



# **ANÁLISE DE SÉRIES TEMPORAIS EM DADOS DE ACUMULADORES DE ENERGIA**

**Trabalho de Conclusão de Curso**

**Engenharia da Computação**

**Felipe Augusto da Silva Ribeiro**  
**Orientador: Alexandre Magno Andrade Maciel**



**Universidade de Pernambuco  
Escola Politécnica de Pernambuco  
Graduação em Engenharia de Computação**

**FELIPE AUGUSTO DA SILVA RIBEIRO**

**ANÁLISE DE SÉRIES TEMPORAIS EM  
DADOS DE ACUMULADORES DE  
ENERGIA**

**Monografia** apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

**Recife, outubro de 2022.**

Ribeiro, Felipe Augusto da Silva

Análise de séries temporais em dados de acumuladores de energia/  
Felipe Augusto da Silva Ribeiro. - Recife-PE, 2022.  
xiii , 42 f.: il. ; 29 cm.

Trabalho de Conclusão de Curso (Graduação em Engenharia de  
Computação) Universidade de Pernambuco, Escola Politécnica de  
Pernambuco, Recife, 2022

Orientador: Profº. Drº. Alexandre Magno Andrade Maciel

1. Geração eólica. 2. Previsão. 3. Sistemas de armazenamento  
de energia por bateria. I. Análise de séries temporais em dados de  
acumuladores de energia. II. Orientador Maciel, Alexandre. III.  
Universidade de Pernambuco.

## MONOGRAFIA DE FINAL DE CURSO

### Avaliação Final (para o presidente da banca)\*

No dia 19/10/2022, às 11h00min, reuniu-se para deliberar sobre a defesa da monografia de conclusão de curso do(a) discente **FELIPE AUGUSTO DA SILVA RIBEIRO**, orientado(a) pelo(a) professor(a) **ALEXANDRE MAGNO ANDRADE MACIEL**, sob título ANÁLISE DE SÉRIES TEMPORAIS EM DADOS DE ACUMULADORES DE ENERGIA, a banca composta pelos professores:

**BRUNO JOSÉ TORRES FERNANDES (PRESIDENTE)**

**ALEXANDRE MAGNO ANDRADE MACIEL (ORIENTADOR)**


Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:

Aprovada       Aprovada com Restrições\*       Reprovada

e foi-lhe atribuída nota: 9,0 ( nove )

\*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O(A) discente terá oito dias para entrega da versão final da monografia a contar da data deste documento.

  
AVALIADOR 1: Prof (a) **BRUNO JOSÉ TORRES FERNANDES**

  
AVALIADOR 2: Prof (a) **ALEXANDRE MAGNO ANDRADE MACIEL**

AVALIADOR 3: Prof (a)

\* Este documento deverá ser encadernado juntamente com a monografia em versão final.

*Dedico este trabalho ao meu pai(in memorian), mãe, esposa e filhos.*

# Agradecimentos

Agradeço primeiramente a Deus, pela minha vida, por me guiar e mostrar sempre o caminho que posso seguir.

À minha esposa, filhos, pai, mãe e irmãos que estiveram do meu lado nessa longa batalha da graduação.


Aos professores, pelos ensinamentos e avaliações que me ajudaram no caminho da graduação.

E ao Instituto Edson Mororó Moura - ITEM, por disponibilizar os dados de energia eólica utilizados neste trabalho.

## Autorização de publicação de PFC

Eu, **Felipe Augusto da Silva Ribeiro** autor(a) do projeto de final de curso intitulado: **ANÁLISE DE SÉRIES TEMPORAIS EM DADOS DE ACUMULADORES DE ENERGIA;** autorizo a publicação de seu conteúdo na internet nos portais da Escola Politécnica de Pernambuco e Universidade de Pernambuco.

O conteúdo do projeto de final de curso é de responsabilidade do autor.

Documento assinado digitalmente  
 FELIPE AUGUSTO DA SILVA RIBEIRO  
Data: 21/10/2022 15:48:50-0300  
Verifique em <https://verificador.iti.br>

---

**Felipe Augusto da Silva Ribeiro**



---

Orientador(a): **Alexandre Magno Andrade Maciel**

---

Coorientador(a):



---

Prof, de TCC: **Daniel Augusto Ribeiro Chaves**

---

Data: 19/10/2022

## Resumo

As energias renováveis, como as fotovoltaicas e eólicas, tornaram-se uma solução para resolver problemas associados ao esgotamento do petróleo, aumento da demanda da energia e o aquecimento global. O uso da energia eólica traz muitas vantagens, como ser a energia mais barata e a coexistência com outras atividades, mas devido a natureza intermitente do vento, traz alguns problemas. Quando colocado em uma rede elétrica, o principal é a flutuação da energia elétrica, que gera problema de confiabilidade na rede. Uma das maneiras de mitigar esse problema é com o uso do BESS (*Battery Energy Storage System*), que suaviza essa potência eólica, dando mais estabilidade à energia entregue à rede. Os modelos ARIMA e LSTM foram utilizados para prever a potência eólica e com isso antecipar o despacho do BESS e assim melhorar a suavização de potência, já que o modelo existente trabalha com a potência eólica atual tendo um atraso no despacho da bateria. O indicador numérico MVP (*Maximum Power Variation*) é utilizado para verificar o desempenho dessa suavização. Os modelos testados conseguem reduzir o indicador, com o destaque para o LSTM, que reduziu em quase 5% . Mostrando que com uma previsão mais precisa, pode se aumentar essa redução.

**Palavras-chaves:** Geração eólica; Suavização de potência; ARIMA; LSTM; MVP.



## **Abstract**

Renewable energies, such as photovoltaics and wind, have become a solution to solve problems associated with oil depletion, increased energy demand and global warming. The use of wind energy brings many advantages, such as being the cheapest energy and coexistence with other activities, but due to the intermittent nature of the wind, it brings some problems. When placed in an electrical network, the main thing is the fluctuation of electrical energy, which generates a problem of reliability in the network. One of the ways to mitigate this problem is with the use of BESS (Battery Energy Storage System), which smoothes this wind power, giving more stability to the energy delivered to the grid. The ARIMA and LSTM models were used to predict the wind power and thus anticipate the BESS dispatch and thus improve the power smoothing, since the existing model works with the current wind power having a delay in the battery dispatch. The numerical indicator MVP (Maximum Power Variation) is used to check the performance of this smoothing. The tested models manage to reduce the indicator, with emphasis on the LSTM, which reduced it by almost 5%. Showing that with a more accurate forecast, this reduction can be increased.

**Keywords:** Wind generation; Power smoothing; ARIMA; LSTM; MVP

## Lista de figuras

<b>Figura 1.</b>	Projeção do crescimento da eólica até 2030	13
<b>Figura 2.</b>	Potência eólica gerada no dia 21 de agosto de 2021	14
<b>Figura 3.</b>	Exemplo de um BESS	16
<b>Figura 4.</b>	Estrutura do BESS	17
<b>Figura 5.</b>	Esquema básico do acoplamento da geração eólica com o BESS	18
<b>Figura 6.</b>	Arquitetura de uma RNA	20
<b>Figura 7.</b>	Célula de memória da rede LSTM	21
<b>Figura 8.</b>	Modelo proposto	23
<b>Figura 9.</b>	Distribuição de Frequência da Potência eólica	25
<b>Figura 10.</b>	Distribuição da Potência ativa do BESS	25
<b>Figura 11.</b>	BESS na função suavização de potência - medição em 03-09-2021	26
<b>Figura 12.</b>	Funcionamento do BESS - medição em 03-09-2021	26
<b>Figura 13.</b>	Gráfico de Box Plot da série completa	27
<b>Figura 14.</b>	Previsão do modelo ARIMA	31
<b>Figura 15.</b>	Previsão do modelo LSTM	32
<b>Figura 16.</b>	Código em Python do modelo ARIMA	40
<b>Figura 17.</b>	Código em Python do modelo LSTM	41

## Lista de tabelas

<b>Tabela 1.</b>	Estatística do conjunto de dados em relação a Potência Ativa em MW	23
<b>Tabela 2.</b>	Previsão do modelo ARIMA	28
<b>Tabela 3.</b>	Parâmetros do LSTM	29
<b>Tabela 4.</b>	Previsão do modelo LSTM	29
<b>Tabela 5.</b>	Suavização de potência medida em 31 de agosto de 2021	31
<b>Tabela 6.</b>	Suavização de potência medida em 02 de setembro de 2021	32
<b>Tabela 7.</b>	Suavização de potência medida em 06 de setembro de 2021	33

## **Lista de abreviaturas e siglas**

ARIMA – *Autoregressive Integrated Moving Average*

BESS – *Battery energy storage system*

ESS – *Energy storage system*

LSTM – *Long short-term Memory*

MVP – *Maximum Power Variation*

RNA – Rede Neurais Artificiais


## Sumário

<b>1. INTRODUÇÃO</b>	<b>12</b>
<b>2. FUNDAMENTAÇÃO TEÓRICA</b>	<b>14</b>
2.1 BESS	15
2.2 SUAVIZAÇÃO DE POTÊNCIA	16
2.3 INDICADOR MAXIMUM POWER VARIATION (MVP)	17
2.4 SÉRIES TEMPORAIS	17
2.5 ARIMA	18
2.6 LSTM	18
<b>3. TRABALHOS RELACIONADOS</b>	<b>20</b>
<b>4. METODOLOGIA</b>	<b>22</b>
4.1 AQUISIÇÃO DOS DADOS	22
4.2 ANÁLISE DOS DADOS	23
4.3 PRÉ-PROCESSAMENTO	26
<b>5. RESULTADOS</b>	<b>29</b>
5.3 TREINAMENTO E AVALIAÇÃO	29
5.2 SUAVIZAÇÃO DE POTÊNCIA CONSIDERANDO A PREVISÃO DE POTÊNCIA COM AVALIAÇÃO DO MVP.	31
<b>6. CONCLUSÃO E TRABALHOS FUTUROS</b>	<b>36</b>
<b>REFERÊNCIAS</b>	<b>37</b>
<b>APÊNDICE A - CÓDIGO FONTE DO TRABALHO</b>	<b>38</b>

## 1. INTRODUÇÃO

A dependência do mundo no uso dos combustíveis fósseis levará a uma situação insustentável no futuro próximo, devido às reservas de combustíveis fósseis disponíveis serem limitadas [1]. As fontes renováveis são uma solução viável para este problema. Além disso, as fontes de energia renováveis são importantes para diminuir o aumento das emissões de gases do efeito estufa e aumento das temperaturas globais [2]. Das energias renováveis disponíveis, a energia eólica se destaca pelo seu crescimento, sendo hoje, a forma mais barata de geração e podendo coexistir com setores como agricultura [3]. Anualmente, mais de 1,2 bilhões de toneladas de CO<sub>2</sub> deixam de ser liberados no mundo devido a capacidade total de energia eólica global atual ser de até 837 GW, sendo 2021 o segundo melhor ano em meio a pandemia, com quase 94 GW de capacidade adicionada globalmente . Na Figura 1, é demonstrado a previsão do aumento da capacidade energética eólica mundial projetada pela GWEC [4].


**Figura 1** - Projeção do crescimento da capacidade eólica até 2030



Fonte: GWEC 2022[4]

Mesmo com o futuro promissor da indústria eólica, a energia eólica pode apresentar vários problemas na sua integração com o sistema elétrico, devido à sua natureza fortemente intermitente do vento, estocasticidade e volatilidade, prejudicando a operação na segurança, confiança e na economia do sistema elétrico [5] [1]. Como problemas podemos citar a elevação de tensão no estado estacionário, queda de tensão, oscilações no sistema elétrico e instabilidade na tensão, entre outras [6]. Na Figura 2 podemos notar devido à natureza intermitente do vento a variação ao longo do dia da potência eólica gerada. Sendo, a flutuação de energia, um das que gera mais preocupações, pois impacta diretamente na regulação da frequência do sistema de energia, na estratégia de redução de pico e na qualidade da energia fornecida [1].

**Figura 2** - Potência eólica gerada no dia 21 de agosto de 2021



Fonte: Compilação do autor

Uma das formas de mitigar esse problema da flutuação de energia é a utilização de um sistema de armazenamento por bateria (*BESS, Battery Energy Storage System*) para suavização de potência que já vem sendo uma tecnologia relativamente madura para esse tipo de problema. A suavização de potência ou suavização de saída garante uma potência de saída mais constante eliminando intermitência da energia eólica [1][6].

O dimensionamento do *BESS* é muito importante para garantir o correto funcionamento da rede [7]. Neste trabalho, simulamos a utilização de um *BESS*, através da previsão da potência eólica utilizando Arima e LSTM com a intenção de

suavizar a potência de saída da geração eólica. Avaliando esta previsão através do indicador numérico *Maximum Power Variation* (MVP) já que esse indicador avalia, além de outras, o desempenho das técnicas de suavização de potência, determinando a maior potência da geração eólica dentro de um intervalo de tempo predefinido [2].

O restante do trabalho está distribuído em mais cinco capítulos. A fundamentação teórica é apresentada no capítulo 2, no capítulo 3 está os trabalhos relacionados, o capítulo 4 apresenta a metodologia adotada neste trabalho, os resultados obtidos são exibidos no capítulo 5, e no capítulo 6 apresenta as conclusões



## 2. FUNDAMENTAÇÃO TEÓRICA

O presente trabalho foi embasado em alguns conceitos cujos mesmos devem ser esclarecidos para um melhor entendimento do trabalho proposto.

### 2.1 BESS

Entre os vários armazenamentos de energia disponíveis, o sistema de armazenamento de energia por bateria (BESS) é uma tecnologia bem madura e flexível, adequada para aplicação na geração de energia renovável, a imagem de um BESS está na Figura 3. As baterias eletroquímicas armazenam eletricidade no material ativo na forma de energia química. Há uma variedade de baterias eletroquímicas disponíveis, tais como, de chumbo-ácido, níquel-cádmio, níquel-metal hidreto, lítio-íon, entre outras. Elas variam na eficiência, custo, densidade de energia e tempo de vida. Essas baterias são utilizadas para reduzir a flutuação de potência de curto prazo, melhorando a qualidade da energia elétrica e serviços ancilares, que são os serviços considerados necessários para uma operação segura e confiável no sistema elétrico [5][6].


Uma das vantagens da bateria eletroquímica é a rápida resposta, superando os outros ESS. A bateria de lítio-íon, que foi utilizada para obter os dados, possui uma vida útil muito grande em ciclos, alta eficiência, uma alta densidade de energia e rápido tempo de resposta, mas ainda seu custo é alto, devido aos circuito de proteção contra sobrecargas e da estrutura espacial de empacotamento necessários para garantir a confiabilidade da bateria [5][8]. Na Figura 4 está imagem da estrutura interna do BESS.

**Figura 3** - Exemplo de um BESS



Fonte: Compilação do Autor


Figura 4 - Estrutura do BESS



Fonte: Compilação do Autor

## 2.2 SUAVIZAÇÃO DE POTÊNCIA

Na geração de energia eólica ocorrem flutuações de energia consideráveis, em escalas de segundos a minutos, devido a natureza intermitente do vento. Essas variações geram problemas para a rede de energia elétrica. O *BESS* é utilizado para compensar essas variações de energia e com isso acabar com os problemas gerados na rede [8]. A suavização de potência é uma das aplicações mais importantes do BESS na geração de energia eólica, mantendo, assim, no sistema elétrico uma potência mais estável. A topologia básica do sistema para a suavização de potência é basicamente composto por um gerador eólico, um BESS, e um conversor. A potência de rede é a soma entre a potência da geração eólica e a potência do BESS, este sendo conectado em ponto de acoplamento em comum, pode extrair energia ou fornecer energia para rede [9]. A Figura 5, é apresentado o esquema básico de um complexo de energia eólica funcionando em paralelo com o BESS. Onde a potência da rede é a soma da potência eólica gerada e a potência do BESS.

**Figura 5** - Esquema básico do acoplamento da geração eólica com o BESS

Fonte: Compilação do Autor

### 2.3 INDICADOR MAXIMUM POWER VARIATION (MVP)

O indicador MVP é utilizado para medir o desempenho da técnica de suavização de potência ativa de geradoras eólicas, esse desempenho é avaliado numericamente. Esse indicador retorna a variação máxima de potência na potência nominal da geração eólica dentro de um intervalo de tempo estabelecido. Ele é utilizado por empresas europeias para restringir as flutuações da geração eólica, o intervalo de tempo utilizado por elas é de 1 min a 10 min [2]. Dependendo do intervalo utilizado o MVP pode ser chamado de MVP1, quando usa o intervalo de 1 minuto, MVP5, intervalo de 5 minutos ou MVP10, no intervalo de 10 minutos. Assim, o MVP tem melhor precisão na avaliação da suavização de potência em parques eólicos.

### 2.4 SÉRIES TEMPORAIS

Uma série temporal é definida como uma sequência de observações de uma variável ordenadas no tempo [10]. Numa série temporal, o tempo é frequentemente variável independente. A série temporal é uma sequência ordenada de observações que ocorrem em intervalos de tempo uniformes. Então, a ordem das observações é importante para séries temporais. Elas podem ser usadas em várias aplicações, mas a previsão é a mais utilizada. Sempre se referindo como o tempo atual como  $t$  e o

anterior como t-1 e tempo antes dele com t-2 e assim sucessivamente. E as observações posteriores com t+1, t+2 e assim por diante. Então uma série pode ser representada por uma sequência de observações ordenadas com o tempo:  $\{\dots, X_{t-2}, X_{t-1}, X_t, X_{t+1}, X_{t+2}, \dots\}$ .

## 2.5 ARIMA

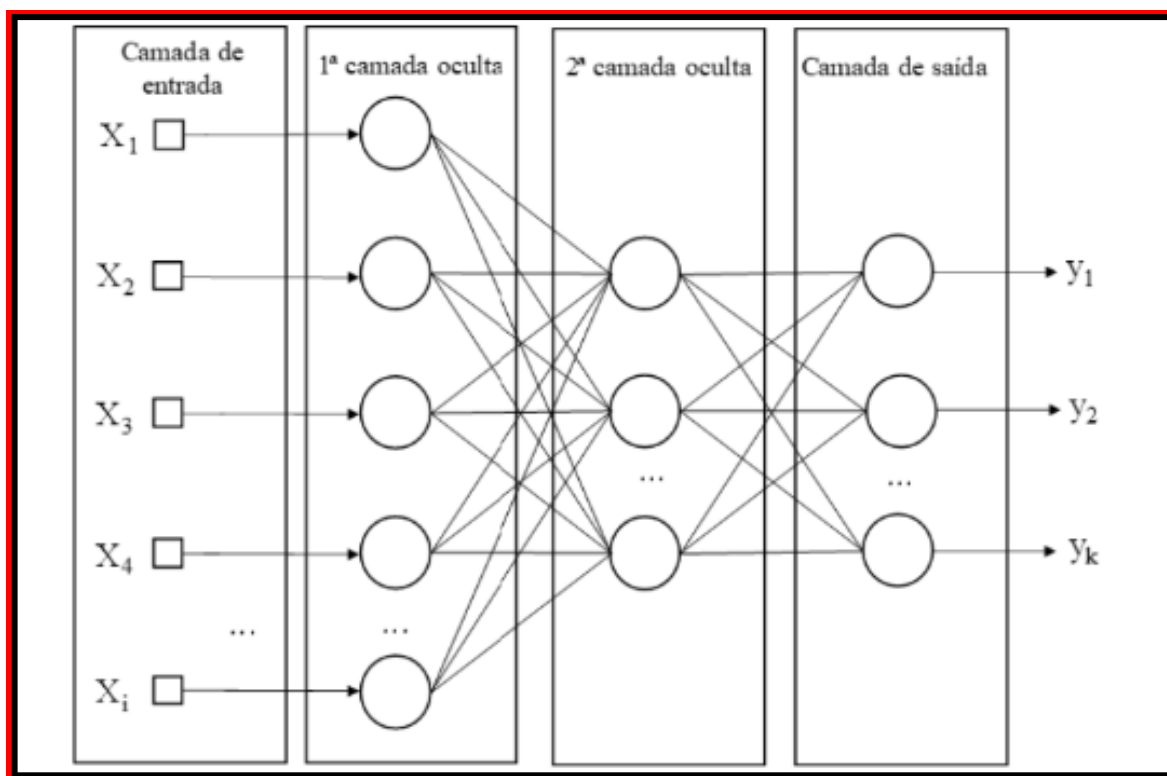
O modelo ARIMA (p, d, q), que foi introduzido por Box e Jenkins[11] é do tipo modelo estatístico baseado em séries temporais, é amplamente utilizado em previsões de curto prazo[12].

Os parâmetros autorregressivos (p, d, q) representam a defasagem das séries diferenciadas. Quando a série temporal não é estacionária ou sazonal, ele precisa ser diferenciada para virar estacionária. No modelo ARIMA(p, d, q), p é o número de termos autorregressivos, d são as diferenças sazonais e q os erros de previsão defasados [12][13][14].

## 2.6 LSTM

Rede Neurais Artificiais (RNA) têm se mostrado excelentes para a previsão de séries temporais. Elas são inspiradas na teoria do funcionamento do cérebro humano, com isso, a RNA tenta reconhecer padrões e regularidades nos dados podendo aprender e fazer generalizações. Uma das vantagens da RNA é seu alto grau de precisão em relação a outros modelos não lineares, isso devido ao processamento paralelo das informações dos dados [14]. Elas são organizadas em camadas: camada inferior ou entradas, a camada oculta e a camada de previsões ou saída, como mostrado na Figura 6.

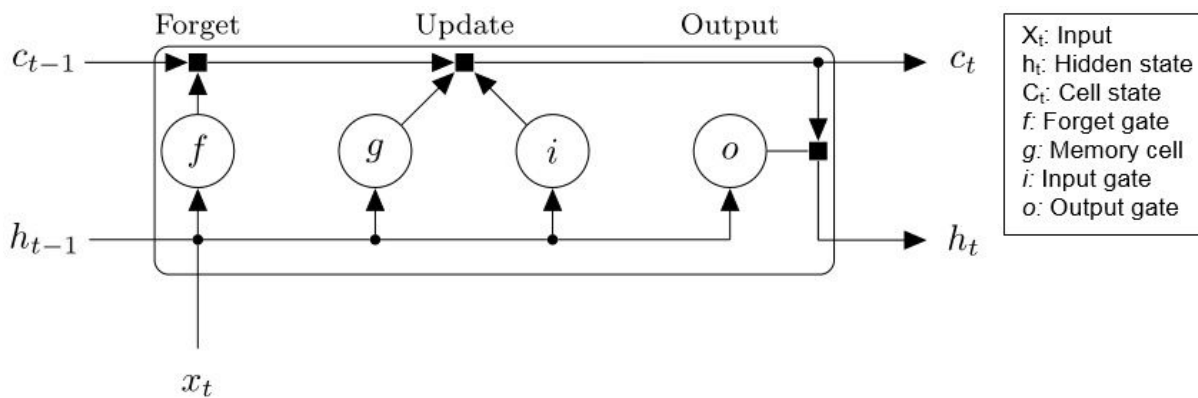
Figura 6 - Arquitetura de uma RNA



Fonte: SILVA[6]

As Redes Neurais Recorrentes (RNN) são representadas pela realimentação da arquitetura padrão, dentro das RNN está a LSTM que foi definida por [15], ela veio resolver o problema de dissipação de gradiente que as RNN tinham, podendo armazenar por uma quantidade arbitrária de passos de tempo. Na Figura 7, representação de uma célula de memória da rede LSTM. Assim, as redes LSTM foram desenvolvidas para evitar o problema da dependência em longo prazo. Com essa capacidade de guardar longos de tempo, a rede LSTM tem se destacado em tarefas que necessitem uma memória de longo alcance, sendo ideal para previsões de séries temporais, que é o objetivo deste trabalho.

Figura 7 - Célula de memória da rede LSTM



Fonte: KUMAR [16]

### 3. TRABALHOS RELACIONADOS

Em [1], é apresentado uma estratégia de controle do BESS baseado no filtro de média móvel comum (MAF) e a previsão de energia eólica de prazo ultracurto. Adicionando a previsão na entrada do filtro, os componentes de baixa frequência são quase eliminados. Fazendo o BESS se concentrar na compensação dos componentes de alta frequência, assim melhorando a suavização de potência e a eficiência econômica. Na etapa da previsão foi usada a regressão linear. Essa estratégia pode reduzir em cerca de 30% a capacidade do BESS em relação ao método sem uso da previsão.

Já em [18], o controle do BESS utiliza a potência média prevista do parque eólico como referência para o controle externo. Foram utilizados dados reais de um parque eólico de 50 MW. O desempenho da proposta foi avaliado por um índice baseado no desvio da potência utilizado para avaliar a eficácia da suavização de potência. Nessa estratégia, ainda pode-se definir o tamanho necessário da bateria para a aplicação.

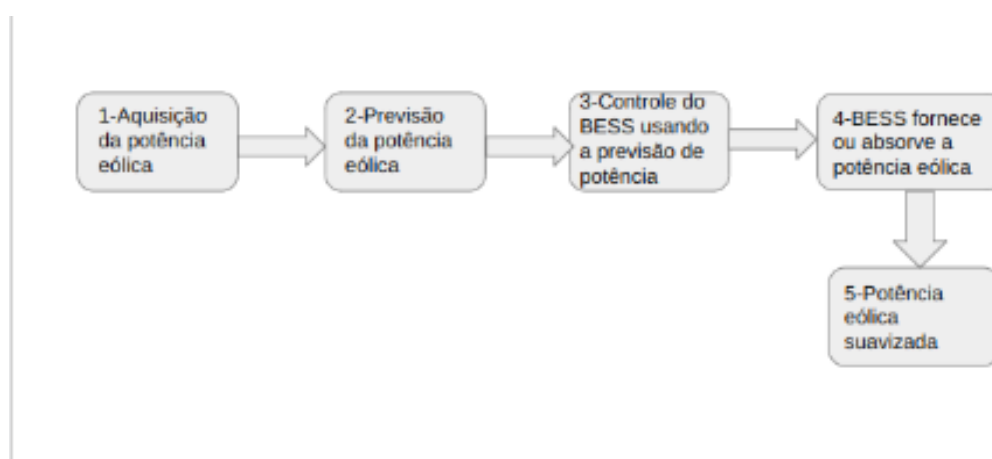
Outro trabalho que mostra a importância da previsão da potência eólica para o controle do BESS é o de Khalid e Salkin[19]. Nesse, foi proposto um sistema de previsão de potência eólica combinado com o BESS, baseado em medições de diferentes pontos de observações. O sistema foi avaliado através de dados de um parque eólico composto por 37 turbinas. A abordagem trouxe resultados que mostram a sua capacidade de suavizar a potência eólica e ainda, otimizar o SOC (Estado de Carga) do BESS.

Esses trabalhos relacionados embasam a pesquisa por utilizarem a previsão da potência eólica com parâmetro para o controle do BESS e assim retornando uma potência suavizada para rede elétrica.

## 4. METODOLOGIA

Como foi demonstrado nos trabalhos relacionados, a previsão da potência eólica é de grande importância para o controle do BESS configurado para suavizar a energia eólica. Neste capítulo será comentado sobre os dados usados para o estudo, os modelos de previsão utilizados bem como as medidas de acurácia que mostraram a qualidade da previsão dos modelos apresentados. Os modelos, cálculos e gráficos produzidos neste trabalho foram executados na linguagem Python. A representação do modelo proposto é apresentada na Figura 8.

**Figura 8** - Modelo proposto



Fonte: Compilação do autor

### 4.1 AQUISIÇÃO DOS DADOS

As medições utilizadas neste trabalho foram realizadas no Sistema de Armazenamento de Energia por Baterias (BESS) instalado no Complexo Eólico de Campo dos Ventos, durante o período de 22 de agosto de 2021 a 23 de outubro de 2021. A capacidade do BESS é de 1 MW/1,29 MWh. O BESS está conectado em paralelo a um grupo de aerogeradores que fornece uma potência de aproximadamente 50,4 MW, sendo a potência total do Complexo de aproximadamente 105,6 MW. As medições realizadas estão no intervalo de a cada 60 segundos. Nos dados, temos informações da potência ativa gerada pelos aerogeradores, a potência ativa do BESS em watts, o fator de potência da geração eólica, a potência ativa da geração eólica em watts, a potência reativa em var e a



frequência da geração eólica em Hz. Para esse trabalho só foi utilizado a potência ativa da geração eólica e a potência ativa do BESS .

## 4.2 ANÁLISE DOS DADOS

Neste trabalho vamos primeiro analisar a Potência Ativa dos aerogeradores que estão no período de 22/08/2021 até 23/10/2021. As medições foram feitas a cada 60 segundos através das funções do EMS do BESS. Na Tabela 1, podemos ver a quantidade de amostras bem como a média e os valores de mínimo e máximo da potência ativa.

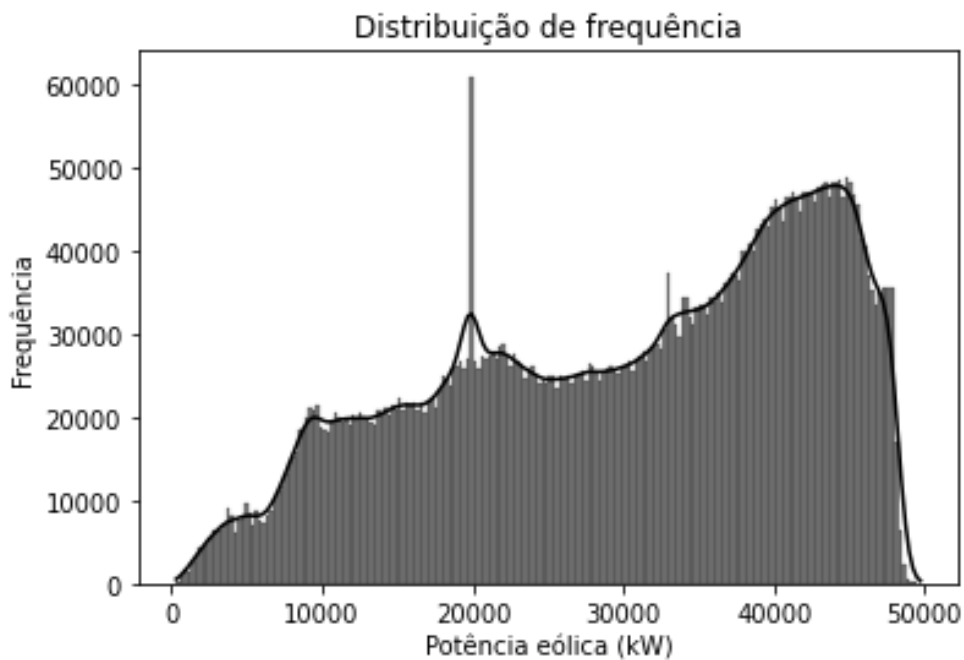
**Tabela 1** - Estatística do conjunto de dados em relação a Potência Ativa em MW

Quantidades das amostras	Média	Mínimo	25%	50%	75%	Máximo
86341	35,63	16,84	32,73	38,58	43,06	48,40

Na Figura 9, podemos verificar por meio do histograma que uma maior incidência durante a série de potências de 37 MW a 45 MW. No gráfico também podemos notar que a potência de 20MW apresenta a maior distribuição nos dados analisados.

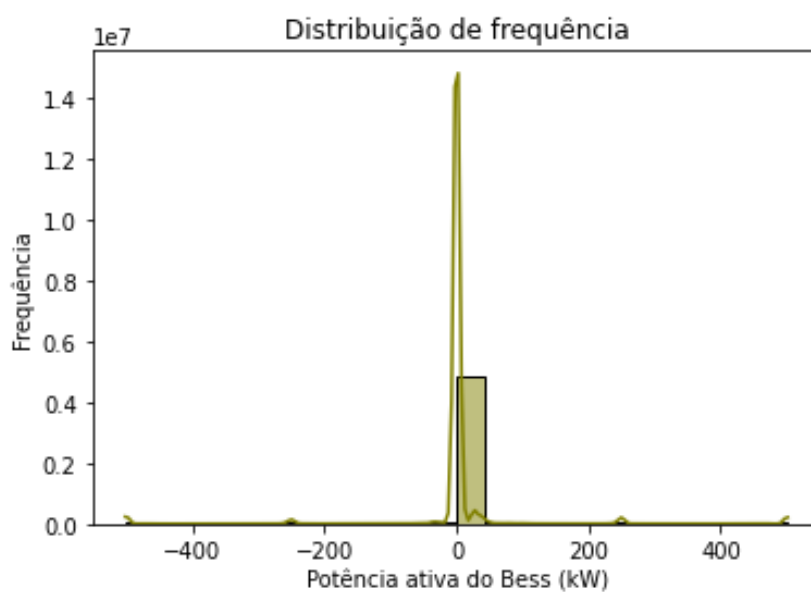
Podemos também verificar a distribuição da potência do BESS, na Figura 10, nela podemos notar que há uma grande incidência entre 0 e 50 KW, os valores de potência negativos são referentes ao momento que o BESS está carregando.

**Figura 9** - Distribuição de Frequência da Potência eólica



Fonte: Compilação do autor.


**Figura 10** - Distribuição da Potência ativa do BESS



Fonte: Compilação do autor.

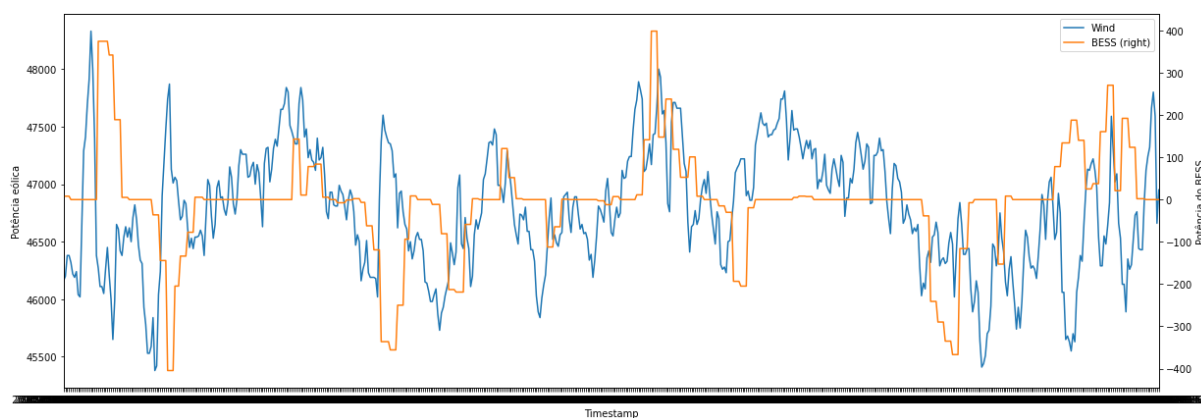
Em se tratando do BESS, na Figura 11, podemos ver o comportamento dele quando está configurado para suavizar a potência eólica, quanto a potência está positiva significa que o BESS está fornecendo energia, no negativo o BESS está absorvendo energia. Na Figura 12, vemos a potência eólica gerada junto com a potência do BESS, nela observamos as flutuações da energia eólica e os momentos que o BESS carrega e descarrega de acordo com as variações da potência eólica.

**Figura 11** - BESS na função suavização de potência - medição em 03-09-2021



Fonte: Compilação do autor.

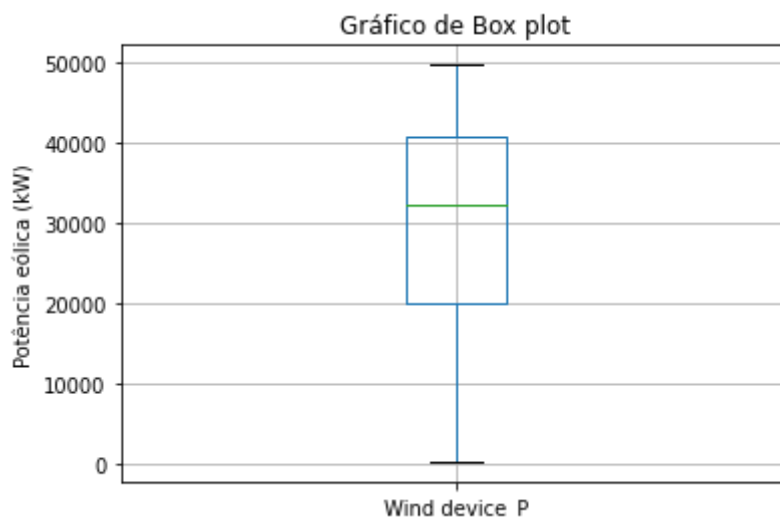
**Figura 12** - Funcionamento do BESS - medição em 03-09-2021



Fonte: Compilação do autor.

Outra forma de analisar graficamente os dados é através do gráfico de box plot, onde podemos confirmar as estáticas básicas do Tabela 1, e é possível observar na Figura 13, a presença de *outliers*, que são considerados atípicos.

**Figura 13** - Gráfico de Box Plot da série completa



Fonte: Compilação do autor.

### 4.3 PRÉ-PROCESSAMENTO

No processo de entendimento dos dados, foi verificado que o mesmo apresentava uma significativa quantidade de registros e uma quantidade pouco expressiva de dados ausentes. Mesmo assim, foi necessário a aplicação de algumas etapas de pré-processamento, para melhorar a análise dos dados e ganhar performance nas avaliações.

Primeiramente, realizou-se a remoção de dados faltantes, depois a remoção de colunas que não seriam utilizadas e a mudança do tipo da coluna para obter uma melhor previsão.

No modelo ARIMA, usamos a função *auto.arima*, para obter os parâmetros  $p$ ,  $d$ ,  $q$  e esta função já realiza a normalização da série. Já no modelo LSTM, a função normalização usada foi a MinMax Scaler, que consiste em dimensionar cada recurso dentro de intervalo entre  $[0,1]$  ou  $[-1,1]$ , quando há números negativos. Esta normalização é calculada com a seguinte equação:

$$Z_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

onde  $x$  são os valores dos dados,  $x_{min}$  retorna o mínimo de valores dos dados e  $x_{max}$  retorna o máximo de valores dos dados da série. Fazendo a normalização os dados serão implantados corretamente no modelo LSTM. Depois disso, nos dois modelos, os dados foram divididos em treino e teste, 70% deles, ou seja, 60.438 amostras, foram usados para o treinamento do modelo, já os 30% restantes, 25.902 amostras, ficaram como teste para avaliar o desempenho do modelo.

A função *early stopping* foi utilizada para identificar as medidas de erro de validação se estabilizarem ou começarem a aumentar, quando isso ocorrer essa função interrompe o treinamento.

A precisão dos modelos, ARIMA e LSTM, é avaliada para se comparar o desempenho de ambos. Esse desempenho é validado pela raiz quadrado médio erro (RMSE) e pelo coeficiente de determinação ( $R^2$ ). O RMSE é calculado usando a seguinte equação:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

onde,  $n$  é o número de observações,  $y_i$  é o valor real e  $\hat{y}_i$  é a previsão do modelo.

Já o coeficiente de determinação é calculado da seguinte forma:

$$R^2 = \frac{SQR}{SQT} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad 0 < R^2 < 1, \quad (3)$$

onde SQR é a soma dos quadrados de regressão e SQT é a soma total dos quadrados, o coeficiente de determinação está em um valor entre 0 e 1.

Depois que os modelos terem sido treinados, os valores de suas previsões foram usados para o controle do despacho do BESS. A simulação foi realizada considerando o uso do BESS de 1 MW para comparar a suavização com os dados reais. Com os dados da suavização de potência, gerados pelos dois modelos de previsão, foi utilizado o indicador MVP para calcular o desempenho da suavização. Foi utilizado MVP5, que significa realizar o cálculo da diferença entre os valores da curva da potência máxima e mínima no intervalo de 5 minutos e com o resultado a potência nominal do gerador onde o BESS está ligado é obtida [3]. Com exemplo, uma potência nominal de geração eólica de 50 MW e uma diferença de potência mínima e máxima de 10 MW no intervalo de 5 minutos, dá um MVP de 20%. Então, quanto menor o valor do MVP, o desempenho da suavização é melhor.

## 5. RESULTADOS

Neste capítulo apresenta os resultados adquiridos com o uso dos modelos de previsão ARIMA e LSTM. Este capítulo foi dividido da seguinte forma: (1) treinamento e avaliação do modelo de previsão, (2) suavização de potência considerando a previsão de potência e avaliação pelo MVP.

### 5.3 TREINAMENTO E AVALIAÇÃO


Para o modelo ARIMA, como já descrito, foi necessário ajustar os parâmetros (p, d, q), estes foram adquiridos pela função *auto.arima* que está dentro do biblioteca *pmdarima* no python. A função *auto.arima* escolhe os melhores parâmetros p, d e q. Os valores encontrados foram ARIMA (5,1,5) , na Tabela 2, é possível ver os valores de acurácia do modelo e na Figura 14 podemos ver as curvas real e prevista pelo modelo ARIMA .

**Tabela 2** - Previsão do modelo ARIMA

<b>ARIMA</b>	<b>RMSE (KW)</b>	<b>R<sup>2</sup></b>
<b>Treino</b>	250,6	0,9815
<b>Teste</b>	395,3	0,9326

Fonte: Compilação do autor

Para o modelo LSTM, a configuração que obteve o melhor resultado foi 2 camadas ocultas com 16 e 4 blocos, a função de ativação é a sigmóide, uma taxa de aprendizagem de 0.001, 24 amostras por lote e com 100 épocas de treinamento. A Tabela 3 pode ser vista as configurações usadas para o modelo LSTM e na Tabela 4 a acurácia do mesmo, na Figura 15, são mostrada a curva real e previsto..

**Figura 14** - Previsão do modelo ARIMA

Fonte: Compilação do autor

**Tabela 3** - Parâmetros do LSTM

Parâmetros	Valores utilizados
Otimizador	Adam
Tamanho da camada	16, 4
Função de ativação	Sigmoid
Taxa de aprendizagem	0,001
Épocas	100
Perda	MSE

Fonte: Compilação do autor


**Tabela 4** - Previsão do modelo LSTM

LSTM	RMSE (KW)	R <sup>2</sup>
Treino	216,94	0,9867
Teste	185,20	0,9945



Fonte: Compilação do autor

**Figura 15** - Previsão do modelo LSTM



Fonte: Compilação do autor

A melhor previsão da potência eólica foi obtida pelo modelo LSTM, como se pode ver nos Tabelas das acurácias dos modelos apresentados, mesmo com as características estocástica da série, que impõe um desafio a previsão, os resultados do modelo LSTM são melhores que o modelo ARIMA, pode-se notar que os modelos acompanham bem o movimento da curva real da potência eólica.

## 5.2 SUAVIZAÇÃO DE POTÊNCIA CONSIDERANDO A PREVISÃO DE POTÊNCIA COM AVALIAÇÃO DO MVP.

Como as previsões feitas nos modelos ARIMA e LSTM, usaremos essa previsão no controle do despacho do BESS, e assim garantir uma melhor suavização da potência eólica. Com as tabelas seguintes informaram os dados da suavização de cada modelo e a avaliação da suavização com o indicador MVP5. Para avaliação do resultado da suavização de potência, são apresentados os dias com os maiores ganhos, Tabela 5, dia 31 de agosto de 2021 e Tabela 6, dia 02 de

setembro de 2021 e Tabela 7, dia 06 de setembro de 2021. Os valores das potências estão em MW.

**Tabela 5** - Suavização de potência medida em 31 de agosto de 2021

Casos	Intervalo de tempo	Potência máxima no intervalo	Potência mínima no intervalo	Valor nominal potência da geração eólica	Valor
Sem BESS	07:35 às 07:40	39,29	32,00	50,4	14,46%
	11:20 às 11:25	43,86	35,99	50,4	16,19%
	17:45 às 17:50	46,05	41,87	50,4	8,29%
Com o BESS	07:35 às 07:40	38,29	32,83	50,4	10,83%
	11:20 às 11:25	42,89	36,99	50,4	11,65%
	17:45 às 17:50	45,69	42,56	50,4	6,21%
Suavização com ARIMA	07:35 às 07:40	37,25	31,56	50,4	11,28%
	11:20 às 11:25	43,23	37,02	50,4	12,32%
	17:45 às 17:50	46,01	42,89	50,4	6,19%
Suavização com LSTM	07:35 às 07:40	38,50	33,95	50,4	9,02%
	11:20 às	42,61	36,76	50,4	11,60%

	11:25				
	17:45 às 17:50	45,94	42,85	50,4	6,13%

Fonte: Compilação do autor

**Tabela 6** - Suavização de potência medida em 02 de setembro de 2021

Casos	Intervalo de tempo	Potência máxima no intervalo	Potência mínima no intervalo	Valor nominal potência da geração eólica	Valor
Sem BESS	09:10 às 09:15	46,85	41,47	50,4	10,67%
	13:05 às 13:10	43,52	31,42	50,4	24,01%
	14:01 às 14:06	39,40	30,19	50,4	18,27%
Com o BESS	09:10 às 09:15	45,92	41,68	50,4	8,41%
	13:05 às 13:10	42,69	31,66	50,4	21,88%
	14:01 às 14:06	38,40	31,19	50,4	14,31%
Suavização com ARIMA	09:10 às 09:15	46,01	41,26	50,4	9,42%
	13:05 às 13:10	43,52	30,99	50,4	24,86%
	14:01 às 14:06	39,20	31,03	50,4	16,21%
Suavização com LSTM	09:10 às 09:15	45,52	42,01	50,4	6,96%

	13:05 às 13:10	42,69	31,66	50,4	20,69%
	14:01 às 14:06	38,40	31,19	50,4	13,55%

Fonte: Compilação do autor

**Tabela 7** - Suavização de potência medida em 06 de setembro de 2021

Casos	Intervalo de tempo	Potência máxima no intervalo	Potência mínima no intervalo	Valor nominal potência da geração eólica	Valor
Sem BESS	10:15 às 10:20	38,70	31,30	50,4	14,68%
	12:27 às 12:32	38,09	26,48	50,4	20,10%
	16:15 às 16:20	44,44	36,67	50,4	15,42%
Com o BESS	10:15 às 10:20	38,28	32,30	50,4	11,87%
	12:27 às 12:32	37,20	27,73	50,4	18,79%
	16:15 às 16:20	43,71	37,67	50,4	11,98%
Suavização com ARIMA	10:15 às 10:20	39,72	32,67	50,4	13,98%
	12:27 às 12:32	37,40	27,67	50,4	19,30%
	16:15 às 16:20	44,69	36,98	50,4	15,29%
Suavização	10:15 às	38,56	33,52	50,4	10,00%

com LSTM	10:20				
	12:27 às 12:32	37,01	27,90	50,4	18,07%
	16:15 às 16:20	43,53	38,05	50,4	10,87%

Fonte: Compilação do autor

Como se pode notar nas tabelas apresentadas os modelos conseguiram suavizar a potência, tendo destaque o modelo com a previsão do LSTM. Levando em consideração o indicador numérico MVP. A melhor redução, no MVP5, com BESS, obtido pelos dados usados neste trabalho foi de 4,54%, mas as reduções são superiores a 1% nos dias estudados. Já com o modelo ARIMA, a melhor redução foi de 3,18% e a pior de -0,85%, neste caso o MVP5 aumentou em relação ao caso sem uso de qualquer método de suavização. Com o modelo LSTM, a melhor redução, nesses dias estudados, foi de 4,72% e a pior, foi de 2,03%, superando o método usado no complexo em todos os casos.

## 6. CONCLUSÃO E TRABALHOS FUTUROS

Neste trabalho realizou-se a análise na influência do uso da previsão da potência eólica para o controle do despacho do BESS. Os dois modelos apresentados, ARIMA e LSTM, mostraram que com uma antecipação da próxima potência é possível ter uma melhor suavização de potência, tendo superado a suavização real, no caso do modelo LSTM. Tendo reduções, no indicador financeiro MVP5, de 4,54% no caso real, de 4,72%, no modelo LSTM e de 3,18% no modelo ARIMA. Mas todos se mostram eficientes na suavização da potência eólica, e assim na redução do indicador MVP5.

Em desenvolvimento e pesquisas futuras, pode-se testar modelos de previsões mais modernos para obtenção de uma melhor previsão. Além disso, testar com outros tamanhos de bateria para assim aumentar a suavização e com isso, pode encontrar um tamanho ideal para o BESS, que concilie economicamente com a capacidade dele suavizar a potência.

## REFERÊNCIAS

- [1] ZHAO, Y. *et al.* Wind Power Fluctuation Smoothing with BESS Considering Ultra-short-term Prediction. *Em: 2019 IEEE INNOVATIVE SMART GRID TECHNOLOGIES - ASIA (ISGT ASIA)*, 2019, Chengdu, China. Anais eletrônicos... Chengdu, China: IEEE, 2019. p. 4025–4030.
- [2] DANTAS, N. K. L. *et al.* Impact Analysis of a Battery Energy Storage System Connected in Parallel to a Wind Farm. *Energies*, 23 jun. 2022. v. 15, n. 13, p. 4586.
- [3] WIND EUROPE. What are the other benefits of wind energy? URL <https://windeurope.org/about-wind/wind-basics/>, [s. l.], 2022.
- [4] GWEC, Global Wind Energy Council. Global Wind Report: Annual market update 2022. URL <http://gwec.net/>, [s. l.], 2022.
- [5] CARVALHO, D. P. A. Dissertação submetida ao Programa de Pós- Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como parte dos requisitos para obtenção do grau de Mestre em Engenharia Elétrica. [s.d.]. p. 102.
- [6] Silva, Pablo Luiz Tabosa da. Sistema de armazenamento de energia utilizando bateria com aplicação para suavização de potência / Pablo Luiz Tabosa da Silva. 2018
- [7] FOSSATI, J. P. *et al.* A method for optimal sizing energy storage systems for microgrids. *Renewable Energy*, maio. 2015. v. 77, p. 539–549.
- [8] BARRA, P. H. A. *et al.* A review on wind power smoothing using high-power energy storage systems. *Renewable and Sustainable Energy Reviews*, mar. 2021. v. 137, p. 110455.
- [9] SIQUEIRA, L. M. S. DE; PENG, W. Control strategy to smooth wind power output using battery energy storage system: A review. *Journal of Energy Storage*, mar. 2021. v. 35, p. 102252.
- [10] WOOLDRIGE, J. M. *Introductory Econometrics: a Modern Approach*. [S.l.: s.n.], 2019.
- [11] G. E. P Box and G. M. Jenkins. *Time series analysis: forecasting and control*, revised Ed. San Francisco: Holden-Day; 1976.
- [12] L. Chen and X. Lai, "Comparison between ARIMA and ANN Models Used in Short-Term Wind Speed Forecasting," 2011 Asia-Pacific Power and Energy

- Engineering Conference, 2011, pp. 1-4, doi: 10.1109/APPEEC.2011.5748446.
- [13] F. A. Eldali, T. M. Hansen, S. Suryanarayanan and E. K. P. Chong, "Employing ARIMA models to improve wind power forecasts: A case study in ERCOT," 2016 North American Power Symposium (NAPS), 2016, pp. 1-6, doi: 10.1109/NAPS.2016.7747861.
- [14] Jing Shi , Xiuli Qu & Songtao Zeng (2011) Short-Term Wind Power Generation Forecasting: Direct Versus Indirect Arima-Based Approaches, *International Journal of Green Energy*, 8:1, 100-112, DOI: 10.1080/15435075.2011.546755
- [15] ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, jan. 2003. v. 50, p. 159–175.
- [16] Hochreiter, S., Schmidhuber, J.: Long short-term memory. *Neural computation* 9, 1735–80 (1997).
- [17] Kumar, Dhananjay; Mathur, H. D.; Bhanot, S.; Bansal, Ramesh C. (2020). Forecasting of solar and wind power using LSTM RNN for load frequency control in isolated microgrid. *International Journal of Modelling and Simulation*, (), 1–13. doi:10.1080/02286203.2020.1767840
- [18] S. Teleke, M. E. Baran, A. Q. Huang, S. Bhattacharya and L. Anderson, "Control Strategies for Battery Energy Storage for Wind Farm Dispatching," in *IEEE Transactions on Energy Conversion*, vol. 24, no. 3, pp. 725-732, Sept. 2009, doi: 10.1109/TEC.2009.2016000.
- [19] Khalid M, Savkin AV. Model predictive control for wind power generation smoothing with controlled battery storage. In: *Proceedings of the 48h IEEE conference on decision and control (CDC) held jointly with 2009 28th Chinese control conference*. 2009, p. 7849–53. <http://dx.doi.org/10.1109/CDC.2009.5400002>.



## APÊNDICE A - CÓDIGO FONTE DO TRABALHO

Nestes apêndices estamos disponibilizando os códigos que foi utilizado para o desenvolvimento deste trabalho. O código completo pode está disponível em: [https://colab.research.google.com/drive/1CypVkEDBHU1DNvcJENsZIXq\\_2pAxZRgO](https://colab.research.google.com/drive/1CypVkEDBHU1DNvcJENsZIXq_2pAxZRgO) e [https://colab.research.google.com/drive/1eIPQWARbQs62L7MVMh1y20iR5N5EtZe\\_#scrollTo=vEbJlwqwnF-M](https://colab.research.google.com/drive/1eIPQWARbQs62L7MVMh1y20iR5N5EtZe_#scrollTo=vEbJlwqwnF-M)

### A.1 Implementação do Algoritmo Suavização\_ARIMA

A Figura 16 parte do código com o modelo ARIMA, em python, utilizado neste trabalho.

**Figura 16** - Código em python do modelo ARIMA

```
from pmdarima.arima.stationarity import ADFTest
from pmdarima.arima import ADFTest
adf_test = ADFTest(alpha=0.05)
adf_test.should_diff(series)

(0.01, False)

series = series.loc['2021-08-21 00:00:00' : '2021-08-21 12:00:00'].copy()

from pmdarima import auto_arima
stepwise_fit = auto_arima(series['Wind'], trace=True, suppress_warnings=True)

Performing stepwise search to minimize aic
ARIMA(2,1,2)(0,0,0)[0] intercept : AIC=583017.466, Time=22.47 sec
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=585661.970, Time=1.19 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=583551.452, Time=3.17 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=583308.984, Time=3.52 sec
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=585659.979, Time=0.55 sec
ARIMA(1,1,2)(0,0,0)[0] intercept : AIC=582990.962, Time=33.16 sec
ARIMA(0,1,2)(0,0,0)[0] intercept : AIC=583309.120, Time=5.87 sec
ARIMA(1,1,1)(0,0,0)[0] intercept : AIC=583369.858, Time=6.49 sec
ARIMA(1,1,3)(0,0,0)[0] intercept : AIC=582913.965, Time=21.18 sec
ARIMA(0,1,3)(0,0,0)[0] intercept : AIC=583013.968, Time=7.56 sec
ARIMA(2,1,3)(0,0,0)[0] intercept : AIC=582025.301, Time=42.24 sec
ARIMA(3,1,3)(0,0,0)[0] intercept : AIC=582011.003, Time=97.03 sec
ARIMA(3,1,2)(0,0,0)[0] intercept : AIC=583030.515, Time=49.18 sec
ARIMA(4,1,3)(0,0,0)[0] intercept : AIC=582016.749, Time=95.77 sec
ARIMA(3,1,4)(0,0,0)[0] intercept : AIC=inf, Time=108.13 sec
ARIMA(2,1,4)(0,0,0)[0] intercept : AIC=582017.486, Time=58.71 sec
ARIMA(4,1,2)(0,0,0)[0] intercept : AIC=583033.940, Time=80.25 sec
ARIMA(4,1,4)(0,0,0)[0] intercept : AIC=581773.186, Time=120.72 sec
ARIMA(5,1,4)(0,0,0)[0] intercept : AIC=581697.563, Time=124.91 sec
ARIMA(5,1,3)(0,0,0)[0] intercept : AIC=581726.181, Time=134.74 sec
ARIMA(5,1,5)(0,0,0)[0] intercept : AIC=581095.795, Time=144.58 sec
ARIMA(4,1,5)(0,0,0)[0] intercept : AIC=581779.118, Time=145.41 sec
ARIMA(5,1,5)(0,0,0)[0] intercept : AIC=581691.227, Time=73.94 sec
ARIMA(4,1,5)(0,0,0)[0] intercept : AIC=581770.509, Time=77.21 sec
ARIMA(5,1,4)(0,0,0)[0] intercept : AIC=581698.933, Time=61.62 sec
ARIMA(4,1,4)(0,0,0)[0] intercept : AIC=581776.263, Time=60.31 sec

Best model: ARIMA(5,1,5)(0,0,0)[0]
Total fit time: 1570.008 seconds

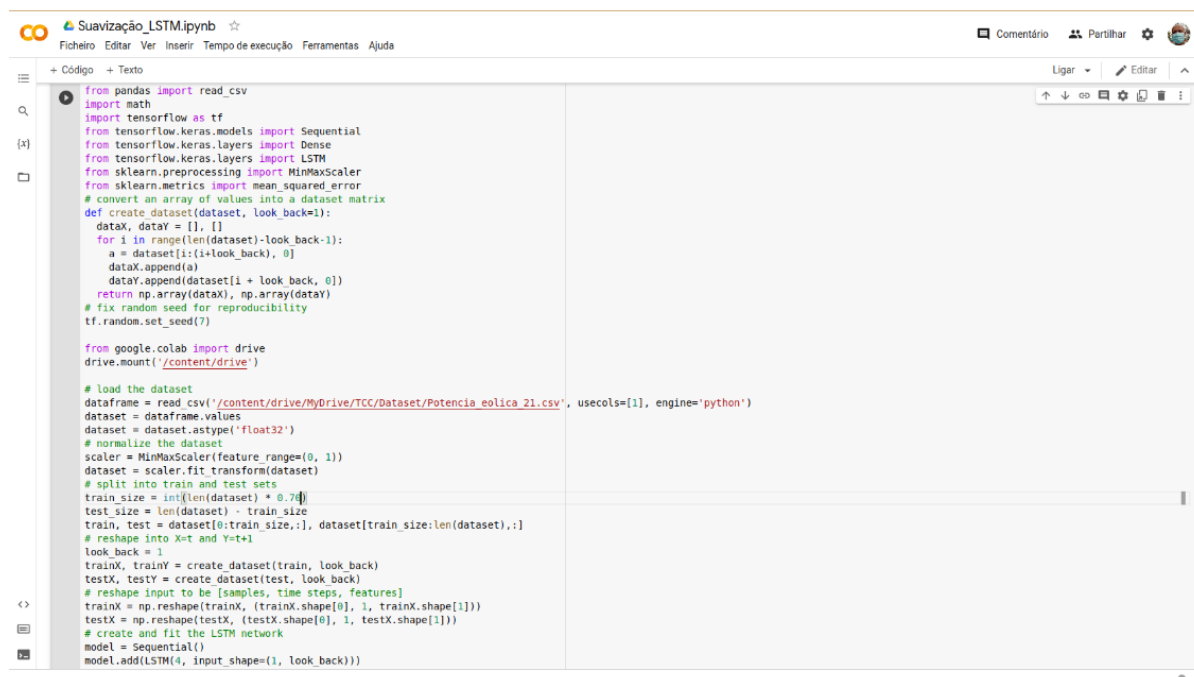
Train = series.loc['2021-08-21 00:00:00' : '2021-08-21 00:50:00'].copy() #Treino
```

Fonte: Compilação do Autor

## A.2 Implementação do Algoritmo Suavização\_LSTM

A Figura 17 parte do código com o modelo LSTM, em python, utilizado neste trabalho.

**Figura 17** - Código em python do modelo LSTM



```
from pandas import read_csv
import math
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.layers import LSTM
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error
# convert an array of values into a dataset matrix
def create_dataset(dataset, look_back=1):
    dataX, dataY = [], []
    for i in range(len(dataset)-look_back-1):
        a = dataset[i:(i+look_back), 0]
        dataX.append(a)
        dataY.append(dataset[i + look_back, 0])
    return np.array(dataX), np.array(dataY)
# fix random seed for reproducibility
tf.random.set_seed(7)

from google.colab import drive
drive.mount('/content/drive')

# load the dataset
dataframe = read_csv('/content/drive/MyDrive/TCC/Dataset/Potencia_eolica_21.csv', usecols=[1], engine='python')
dataset = dataframe.values
dataset = dataset.astype('float32')
# normalize the dataset
scaler = MinMaxScaler(feature_range=(0, 1))
dataset = scaler.fit_transform(dataset)
# split into train and test sets
train_size = int(len(dataset) * 0.75)
test_size = len(dataset) - train_size
train, test = dataset[0:train_size,:], dataset[train_size:len(dataset),:]
# reshape into X-t and Y-t+1
look_back = 1
trainX, trainY = create_dataset(train, look_back)
testX, testY = create_dataset(test, look_back)
# reshape input to be [samples, time steps, features]
trainX = np.reshape(trainX, (trainX.shape[0], 1, trainX.shape[1]))
testX = np.reshape(testX, (testX.shape[0], 1, testX.shape[1]))
# create and fit the LSTM network
model = Sequential()
model.add(LSTM(4, input_shape=(1, look_back)))
```

Fonte: Compilação do Autor