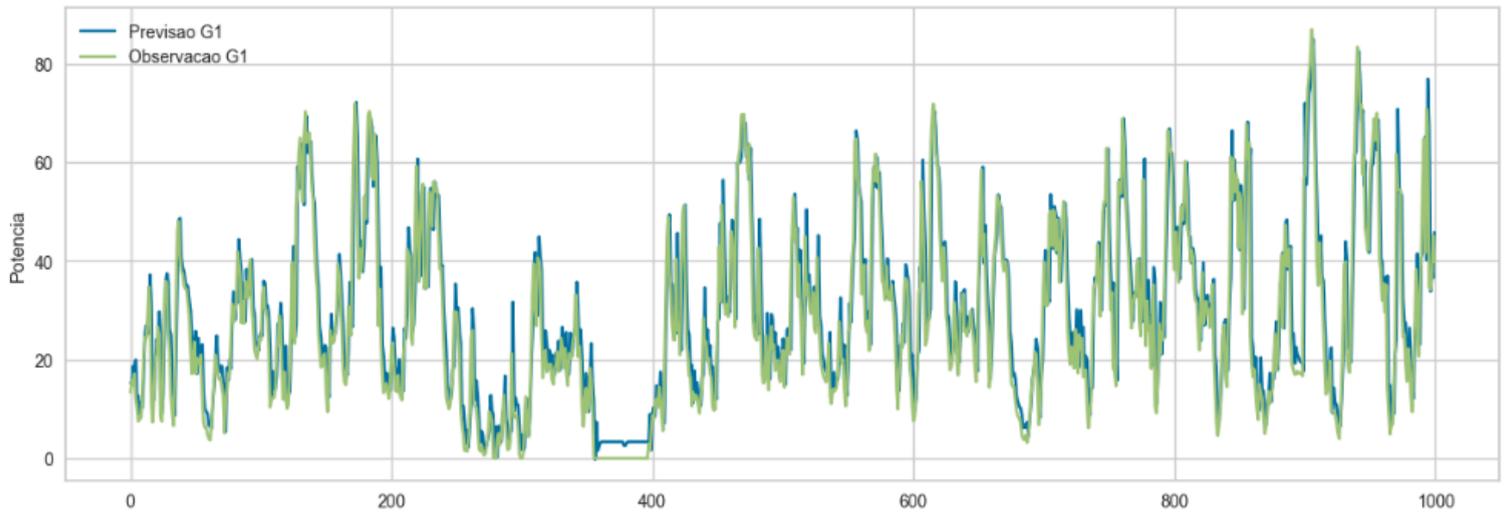


Figura - Resultados G2 k=1

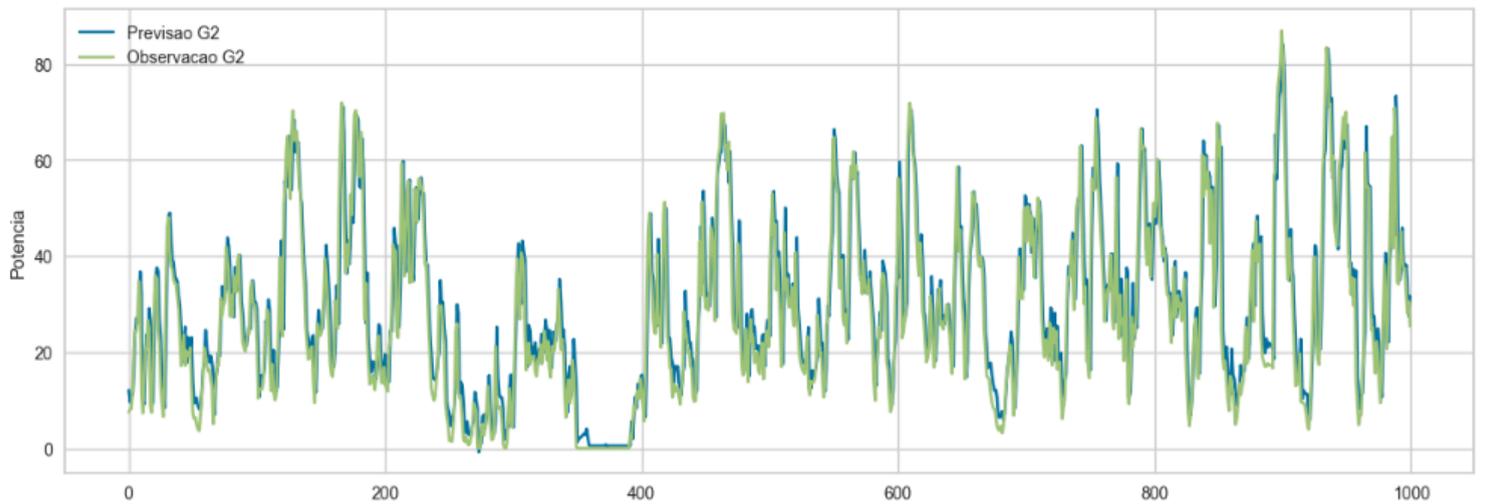


Figura - Resultados G3 k=1

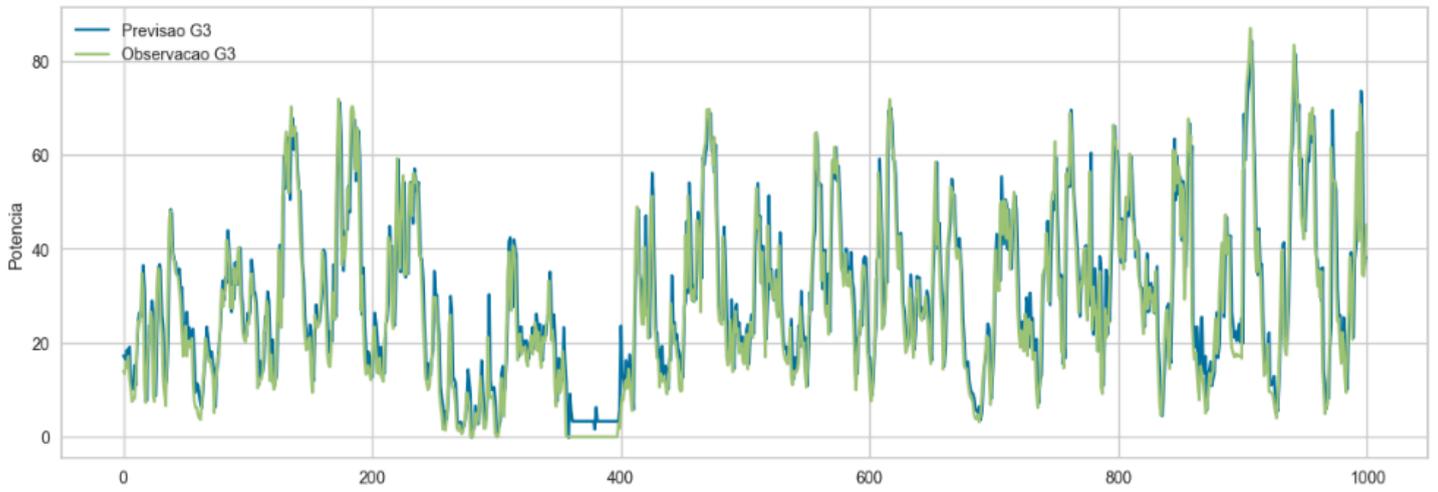


Figura - Resultados G4 k=1

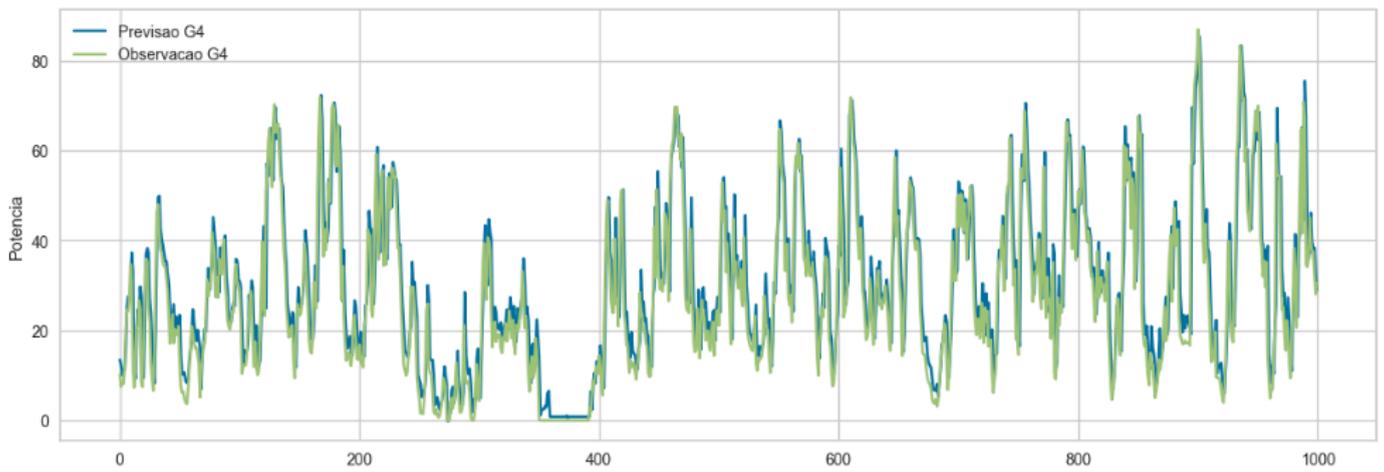


Figura - Resultados G5 k=1

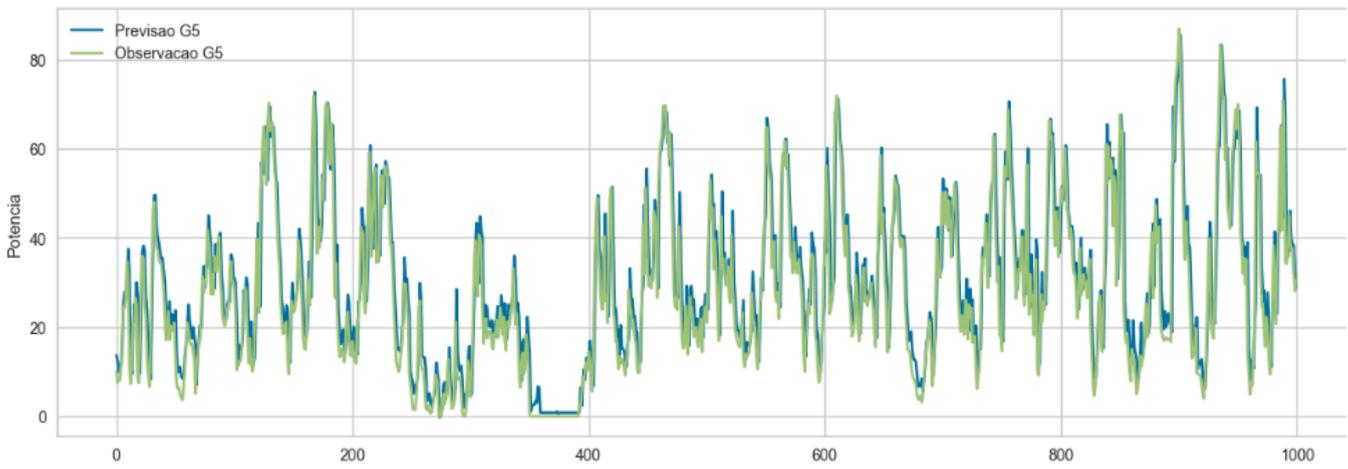


Figura - Correlação L-WRF-C em comparativo com L-WRF (rampa subida)

