



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE CIÊNCIAS EXATAS E NATURAIS  
FACULDADE DE COMPUTAÇÃO

YANN FABRICIO CARDOSO DE FIGUEIREDO

**PREDIÇÃO DE SÉRIES TEMPORAIS DA VELOCIDADE  
DO VENTO NO BRASIL**

BELÉM/PA  
2021

YANN FABRICIO CARDOSO DE FIGUEIREDO

**PREDIÇÃO DE SÉRIES TEMPORAIS DA VELOCIDADE  
DO VENTO NO BRASIL**

Trabalho de Conclusão de Curso, apresentado como requisito parcial para a obtenção de grau de Bacharel em Ciência da Computação, pela Universidade Federal do Pará.

Orientador: Prof. Dr. Lídio Mauro Lima de Campos  
Universidade Federal do Pará

BELÉM/PA  
2021

YANN FABRICIO CARDOSO DE FIGUEIREDO

**PREDIÇÃO DE SÉRIES TEMPORAIS DA VELOCIDADE  
DO VENTO NO BRASIL**

Trabalho de Conclusão de Curso, apresentado como requisito parcial para a obtenção de grau de Bacharel em Ciência da Computação, pela Universidade Federal do Pará.

DATA DE APROVAÇÃO: 06/10/2021

CONCEITO: Excelente

---

Prof. Dr. Lídio Mauro Lima de Campos  
Orientador - FACOMP/ICEN/UFPA

---

Prof. Dr. Filipe de Oliveira Saraiva  
Membro - FACOMP/ICEN/UFPA

---

Prof. Dr. Vinicius Augusto Carvalho de  
Abreu  
Membro - FACOMP/ICEN/UFPA

BELÉM/PA  
2021

Dedico aos meus pais e a toda a minha família.

## AGRADECIMENTOS

Agradeço aos meus pais e a toda minha família, pelo apoio e incentivo durante minha caminhada na graduação e por toda minha vida.

Agradeço ao meu orientador, Prof.Dr.Lídio Mauro Lima de Campos, pelas orientações, empenho e disponibilidade de tempo.

Agradeço a todos os professores que tive durante a graduação, responsáveis também pelo meu sucesso na caminhada.

Agradeço a todos da direção e secretaria da FACOMP, pela atenção e empenho em garantir informação e excelência durante a graduação.

*“O que todos devemos fazer é nos certificar que estamos usando a inteligência artificial de uma maneira que beneficie a humanidade, e não que a deteriore.” (Tim Cook)*

## RESUMO

Historicamente o Brasil têm sua produção de energia elétrica sustentada por duas principais fontes de geração, a hidroelétrica e a termoeétrica, sendo que a segunda, em muitas das usinas, é utilizada mais quando a primeira tem um período de baixa. Nos últimos anos o Brasil vem aumentando as pesquisas e conseqüentemente o uso de outro tipo de geração de energia, a eólica, sendo esta atualmente a segunda maior fonte de geração de energia no país. A geração de energia eólica possui como vantagem o fato de ser um tipo de energia limpa, ajudando assim na preservação do meio ambiente. Apesar de ser benéfica e mais barata que as demais fontes de energia citadas, a geração por turbinas eólicas enfrenta um problema de imprevisibilidade quanto ao recurso principal, o vento. Surge então uma necessidade cada vez maior em pesquisar formas de prever a disponibilidade do vento com base em certas variáveis, como a velocidade do vento. Este trabalho têm o objetivo de desenvolver modelos de previsão da velocidade do vento, usando para isto técnicas de inteligência artificial aplicadas juntamente de Redes Neurais Artificiais Profundas (RNAPs) através das arquiteturas de rede direta (*Deep Feedforward*) e recorrente (LSTM), para assim ter uma noção mais completa da disponibilidade de energia eólica nas regiões estudadas. A pesquisa foi feita com base em variáveis meteorológicas dos repositórios do INMET (Instituto Nacional de Meteorologia), no caso da estação eólica de Macau (RN), e do SONDA (Sistema de Organização Nacional de Dados Ambientais), no caso da estação eólica de Petrolina (PE). Ambas bases de dados contém informações do período de 1 de janeiro de 2004 a 31 de maio de 2017 na base com dados em formato de dias, 1 de junho de 2016 a 31 de maio de 2017 na base com dados em formato de horas, e 27 de maio de 2017 a 31 de maio de 2017 com a base em formato de minutos. Para um único modelo de previsão específico, com a base em formato de dias, a série temporal vai de 1 de janeiro de 2015 a 31 de julho de 2018. No total foram gerados 15 modelos, criados a partir da aplicação de *Ensemble Learning Methods*, no caso *voting* e *bagging*, em diversos submodelos criados para cada base e prazo de dados. O melhor modelo foi usando a base de Petrolina de curto prazo, com registros disponibilizados no formato de horas, obtido ao ser usado o método *bagging* para criar o modelo final. O melhor modelo obteve MAE de 0.0036, MAPE de 0.0012% e RMSE de 0.0143.

**Palavras-chave:** Energia eólica. Previsão. Redes Neurais Artificiais. Rede *Deep Feedforward*. Rede recorrente (LSTM). Velocidade do vento. Séries temporais.

## ABSTRACT

Historically, Brazil has its electricity production sustained by two main generation sources, hydroelectric and thermoelectric, and the second, in many of the plants, is used more when the first has a low period. In recent years, Brazil has been increasing research and consequently the use of another type of energy generation, wind, which is currently the second largest source of energy generation in the country. The advantage of wind power generation is that it is a type of clean energy, thus helping to preserve the environment. Despite being beneficial and cheaper than the other energy sources mentioned, the generation by wind turbines faces a problem of unpredictability regarding the main resource, the wind. An increasing need then arises to research ways to predict wind availability based on certain variables, such as wind speed. This work aims to develop wind speed prediction models, using artificial intelligence techniques applied together with Deep Artificial Neural Networks (RNAPs) through direct (Deep Feedforward) and recurrent (LSTM) network architectures), in order to have a more complete notion of the availability of wind energy in the studied regions. The research was based on meteorological variables from the INMET (National Institute of Meteorology) repositories, in the case of the Macau (RN), and SONDA (National Environmental Data Organization) repositories, in the case of the Macau wind farm. Petrolina (PE). Both databases contain information for the period from January 1, 2004 to May 31, 2017 in the database in day format, June 1, 2016 to May 31, 2017 in the database in time format, and May 27, 2017 to May 31, 2017 with the base in minute format. For a single specific prediction model, based on days format, the time series runs from January 1, 2015 to July 31, 2018. In total, 15 models were generated, created from the application of Ensemble Learning Methods, in the case of voting and bagging, in various sub-models created for each database and data term. The best model was using the short-term Petrolina base, with records available in the format of hours, obtained by using the bagging method to create the final model. The best model obtained MAE of 0.0036, MAPE of 0.0012% and RMSE of 0.0143.

**Keywords:** Wind energy. Prediction. Artificial Neural Networks. Deep Feedforward network. Recurring network (LSTM). Wind speed. Time series.

## LISTA DE FIGURAS

Figura 1.1 – Matriz elétrica do Brasil em 2020. . . . .	14
Figura 1.2 – Aumento da capacidade de produção de energia em 2020. . . . .	15
Figura 3.1 – Formação e circulação do vento. . . . .	23
Figura 3.2 – Evolução da energia eólica no Brasil. . . . .	24
Figura 3.3 – Funcionamento de um aerogerador para produção de energia. . . . .	25
Figura 3.4 – Etapas principais do processo KDD. . . . .	27
Figura 3.5 – Estrutura básica de uma RNA. . . . .	32
Figura 3.6 – RNA <i>perceptron</i> multicamadas. . . . .	32
Figura 3.7 – RNA recorrente. . . . .	34
Figura 3.8 – Estrutura de RNA recorrente e LSTM. . . . .	35
Figura 3.9 – Estrutura de um portão na rede LSTM. . . . .	36
Figura 4.1 – Etapas de pesquisa. . . . .	38
Figura 4.2 – Comportamento das séries temporais que compõe o banco de dados utilizado. . . . .	43
Figura 4.3 – Localização da estação eólica de Petrolina/PE. . . . .	44
Figura 4.4 – Localização da estação eólica de Macau/RN. . . . .	44
Figura 4.5 – Exemplo de validação dos dados da SONDA. . . . .	45
Figura 4.6 – Diagrama do processo de predição de série temporal. . . . .	46
Figura 4.7 – Funcionamento do <i>voting</i> . . . . .	48
Figura 4.8 – Funcionamento do <i>bagging</i> . . . . .	49
Figura 5.1 – Modelo LSTM do modelo 1 (segundo a tabela 5.2) . . . . .	54
Figura 5.2 – Modelo DFF do modelo 1 (segundo a tabela 5.2) . . . . .	55
Figura 5.3 – Submodelo 2 do modelo 5 (segundo a tabela 5.4) . . . . .	57
Figura 5.4 – Submodelo 5b5-LSTM do modelo 5 (segundo a tabela A.10) . . . . .	57
Figura 5.5 – Modelo 10j-DFF do modelo 10 (segundo a tabela A.20) . . . . .	60

## LISTA DE TABELAS

Tabela 3.1 – Classificação das escalas de tempo para previsão do vento . . . . .	30
Tabela 4.1 – Período, grandeza e quantidade de registros das bases de dados . . . . .	41
Tabela 4.2 – Atributos das variáveis selecionadas do banco de dados . . . . .	42
Tabela 4.3 – Correlação entre as séries temporais . . . . .	42
Tabela 4.4 – Localização das estações eólicas. . . . .	43
Tabela 5.1 – Modelos finais . . . . .	52
Tabela 5.2 – Melhores hiper parâmetros dos modelos UCP . . . . .	53
Tabela 5.3 – Resultados dos erros para predição multipassos Ultra Curto Prazo (Minutos) . . . . .	54
Tabela 5.4 – Melhores hiper parâmetros dos modelos CP . . . . .	56
Tabela 5.5 – Resultados dos erros para predição multipassos Curto Prazo (Horas) . . . . .	56
Tabela 5.6 – Melhores hiper parâmetros dos modelos MP . . . . .	59
Tabela 5.7 – Resultados dos erros para predição multipassos Médio Prazo (Dias) . . . . .	59
Tabela A.1 – Hiper parâmetros das simulações do modelo 1 . . . . .	68
Tabela A.2 – Métricas das simulações do modelo 1 . . . . .	69
Tabela A.3 – Hiper parâmetros das simulações do modelo 2 . . . . .	69
Tabela A.4 – Métricas das simulações do modelo 2 . . . . .	70
Tabela A.5 – Hiper parâmetros das simulações do modelo 3 . . . . .	70
Tabela A.6 – Métricas das simulações do modelo 3 . . . . .	71
Tabela A.7 – Hiper parâmetros das simulações do modelo 4 . . . . .	71
Tabela A.8 – Métricas das simulações do modelo 4 . . . . .	72
Tabela A.9 – Hiper parâmetros das simulações do modelo 5 . . . . .	72
Tabela A.10 – Métricas das simulações do modelo 5 . . . . .	73
Tabela A.11 – Hiper parâmetros das simulações do modelo 6 . . . . .	73
Tabela A.12 – Métricas das simulações do modelo 6 . . . . .	74
Tabela A.13 – Hiper parâmetros das simulações do modelo 7 . . . . .	74
Tabela A.14 – Métricas das simulações do modelo 7 . . . . .	75
Tabela A.15 – Hiper parâmetros das simulações do modelo 8 . . . . .	75
Tabela A.16 – Métricas das simulações do modelo 8 . . . . .	76
Tabela A.17 – Hiper parâmetros das simulações do modelo 9 . . . . .	76
Tabela A.18 – Métricas das simulações do modelo 9 . . . . .	77
Tabela A.19 – Hiper parâmetros das simulações do modelo 10 . . . . .	77
Tabela A.20 – Métricas das simulações do modelo 10 . . . . .	78
Tabela A.21 – Hiper parâmetros das simulações do modelo 11 . . . . .	78
Tabela A.22 – Métricas das simulações do modelo 11 . . . . .	79
Tabela A.23 – Hiper parâmetros das simulações do modelo 12 . . . . .	79
Tabela A.24 – Métricas das simulações do modelo 12 . . . . .	80
Tabela A.25 – Hiper parâmetros das simulações do modelo 13 . . . . .	80
Tabela A.26 – Métricas das simulações do modelo 13 . . . . .	81
Tabela A.27 – Hiper parâmetros das simulações do modelo 14 . . . . .	81
Tabela A.28 – Métricas das simulações do modelo 14 . . . . .	82
Tabela A.29 – Hiper parâmetros das simulações do modelo 15 . . . . .	82
Tabela A.30 – Métricas das simulações do modelo 15 . . . . .	83

## LISTA DE SIGLAS

RNA	Rede Neural Artificial
RNAP	Rede Neural Artificial Profunda
LSTM	Long Short Term Memory
DFD	Deep Feedforward
FTDNN	Focused Time Delay Neural Network
NARX	Nonlinear Autoregressive Network with Exogenous Inputs
KDD	Knowledge Discovery in Databases
MAE	Mean Absolute Error
MSE	Mean Squared Error
MAPE	Mean Absolute Percentage Error
RMSE	Root Mean Squared Error
VMED	Velocidade média
MLP	Multilayer Perceptron
KNN	K Nearest Neighbor
ABEEólica	Associação Brasileira de Energia Eólica
ANEEL	Agência Nacional de Energia Elétrica
FUNCEME	Fundação Cearense de Meteorologia e Recursos Hídricos
TIC	Coefficiente de Desigualdade de Theil
AR	Auto-Regressiva
ARIMA	Autoregressive Integrated Moving Average
ARMA	Auto-Regressivo de Médias Móveis
SARIMA	Seasonal Autoregressive Integrated Moving Average
AEI	Alternative Energy Institute
SONDA	Sistema de Organização Nacional de Dados Ambientais
INMET	Instituto Nacional de Meteorologia
REN	Renewables Now
BTT	Backpropagation Through Time

## LISTA DE SÍMBOLOS

$\rho$	Letra grega Rô
$\phi$	Letra grega Phi
$\Theta$	Letra grega Teta
$\sigma$	Letra grega sigma minúscula
$\Sigma$	Letra grega sigma maiúscula

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	Motivação	14
1.2	Justificativa	16
1.3	Contribuições e relevância do tema	18
1.4	Delimitação da pesquisa	18
1.5	Objetivos	18
1.5.1	Objetivo geral	18
1.5.2	Objetivos específicos	19
1.6	Metodologia	19
1.7	Estrutura do trabalho	20
<b>2</b>	<b>REVISÃO DE LITERATURA</b>	<b>21</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>23</b>
<b>3.1</b>	<b>Energia Eólica</b>	<b>23</b>
3.1.1	Conceito e Características	23
3.1.2	Geração de Energia Eólica	25
<b>3.2</b>	<b>Processo de descoberta de conhecimento em banco de dados (KDD)</b>	<b>26</b>
3.2.1	Etapas do KDD	27
3.2.1.1	Etapa de seleção de dados	27
3.2.1.2	Etapa de pré-processamento	28
3.2.1.3	Etapa de transformação de dados	28
3.2.1.4	Etapa de <i>data mining</i>	28
3.2.1.5	Etapa de interpretação e avaliação	28
<b>3.3</b>	<b>Séries temporais</b>	<b>29</b>
<b>3.4</b>	<b>Métodos para predição de séries temporais</b>	<b>29</b>
3.4.1	Modelos Autorregressivos Integrados de Médias Móveis (ARIMA)	30
3.4.2	Modelo auto-regressivo integrado sazonal de médias móveis (SARIMA)	31
3.4.3	Redes Neurais Artificiais <i>Feedforward</i> e Profundas	31
3.4.4	Redes Neurais Artificiais LSTM	34
<b>4</b>	<b>MATERIAL E MÉTODOS</b>	<b>38</b>
<b>4.1</b>	<b>Introdução</b>	<b>38</b>
<b>4.2</b>	<b>Etapas da pesquisa</b>	<b>38</b>
<b>4.3</b>	<b>Banco de dados e Pré-processamento de dados</b>	<b>40</b>
4.3.1	Pré-processamento de dados	40
4.3.2	Banco de dados	41
<b>4.4</b>	<b>Modelo de previsão proposto</b>	<b>45</b>
<b>4.5</b>	<b>Arquitetura de computador utilizada e esforço computacional</b>	<b>47</b>
<b>4.6</b>	<b>Experimentos e Validação - Métodos de construção de modelos (<i>Ensemble Learning Methods</i>)</b>	<b>47</b>
4.6.1	<i>Voting</i>	47
4.6.2	<i>Bagging</i>	48
<b>4.7</b>	<b>Métricas utilizadas</b>	<b>49</b>

<b>5</b>	<b>RESULTADOS</b> . . . . .	<b>51</b>
<b>5.1</b>	<b>Introdução</b> . . . . .	<b>51</b>
<b>5.2</b>	<b>Apresentação dos modelos propostos e Análises dos resultados</b>	<b>51</b>
5.2.1	Modelos de Ultra Curto Prazo . . . . .	52
5.2.1.1	Predição a ultra curto prazo - UCP (minutos) . . . . .	53
5.2.2	Modelos de Curto Prazo . . . . .	55
5.2.2.1	Predição a curto prazo - CP (horas) . . . . .	56
5.2.3	Modelos de Médio Prazo . . . . .	58
5.2.3.1	Predição a médio prazo - MP (dias) . . . . .	59
<b>6</b>	<b>CONCLUSÃO</b> . . . . .	<b>61</b>
6.0.1	Sugestões para trabalhos futuros . . . . .	62
	<b>REFERÊNCIAS</b> . . . . .	<b>63</b>
	 <b>APÊNDICES</b>	 <b>67</b>
	<b>APÊNDICE A – RESULTADOS DE TODAS AS SIMULAÇÕES REALIZADAS</b> . . . . .	<b>68</b>


# 1 INTRODUÇÃO

## 1.1 Motivação

Segundo (ABEEÓLICA, 2020) a matriz elétrica brasileira tem como principal tipo de produção a energia hidrelétrica, sendo esta, em 2020, responsável por 58.8% da geração elétrica no Brasil. Há uma necessidade cada vez maior de buscar fontes mais limpas de energia como uma alternativa a hidrelétrica, pois atualmente a maior parte da capacidade de geração de energia a partir desta fonte está em terras indígenas e centros de conservação, onde não é possível a construção de novas usinas. Segundo (GLOBO, 2020), o governo federal prevê um cenário onde cerca de 10 usinas hidrelétricas serão construídas até 2029, porém todas de médio e pequeno porte, o que evidencia uma queda cada vez maior da presença desse tipo de geração, enquanto outras fontes de energia mais limpas tendem a crescer, como é o caso da eólica e solar.

É citado em (ABEEÓLICA, 2020) que a produção de energia eólica cresceu muito nos últimos anos, tendo passado de uma capacidade de produção de 1GW em 2010 para 17.75GW em 2020, ou seja, um crescimento de cerca de 17 vezes em uma década. Segundo a ABEEólica (Associação Brasileira de Energia Eólica) a maior parte da produção encontra-se no nordeste (litoral) e sul, por conta da capacidade de ventos constantes e regulares. Especificamente, a Bahia é hoje a maior produtora de energia eólica no Brasil, tendo mais de 160 parques eólicos e mais de 400 aerogeradores. Esse aumento da produção de energia eólica fez com que esse tipo de fonte limpa e renovável de energia seja hoje a segunda maior na matriz elétrica brasileira, ocupando mais de 10% da capacidade de produção. Segundo a ABBEólica, em 2020, o Brasil ficou em 7º no ranking dos países com mais capacidade de geração de energia eólica implementada, e se for considerada apenas a nova capacidade de produção instalada em 2020, o Brasil ocupa o 3º lugar com 2.3GW, atrás apenas de China e Estados Unidos. A Figura 1.1 apresenta a matriz elétrica do Brasil segundo o boletim publicado em 2020 pela ABEEólica, e evidencia a capacidade de geração de cerca de 17.75GW de energia eólica no ano de 2020. (ABEEÓLICA, 2020)

Figura 1.1 – Matriz elétrica do Brasil em 2020.




Fonte: (ABEEÓLICA, 2020)

Por não agredir o meio ambiente, como as usinas hidrelétricas e termoelétricas, os parques eólicos tem sido uma alternativa limpa e renovável de gerar energia cada vez mais requerida, portanto estando em constante aumento de capacidade, como mostra a Figura 1.2 que ilustra o aumento da capacidade durante o ano de 2020, segundo a ABEEólica.

Apesar de ter o benefício de ser sustentável e barata, a energia eólica enfrenta um grande problema, que é a imprevisibilidade quanto ao recurso principal, o vento. É importante ressaltar que a energia eólica provém um tipo de fonte considerada intermitente, justamente por conta da imprevisibilidade citada do recurso eólico. Esse tipo de geração de energia depende das condições meteorológicas para garantir a produção, e isso desperta cada vez a necessidade de pesquisas para encontrar maneiras de prever se será possível gerar energia em determinada hora, dia, mês e assim sucessivamente. Uma das principais variáveis que regem a capacidade de produção de energia eólica é a velocidade do vento, portanto poder prever essa variável ajudaria a entender o comportamento do vento em determinado momento, e assim garantir mais confiabilidade desse tipo de energia na matriz elétrica do Brasil.

Figura 1.2 – Aumento da capacidade de produção de energia em 2020.



Fonte: ABEEólica (Associação Brasileira de Energia Eólica)/ANEEL (Agência Nacional de Energia Elétrica)

A geração de energia eólica e as formas de prever quando pode ser possível contar com esse tipo de produção têm crescido muito nos últimos anos, o que acarretou em diversos estudos, como de (FARIAS, 2020), propondo alternativas para ajudar a prever a disponibilidade do recurso eólico. Inclusive diversos estudos, como de (FUJISE, 2018), propõe uma ideia bem semelhante a apresentada neste trabalho, prever séries temporais da velocidade do vento através do uso de RNA (Rede Neural Artificial) para ajudar a compreender o comportamento do vento e conseqüentemente calcular quando esse recurso estará disponível para ser utilizado na produção de energia elétrica.

Segundo (ROSSI, 2013) as técnicas de inteligência artificial são bastante utilizadas em problemas mais complexos. O destaque das redes neurais, especialmente as Redes

Neurais Artificiais Profundas (RNAPs) e redes recorrentes (como a LSTM), como uma dessas técnicas, vem crescendo muito, pois elas estão sendo utilizadas em muitos trabalhos e pesquisas com problemas de predição, como o de (ALENCAR, 2018) e (OLIVEIRA, 2020), e isso desperta o interesse em estudos para o uso de RNA, Redes Neurais Artificiais Profundas (RNAPs) e redes recorrentes (como a LSTM), na predição de séries temporais, sobretudo por conta da sua grande vantagem de modelagem não linear. Com o passar dos anos, pesquisadores, como (FERRAZ et al., 2017) e (SANTOS; SPANCERSKI, 2021), estão dando mais atenção para redes neurais para predizer séries temporais relacionadas a velocidade do vento, deixando de usar tanto as tradicionais técnicas estatísticas de previsão, como o modelo ARIMA, por exemplo.

Segundo (MAGALHAES; CHAGAS, 2019), as ferramentas mais convenientemente utilizadas para predição são aquelas baseadas em modelos estatísticos, como ARMA (*Autoregressive Moving Average*) e ARIMA (*Autoregressive Integrated Moving Average*). Apesar dos modelos estatísticos serem ótimas soluções a serem adotadas, o cenário tem mudado por conta de resultados positivos de predição usando técnicas baseadas em modelos de inteligência artificial, como KNN (*K-Nearest Neighbors*) e RNA (Redes Neurais Artificiais), que inclusive conta com diversas arquiteturas como a *Deep Feedforward* e a LSTM (*Long Short Term Memory*). Os resultados positivos, como o do modelo de rede *feedforward* do trabalho de (FERRAZ et al., 2017), estão diretamente ligados com o fato de as RNAs trabalharem com não linearidades existentes nos sistemas reais. Mesmo com os resultados bons em pesquisas com RNAs, ainda são constatadas desvantagens presentes na técnica, assim como em qualquer outra. Uma maneira encontrada por diversos autores para reduzir os impactos dessas desvantagens de técnicas de predição foi fazer uma combinação de técnicas, ou seja, utilizar modelos híbridos para tarefas de predição, como fez (ALENCAR, 2018) em sua pesquisa.

As Redes Neurais Artificiais Profundas e recorrentes tem sido amplamente utilizadas com sucesso em muitos problemas de predição de séries temporais, como nos trabalhos de (OLIVEIRA, 2020), (YONGQIAN et al., 2017) e (SANTOS; SPANCERSKI, 2021). Em razão das bem sucedidas técnicas citadas de RNAPs e recorrentes terem sido eficientes na predição, isso motivou o uso das redes RNAPs para predição da velocidade do vento neste trabalho, especificamente as de arquitetura *Deep Feedforward* e LSTM (rede recorrente).

## 1.2 Justificativa

A energia hidrelétrica está com sua capacidade de geração estagnada, devido aos locais ainda aptos a terem usinas possuírem muita importância ambiental. A energia termoelétrica requer um custo de operação muito alto, o que acaba também impactando no aumento do custo de tarifa. Tendo essas questões em vista, a produção de energia eólica têm sido cada vez mais requerida, por possuir custo de operação baixo, além de possuir muito potencial de expansão no Brasil, principalmente no litoral nordestino. Por esta razão, o governo federal, diante de dados da ABEEólica, estima que a capacidade de produção de energia eólica atinja cerca de 40GW em 10 anos, um aumento de praticamente 160% em comparação com os 15.4GW do fim de 2019, quando haviam no Brasil 613 parques eólicos e 7536 aerogeradores em operação. (AZEVEDO, 2020)

Segundo (AZEVEDO, 2020), em um cenário mais próximo, a ABEEólica estima que em 2023 haja 21.5GW de capacidade para gerar energia eólica no Brasil, e esse crescimento leva em conta também a expansão de exploração do recurso eólico fora dos tradicionais parques eólicos em terra, ou seja, no mar aproveitando os ventos presentes nesse tipo de ambiente. Com todas essas projeções mostrando um aumento significativo

da capacidade de produção de energia eólica, fica evidente a necessidade de desenvolver soluções para ajudar a fazer esse tipo de energia ser mais confiável e segura dentro da matriz elétrica brasileira. Dentre as soluções possíveis, desenvolver modelos para realizar a predição da velocidade do vento, umas das principais variáveis que regem o comportamento do vento, seria uma excelente alternativa e de muita relevância para contribuir com avanços na área, como já foi feito por diversos trabalhos realizados.

Diante desse cenário de necessidade por aumento nos estudos sobre recursos eólicos para gerar energia, faz-se necessário adotar outras possíveis soluções além das já utilizadas na literatura, que contém, principalmente, técnicas de previsão por meios estatísticos, tal como o modelo SARIMA. As redes neurais, tanto utilizadas individualmente quanto em modelos híbridos, como o de (ALENCAR, 2018), surgiram como uma alternativa que vem dando resultados muito bons, como pode ser visto, por exemplo, na tese de (OLIVEIRA, 2020), onde é proposta uma abordagem de um modelo autorregressivo linear e uma rede neural artificial para a predição probabilística da amplitude do vento no período de curtíssimo prazo.

Nesse sentido, é necessário o desenvolvimento de métodos precisos para realizar a predição da velocidade do vento para geração de energia eólica, possibilitando uma inserção mais segura dessa fonte de energia na matriz energética brasileira. Esses métodos seriam baseados em Redes Neurais Artificiais Profundas, por conta do sucesso e eficiência que as técnicas de RNAP tiveram ao longo do tempo, como no trabalho de (RAMALHO; DIAS, 2009), onde é utilizada uma estrutura de rede neural dinâmica capaz de efetuar a estimativa da velocidade do vento no dia seguinte.

Segundo (RAMALHO; DIAS, 2009), para que sejam instalados parques eólicos é preciso uma série de estudos prévios para fazer uma avaliação da região onde se planeja instalar o parque. Na avaliação são considerados diversos fatores, como se a região possui condições mínimas viáveis para suprir um parque eólico. O estudo é realizado através da análise de séries temporais dos dados coletados, entretanto é bem comum que haja descontinuidade na medição ou ainda dados insuficientes para fazer um estudo sobre o comportamento futuro. Os procedimentos e processos para fazer a coleta de dados, assim como os estudos feitos, exige tempo e bastante investimento financeiro. Diante desse cenário surge a importância da utilização de técnicas de inteligência artificial, como Redes Neurais Artificiais Profundas (RNAP), para simular variáveis ambientais de uma localidade onde se deseja instalar um parque eólico. Com uma RNAP é possível fazer uma regressão não linear com o intuito de prever determinado atributo a partir de informações históricas.

Na literatura é possível encontrar diversas técnicas utilizadas para predição de séries temporais, inclusive de séries envolvendo atributos para previsão da velocidade do vento. Uma das mais utilizadas é a RNA, no caso deste trabalho a *Deep Feedforward* e a LSTM (rede recorrente). Na pesquisa de (ALENCAR, 2018) são usados modelos híbridos para superar desvantagens encontradas ao utilizar as técnicas separadamente, no caso foram utilizados três modelos híbridos, um com SARIMA mais Wavelet, um com SARIMA mais RNA e outro com SARIMA mais duas redes neurais.

Segundo (ALENCAR, 2018), o modelo SARIMA é bom pois contempla as séries que apresentam autocorrelação sazonal, e conta com quatro etapas no seu processo: pré-tratamento da amostra, identificação e estimativa, diagnóstico e otimização, e por último predição. Outra técnica usada na predição de séries temporais é a KNN (*K-Nearest Neighbors*), que segundo (AZANK, 2019) é uma técnica com a vantagem de não ser paramétrica, ou seja, não assume nada do *dataset*, sendo muito boa para usar com bases de dados que não se têm muitas informações sobre. Outro aspecto positivo do KNN é o fato de ser uma técnica bem versátil para *datasets* não lineares, o que a torna ótima para

problemas de separação de características em bases de dados menores.

A técnica aplicada neste trabalho é a de modelo de inteligência computacional, especificamente RNA, e segundo (FREIRE, 2014) são mais simples que outras técnicas, mais rápidas na predição e mais recomendadas para predições de curto prazo, que é o caso deste trabalho que trata de bases de dados formadas com o horizonte de ultra curto, curto e médio prazo. Por conta da variação de horizontes foram selecionadas as arquiteturas *Deep Feedforward*, que possui desempenho melhor quando se trata de poucos dados na base, e a LSTM, que é justamente o oposto por se sair melhor quando a base de dados possui uma grande quantidade de registros.

### 1.3 Contribuições e relevância do tema

Na literatura existem inúmeros projetos e trabalhos que aplicam técnicas relacionadas a séries temporais para predição da velocidade do vento, como o de (OLIVEIRA, 2020) e (FERRAZ et al., 2017), e conseqüentemente para capacidade de produção de energia eólica. Especificamente Redes Neurais Artificiais, como *Deep Feedforward* e a LSTM, ganham cada vez mais atenção de pesquisadores para realizar esse tipo de tarefa de predição, tanto em modelos híbridos, como no trabalho de (ALENCAR, 2018), quanto em modelos unicamente de RNA, como *Deep Feedforward* e a LSTM usados neste trabalho. Apesar desse crescimento de pesquisas com RNA em tarefas de predição, ainda se faz necessário novos trabalhos abordando esse direcionamento de pesquisa, para assim contribuir ainda mais para um cenário de produção de energia eólica mais estável e previsível e conseqüentemente para deixar a participação desse tipo de produção mais confiável na matriz elétrica brasileira e mundial.

### 1.4 Delimitação da pesquisa

As delimitações desta pesquisa se resumem ao problema da predição da velocidade do vento, usando para isso diversos modelos baseados em Redes Neurais Artificiais Profundas, especificamente redes *Deep Feedforward* e a LSTM. Diversos modelos foram desenvolvidos para serem comparados e conseqüentemente para que haja uma seleção do modelo mais adequado para o problema abordado no trabalho.

Os modelos desenvolvidos na pesquisa utilizam as arquiteturas de rede *Deep Feedforward* e a LSTM, sendo aplicáveis para qualquer base de dados de parque eólico, desde que possuam as variáveis semelhantes. Pode ainda ser adaptado para qualquer cenário temporal, como feito durante as simulações realizadas na pesquisa.

Neste estudo foram utilizados os dados meteorológicos de duas estações eólicas do nordeste brasileiro, especificamente das estações de Petrolina-PE e Macau-RN. Ambas bases de dados contém informações do período de 1 de janeiro de 2004 a 31 de maio de 2017 distribuídas em bases de dias, minutos e horas, porém para Macau/RN a base em minutos é inexistente.

### 1.5 Objetivos

#### 1.5.1 Objetivo geral

Desenvolver um modelo para prever a velocidade do vento para geração de energia eólica, utilizando para isso métodos de inteligência artificial, mais especificamente

RNAP (Rede Neural Artificial Profunda) com arquiteturas *Deep Feedforward* e recorrente (LSTM).

### 1.5.2 Objetivos específicos

- Desenvolver um modelo para prever a velocidade do vento a ultra curto, curto e médio prazo, e assim ter conhecimento da possibilidade de geração de energia eólica, utilizando para isso RNAPs (Rede Neural Artificial Profundas);
- Comparar os resultados das simulações feitas com os modelos de RNA direta e recorrente (LSTM) desenvolvidos;
- Selecionar o modelo com o melhor desempenho;
- Programar e aplicar o modelo de previsão da velocidade do vento.

## 1.6 Metodologia

Após profunda pesquisa na literatura, foi definido o problema abordado neste trabalho, assim como os métodos viáveis para contribuir com uma solução em determinada escala de tempo. Com base no trabalho de (ALENCAR, 2018), foram identificados os diferentes passos de previsão os quais foram utilizados nas simulações dos modelos, que no caso são previsões a ultra curto prazo, curto prazo e médio prazo de 20 passos a frente. Os dados usados neste trabalho foram coletados dos repositórios do SONDA (Sistema de Organização Nacional de Meteorologia) e INMET (Instituto Nacional de Meteorologia), sendo bases de dados das estações eólicas de Petrolina/PE e Macau/RN, respectivamente. Adicionalmente foram identificados os modelos a usar, bem como foi feita a implementação dos algoritmos para redes *Deep Feedforward* e LSTM. Para a implementação dos algoritmos foram utilizadas bibliotecas como *tensorflow (keras)*, *numpy*, *pandas*, *matplotlib*, *keras tuner*, entre outras detalhadas na seção 4.2.

Os dados coletados passaram por algumas etapas de pré-processamento, como normalização, por exemplo. A principal formatação que precisou ser feita foi a adaptação dos registros da base de dados de Petrolina/PE, pois no repositório só havia disponível uma base com dados na escala de minutos, onde para obter as demais bases foi preciso fazer uma média de 60 registros da base de minutos para obter cada registro para uma base de horas, e foi preciso fazer uma média de 1440 registros da base de minutos para obter cada registro da base de dias. Os detalhes dos pré-processamentos e formatações estão na seção 4.3. No caso da base de Macau/RN, no repositório já haviam prontas bases de dados na escala de dia e hora, porém não existe uma base em minutos, portanto para essa base não foram desenvolvidos modelos para previsão a ultra curto prazo.

Após a coleta de dados, pré-processamento e implementação dos algoritmos de cada rede, foram feitas as simulações de cada modelo para previsão da velocidade do vento 20 passos a frente, ou seja, 20 minutos, horas ou dias a frente. Técnicas de *Ensemble Learning Methods*, especificamente *voting* e *bagging*, descritas na seção 4.6, foram utilizadas para combinar os modelos aplicados e gerar versões finais mais otimizadas. Finalizando a pesquisa, foram feitas as devidas comparações entre os modelos de cada horizonte de previsão (ultra curto, curto e médio prazo) e o modelo híbrido, composto de um modelo SARIMA (*Seasonal Autoregressive Integrated Moving Average*) e duas Redes Neurais Artificiais, da tese de (ALENCAR, 2018). As comparações foram feitas baseadas nas métricas de erro obtidas, que são MAE (*Mean Absolute Error*), MAPE (*Mean Absolute Percentage Error*) e RMSE (*Root Mean Squared Error*).

## 1.7 Estrutura do trabalho

No capítulo 1 é apresentado o contexto no qual o trabalho está inserido, a justificativa, a motivação, a delimitação da pesquisa e os objetivos almejados.

No capítulo 2 é apresentada a revisão de literatura do tema, expondo pesquisas feitas com a mesma finalidade.

No capítulo 3 são mostrados conceitos teóricos relacionados aos métodos utilizados e fundamentos importantes no decorrer da pesquisa, como energia eólica, séries temporais, métodos estatísticos de predição, RNA *Deep Feedforward*, e RNA LSTM.

No capítulo 4 é apresentada a metodologia da pesquisa e ainda os materiais utilizados, como bases de dados, modelos propostos e métodos.

No capítulo 5 são apresentados resultados de experimentos e os modelos gerados, e são feitas diversas análises comparativas para a seleção do melhor modelo.

Finalizando, o capítulo 6 faz as devidas conclusões do trabalho.

## 2 REVISÃO DE LITERATURA

A predição da geração de energia eólica é uma tarefa complexa devido à aleatoriedade e intermitência do vento (ZHANG; WANG; WANG, 2014). Neste sentido, diversos trabalhos têm sido publicados na literatura propondo metodologias para predição da velocidade do vento, como o de (OLIVEIRA, 2020), (FARIAS, 2020) e (YONGQIAN et al., 2017).

A pesquisa de (RAMALHO; DIAS, 2009) usou RNAP (Rede Neural Artificial Profunda) para prever séries temporais da velocidade do vento na cidade de Fortaleza no Ceará, com o objetivo de checar a viabilidade de instalação de parques eólicos. O autor destaca a capacidade da cidade de Fortaleza para gerar energia eólica, por conta dos ventos constantes e regulares da região nordestina, principalmente no litoral. A velocidade do vento na cidade alvo do estudo fica em torno de 7,5 a 9 m/s na média durante o ano à uma altura de 50m. Para treinar a rede neural foram utilizados dados da FUNCEME (Fundação Cearense de Meteorologia e Recursos Hídricos), onde o desempenho foi medido por meio das métricas de MSE (*Mean Squared Error*) e coeficiente de desigualdade de Theil. Treinando a rede neural com dados históricos, coletados entre 2003 e 2004, fez com que fosse possível estimar a velocidade do vento em uma janela temporal curta, de poucos dias, pois o aumento dessa janela resulta em mais erros na predição por conta da variação meteorológica. O melhor resultado desse estudo obteve um MSE de 0,007378 e um TIC (coeficiente de desigualdade de Theil) de 0,05203, ao utilizar uma memória de curto prazo na rede neural. Um ponto fraco deste trabalho são as métricas usadas (TIC e MSE), pois as mesmas acabaram não variando muito a medida que aumentavam-se os neurônios, sendo portanto necessário colocar a rede com 15 neurônios. (RAMALHO; DIAS, 2009)

Um outro estudo, feito por (BEZERRA et al., 2011), fez uma comparação entre resultados de predição de séries temporais obtidos em diversos modelos, sendo eles RNA, AR (auto-regressiva), ARIMA (*autoregressive integrated moving average*), ARMA (auto-regressivo de médias móveis) e o modelo de persistência, sendo este último a principal base para comparação. Quanto a RNA foram utilizados 2 subtipos ou arquiteturas, FTDNN (*Focused Time Delay Neural Network*) e NARX (*Nonlinear Autoregressive Network with Exogenous Inputs*), rede direta e recorrente respectivamente. Os resultados foram definidos com base nas métricas MAE, RMSE e MAPE, calculadas após simulações feitas para predições com horizontes de 1, 6, 12, 24 e 48 horas, e com a frequência da predição sendo horária. Para as simulações feitas foram utilizados dados históricos retirados da página na internet do *Alternative Energy Institute* (AEI), da *West Texas AM University*, referentes ao intervalo de 2003 a 2008 e ao local *Tall Tower South*. Após a comparação de desempenho entre os modelos foi verificada a eficiência maior ao utilizar a RNA de rede recorrente, NARX, onde nos horizontes acima de 6 horas obteve uma crescente diferença no valor do erro julgando pela métrica MAPE. O autor destaca que o NARX foi melhor do que FTDNN em todos os horizontes alvos do estudo, onde o NARX obteve o menor erro no horizonte de 1 hora ao atingir um MAPE de 16.16%, MAE de 0,0360 e RMSE de 0,0489. (BEZERRA et al., 2011)

A pesquisa de (FERRAZ et al., 2017) optou por realizar a predição de séries temporais da velocidade do vento no estado da Bahia, especificamente na cidade de Esplanada, utilizando para isso uma RNA do tipo *feed-forward*. As simulações foram feitas para diferentes passos à frente, de 1 a 12, ou seja, 30 minutos a 6 horas, e utilizando dados no treinamento referentes às quatro estações do ano para otimizar o desempenho da rede.

Para aumentar mais a eficiência do treinamento da rede foi utilizada a média de cinco inicializações da rede, onde cada uma teve valores de atraso definidos com base em uma função de autocorrelação. Foram utilizados dados históricos para predição da velocidade do vento coletados entre janeiro de 2015 e novembro de 2016, e ao final das simulações foi constatado que o modelo usado para a estação primaveira foi mais eficaz em um horizonte de predição de duas horas, sendo que a variação em um ano de MAPE para diferentes passos de predição foi menor que 26,91%. (FERRAZ et al., 2017)

O trabalho de (ALENCAR, 2018) possui dados meteorológicos do banco de dados do Sistema de Organização Nacional de Dados Ambientais (SONDA), especificamente da estação de Petrolina do período de 1 de janeiro de 2004 a 31 de março de 2017. O estudo teve o objetivo de usar os dados mencionados para prever a velocidade do vento a partir de modelos de ultra curto, curto, médio e longo prazo, e assim consequentemente tentar prever a capacidade da geração de energia para cada um destes horizontes usados na estação de Petrolina. A predição para cada um dos horizontes foi feita em diferentes modelos para efeito de comparação e assim encontrar o melhor para a tarefa de predição. Para conferir o desempenho de cada modelo foi feita uma comparação com 5, 10 e 20 passos para frente, sendo considerados minutos, horas, dias, semanas, meses e anos como horizonte de predição. Os modelos utilizados foram RNA, SARIMA (*Seasonal Autoregressive Integrated Moving Average*) e híbridos, sendo que deste último surgiu o mais eficiente dos resultados obtidos, mais especificamente quando foi feita simulação para o horizonte de horas. Foram utilizados três modelos híbridos, um com SARIMA mais *Wavelet*, um com SARIMA mais RNA e outro com SARIMA mais duas redes neurais, e após os experimentos foi constatado que o modelo com uma rede neural a mais possui desempenho superior, especialmente para o horizonte de horas, como já mencionado anteriormente. No melhor resultado, para um passo a frente e horizonte de horas, foram obtidos MAE de 0.139 e RMSE de 0.310, e na métrica MAPE o melhor resultado foi para o horizonte de meses com 1.813%. Quanto ao melhor resultado para 20 passos a frente, o horizonte de horas obteve as melhores métricas, com MAE de 0.176, RMSE de 0.784 e MAPE de 2.417%. (ALENCAR, 2018)

### 3 FUNDAMENTAÇÃO TEÓRICA


#### 3.1 Energia Eólica

##### 3.1.1 Conceito e Características

A energia eólica é uma alternativa elétrica limpa e renovável, que pode ser obtida ao aproveitar a energia cinética do vento, formada pelas massas de ar em movimento. A conversão para energia elétrica acontece graças a utilização de turbinas eólicas, ou aerogeradores, como também são conhecidas, (ALVES, 2010). Segundo (NASCIMENTO; MENDONÇA; CUNHA, 2012), esse tipo de energia foi usado a princípio para atividades agrícolas, mais especificamente para bombeamento de água e moagem de grãos. A produção da energia eólica acontece graças ao contato do vento com as pás do cata-vento da usina, que ao serem giradas convertem a energia cinética em mecânica, e esta aciona o rotor do aerogerador para produzir energia elétrica, (ALENCAR, 2018).

A geração de energia eólica depende do vento, um recurso meteorológico capaz de alimentar a produção de uma alternativa elétrica na matriz energética mundial, e pode ser descrito como um fluido, um corpo sem uma forma definida derivado da movimentação frequente e contínua do ar na superfície terrestre. Segundo (FEAM, 2013), o vento é produto resultante do deslocamento de massas de ar, sendo originado pelos efeitos das diferenças de temperatura e pressão atmosférica entre duas regiões diferentes e é influenciado por efeitos naturais, como latitude e altitude. A figura 3.1 ilustra o comportamento e formação do vento com base na movimentação do ar entre zonas de baixa e alta pressão para buscar o equilíbrio entre temperatura e pressão na atmosfera.

Figura 3.1 – Formação e circulação do vento.



Fonte: <https://www.infoescola.com/geografia/origem-e-tipos-de-ventos/>

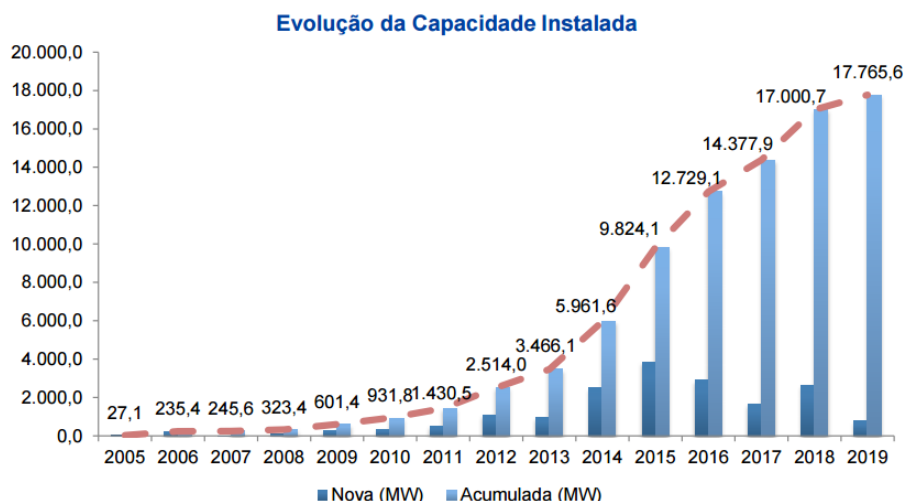
As turbinas eólicas de uma usina devem ser instaladas em locais onde os parâmetros regionais influenciem positivamente o vento, pois o mesmo varia bastante e necessita de uma avaliação para verificar a capacidade de geração de uma localidade antes de ser

instalada uma fonte de energia eólica. Para (DUTRA, 2011), os principais fatores que influenciam no vento são a variação da velocidade com a altura, rugosidade do terreno, presença de obstáculos ao redor e relevo.

A década de 70, após as crises do petróleo, foi um período onde diversos países começaram a se articular buscando outras fontes de energia, a fim de não serem tão dependentes de combustíveis importados. Além dessa preocupação com a independência de combustíveis, com o tempo surgiu também questões ambientais, onde a necessidade por alternativas sustentáveis de geração de energia se torna cada vez mais necessária, e foi nesse cenário onde a energia eólica começou a ter ainda mais atenção nas matrizes elétricas de muitos países. Especificamente no Brasil, esse investimento em energia elétrica originada a partir de recurso eólico, começou na década de 90, tendo suas primeiras usinas e parques eólicos construídos no nordeste brasileiro. (SIMAS; PACCA, 2013).

A figura 3.2 mostra a evolução de energia eólica instalada no Brasil desde meados de 2005, culminando em um aumento bem acelerado ao entrar nos anos 2010.

Figura 3.2 – Evolução da energia eólica no Brasil.



Fonte: ABEEólica

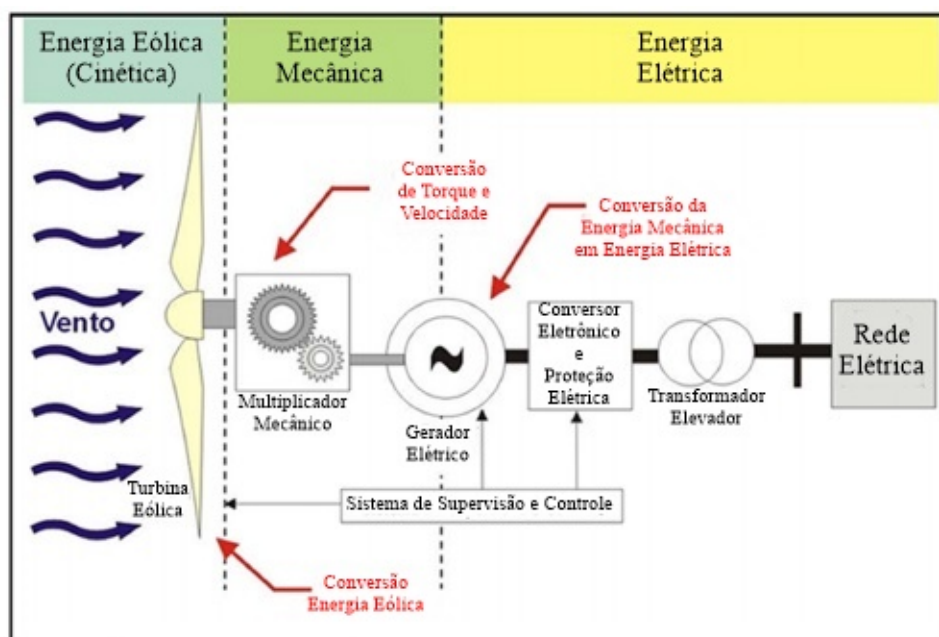
Segundo (PICOLO; RÜHLER; RAMPINELLI, 2014), um sistema eólico pode ser utilizado em diversos tipos de sistemas, como um isolado, um híbrido e até mesmo um interligado a rede de energia elétrica. Além dos tradicionais aerogeradores é possível também posicionar geradores no mar para aproveitar o vento originado e ampliado por este tipo de ambiente, e para esse tipo de gerador de energia eólica é atribuído o nome *offshore*.

O investimento em energia eólica tem diversos benefícios e vantagens, pois os parques ou estações ocupam um espaço pequeno, podendo inclusive ter atividades, como a agricultura, ocorrendo entre os aerogeradores. O vento, recurso abundante usado para gerar a energia eólica, faz que com a dependência de combustíveis fósseis seja reduzida e ainda colabora para uma economia melhor e para geração de mais empregos na localidade onde a central eólica foi instalada. Uma outra vantagem na geração de energia eólica é a produção sustentável, tendo uma redução bem grande na emissão de poluentes e outros tipos de agressões ao meio ambiente.

### 3.1.2 Geração de Energia Eólica

A produção de energia eólica acontece graças ao processo criado pelos componentes de uma turbina eólica, sendo estes responsáveis por perceber e captar a energia cinética originada do vento, e então essa energia é convertida para mecânica e posteriormente para a pretendida energia elétrica. O detalhamento desses processos pode ser visto na figura 3.3, onde é ilustrado que as pás do rotor se movimentam após serem atingidas pelo vento, e a frequência do rotor é multiplicada por conta de um sistema de engrenagens que recebe a transferência do movimento das pás do aerogerador. A velocidade gerada é transmitida para o gerador elétrico para gerar energia elétrica através de indução eletromagnética. (PICOLO; RÜHLER; RAMPINELLI, 2014)

Figura 3.3 – Funcionamento de um aerogerador para produção de energia.



Fonte: (PICOLO; RÜHLER; RAMPINELLI, 2014)

A geração eólica produz o potencial de energia elétrica a partir da energia cinética gerada por causa do vento. A conversão para energia mecânica acontece por conta de um processo que transforma a força do vento em um torque, e este age sobre as pás do rotor do aerogerador. A energia cinética de rotação ocorre no momento que é produzido pelas pás o torque eletromagnético no eixo da turbina, enquanto a energia cinética de rotação acontece quando as pás são giradas pelo vento. A equação 3.1 demonstra como ocorre esse processo de geração de energia cinética. (ALENCAR, 2018)

$$E_c = \frac{m \cdot v^2}{2} \quad (3.1)$$

Onde  $E_c$  é a energia cinética,  $m$  é a massa do ar e  $v$  é a velocidade da massa de ar em movimento.

Normalmente a classificação de uma turbina eólica acontece por meio do cálculo da potência disponível no vento, e este é feito por meio da equação 3.2. Onde  $P_d$  é potência,

$E$  é a energia cinética do vento e  $t$  é uma unidade de tempo dada em segundos.

$$Pd = \frac{E}{\Delta.t} = \frac{m.v^2}{2.t} \quad (3.2)$$

Como a densidade do ar é uma razão entre massa e volume, o termo  $m/t$  pode ser chamado de taxa de fluxo de massa ( $m$ ), que pode ser definida como massa por unidade de tempo, representada pela densidade do ar ( $\rho$ ) e fluxo de ar ( $Q$ ). O fluxo de massa de ar é dado pela equação 3.3.

$$m = \rho.Q \quad (3.3)$$

Onde taxa de massa, vazão volumétrica e massa específica do ar são respectivamente  $m$ ,  $Q$  e  $\rho$ .

O fluxo ( $Q$ ) é a quantidade de ar que passa por uma área específica. Pode ser calculada através do produto da velocidade do vento ( $v$ ) pela área em que o fluxo de ar passa pelas pás do rotor da turbina ( $A$ ). O fluxo é dado pela equação 3.4.

$$Q = v.A \quad (3.4)$$

Portanto, a taxa de fluxo de massa ( $m$ ) pode ser reescrita combinando as equações 3.3 e 3.4, resultando na equação 3.5.

$$m = \rho.v.A \quad (3.5)$$

Substituindo a equação 3.5 na equação 3.2, obtemos o potencial de vento que é a potência disponível no vento que passa pela seção  $A$ , através do fluxo do ar. A potência disponível no vento é dada pela equação 3.6.

$$P = \frac{1}{2}.\rho.A.v^3 \quad (3.6)$$

Porém a turbina eólica não pode aproveitar totalmente a potência disponível no vento para geração de eletricidade. Para (DUTRA, 2011), é necessário introduzir um coeficiente de potência  $C_p$  para considerar esta característica física, e este pode definido como a fração da potência eólica extraída das pás do rotor. Com a adição do coeficiente de potência a equação final fica como exposto na 3.7.

$$P = \frac{1}{2}.\rho.A.v^3.C_p \quad (3.7)$$

### 3.2 Processo de descoberta de conhecimento em banco de dados (KDD)

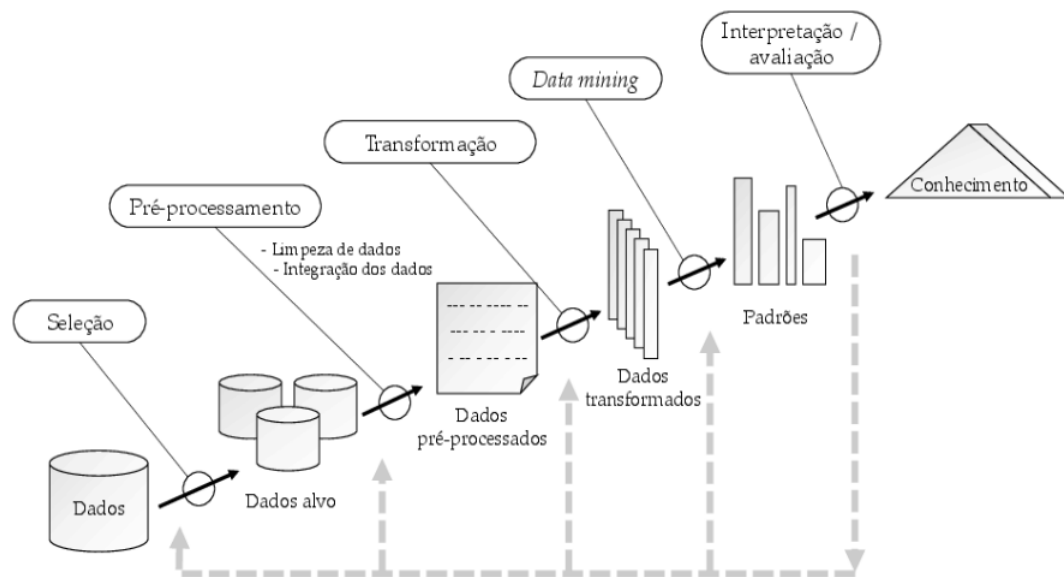
O processo de descoberta de conhecimento em banco de dados, ou simplesmente processo KDD (*Knowledge Discovery in Databases*), é basicamente um processo para extrair informações implícitas e obter novos conhecimentos a partir de um banco de dados, conhecimentos esses que podem ser tendências, padrões, probabilidades, associações ou fatos, segundo (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996) e (GOLDSCHMIDT; PASSOS, 2005).

O processo de KDD ocorre em diferentes etapas para atingir o objetivo de extrair conhecimento de um banco de dados. Segundo (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996), as etapas do KDD envolvem aspectos como preparação de dados, busca por padrões, avaliação do resultado e ainda etapas extras que possuem a finalidade de

preparação da transição das etapas. Para (ASSEISS, 2017), o KDD trata-se de um processo que visa utilizar uma base de dados, junto com procedimentos extras que possuem o intuito de fazer a seleção, pré-processamento, amostragem ou ainda a transformação dos dados. Outra importante etapa do KDD é a de *data mining*, sendo que esta possui a finalidade de aplicar algoritmos para extrair padrões a partir dos dados.

É importante mencionar que, segundo (ASSEISS, 2017), mesmo o processo de KDD sendo representado, como mostra a figura 3.4, como um processo ordenado, o mesmo é muito interativo, dando possibilidade do usuário do processo, quando precisar, retornar a qualquer etapa anterior para executar alterações ou ainda executar *loops* nas etapas a fim de não necessitar retornar quando avançar para etapas posteriores. A figura 3.4 mostra as cinco etapas consideradas principais, tendo outras que são para preparação entre as etapas principais.

Figura 3.4 – Etapas principais do processo KDD.



Fonte: (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996)

### 3.2.1 Etapas do KDD

#### 3.2.1.1 Etapa de seleção de dados

Nessa etapa acontece a escolha da base de dados a ser trabalhada durante o processo do KDD, e tendo a base é também feita uma seleção quanto a atributos úteis para a problemática trabalhada, por exemplo na predição de velocidade do vento tratada neste trabalho, e ainda é checado se há conexões com outras bases ou tabelas para que ocorra um processamento conjunto dos dados. Para (BOENTE; GOLDSCHMIDT; ESTRELA, 2008) é necessário estudar o banco de dados antes da seleção, como entender que tipos de dados existem em uma tabela e se têm outras tabelas relacionadas, tendo em vista que o processo de *data mining* precisa de dados com qualidade para funcionar de maneira eficiente.

### 3.2.1.2 Etapa de pré-processamento

Na etapa de pré-processamento é feita uma série de inspeções na base dados e atributos selecionados na etapa anterior, com o intuito de fazer uma limpeza nos mesmos. A inspeção consiste em diversas ações como tratar valores ausentes, eliminar atributos desnecessários, eliminar *outliers* em determinados atributos, balancear os dados, ou ainda adaptar os dados para outro horizonte, como, por exemplo, neste trabalho, onde a base original de dados é em minutos, porém foi adaptada para dias e horas para tornar possível o uso de outros horizontes, no caso médio e curto prazo.

### 3.2.1.3 Etapa de transformação de dados

A etapa de transformação de dados é feita para tornar os dados menos complexos após o pré-processamento, e conseqüentemente otimizar o tempo de processamento do algoritmo de *data mining* aplicado (ASSEISS, 2017). A transformação contém diversas operações que podem ser feitas quando é utilizada no processo de KDD, como a discretização de atributos numéricos, generalização de dados, e seleção de atributos relevantes (HAN; KAMBER, 2006).

### 3.2.1.4 Etapa de *data mining*

Segundo (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996), a etapa de *data mining* é a principal do KDD, pois é nela onde são extraídos novos conhecimentos e descobertos novos padrões, e ela é dividida em sub etapas chamadas de tarefas, que são variadas e distintas para atender a diversos padrões existentes em grandes volumes de dados. As etapas de *data mining* são a sumarização, classificação, agrupamento, associação e regressão, sendo descritas nos itens abaixo.

- Sumarização: Essa tarefa têm a finalidade de fazer a generalização dos dados para obter um conjunto de dados menor.
- Classificação: Essa tarefa têm a finalidade de gerar aprendizagem de regras ou funções para determinar a classe de um objeto segundo seus atributos.
- Agrupamento: Essa tarefa têm a finalidade de realizar a identificação de grupos semelhantes a partir dos dados trabalhados, ou seja, agrupar conjuntos de dados similares entre grupos na base de dados.
- Associação: Essa tarefa têm a finalidade de descobrir regras de associação para revelar relacionamentos entre objetos na base de dados.
- Regressão: Essa tarefa têm a finalidade de determinar funções com erros mínimos que modelem os dados, isso por meio de metodologia estatística.

### 3.2.1.5 Etapa de interpretação e avaliação

Na etapa de interpretação e avaliação, como o próprio nome indica, é quando o resultado da etapa de *data mining* é avaliado e posteriormente interpretado. Se os dados forem considerados interpretáveis, ou seja, puderem ser compreendidos, então começa a avaliação, onde é decidido se foi obtido conhecimento relevante para a problemática trabalhada, e o quão relevante é, além de ser verificado também se há indicativo de um novo padrão. Caso os dados não sejam interpretáveis é necessário que seja feito novamente os passos anteriores do processo de KDD, ou pelo menos parte deles (BOENTE; GOLDSCHMIDT; ESTRELA, 2008).

### 3.3 Séries temporais

Durante as últimas décadas a comunidade de pesquisa científica tem se interessado bastante em séries temporais e em sua modelagem. Segundo (ADHIKARI; AGRAWAL, 2013), a razão principal para modelar séries temporais é fazer uma coleta cuidadosa e rigorosa para poder realizar um estudo sobre eventos passados de uma série temporal, assim é possível desenvolver um modelo mais adequado para descrever a estrutura da série. O modelo desenvolvido pode ser usado para fazer previsões de valores futuros da série com base nos valores do passado.

Para que a previsão de uma série temporal ocorra sem problemas é necessário ajustar o modelo desenvolvido. Pesquisadores não tem medido esforços para ter cada vez mais modelos eficientes para previsão. Segundo (EHLERS, 2007), tem certas características bem particulares desses dados de séries temporais, como citado abaixo.

- Observações correlacionadas são mais difíceis de analisar e necessitam de técnicas específicas.
- Deve ser levado em conta a ordem temporal das observações.
- Fatores complicadores como presença de tendências e variação sazonal ou cíclica podem ser difíceis de estimar ou remover.
- A seleção de modelos pode ser bastante complicada, e as ferramentas podem ser de difícil interpretação.
- É mais difícil de lidar com observações perdidas e dados discrepantes devido à natureza sequencial.

Segundo (FARIAS; TREVISAN, 2013), em uma série temporal existem movimentos característicos conhecidos como componentes fundamentais, e a definição destes estão descritas abaixo.

- Componente tendencial: Se trata de um movimento evolutivo que faz a tradução da influência de fatores responsáveis por fazer com que determinado fenômeno seja mais ou menos intenso no decorrer do tempo. Pode-se dizer então que essa componente é caracterizada por ser um movimento ascendente ou descendente de longa duração, ou seja, de um período maior que um ano. Quando uma série temporal não apresenta nenhum tipo de tendência ela é chamada de "série estacionária".
- Componente cíclica: Se trata de um movimento oscilatório de longa duração, é responsável por comunicar a influência de fatores aleatórios com ação repetitiva. Esse componente faz a indicação das fases de contração e expansão de certas atividades. O componente possui três ciclos: Ciclos longos, com duração de por volta de 50 anos; Ciclos médios, com duração de por volta de 10 anos; Ciclos curtos, com duração de 2 a 7 anos.
- Componente sazonal: Se trata de um movimento oscilatório, assim como a cíclica, de curta duração, ou seja, de períodos menores que um ano. Esse componente faz a tradução de fatores que atuam de forma periódica, quando se trata de diminuir ou aumentar a intensidade do fenômeno.
- Componente aleatória: Se trata de um movimento oscilatório com curta duração e que possui grande instabilidade. Esse componente comunica a influência de fatores casuais.

### 3.4 Métodos para previsão de séries temporais

Para previsão de séries temporais foram bastante utilizados por pesquisadores métodos de modelo estatístico durante muito tempo, e nas subseções 3.4.1 e 3.4.2 estão dois

dos principais métodos desse tipo de modelo. O uso de redes neurais para predição de séries temporais tem sido mais consideradas e utilizadas, e nas subseções 3.4.3 e 3.4.4 são tratados dois tipos de Redes Neurais Artificiais Profundas e que inclusive serão o foco principal deste trabalho. Especificamente neste texto serão trabalhadas séries temporais de atributos meteorológicos para predição de velocidade do vento, sendo usados diferentes horizontes ou escalas de tempo. Segundo (ZHAO; WANG; LI, 2011), (DONGMEI; YUCHEN; XU, 2011) e (WANG; GUO; HUANG, 2011), os horizontes ou escalas de tempo podem ser divididos em quatro categorias, como exposto nos itens abaixo e na tabela 3.1, onde tem exemplos para os tipos de escala, que considera o funcionamento dos sistemas de energia elétrica.

- Previsão de ultra-curto prazo: De alguns minutos a 1 hora à frente.
- Previsão de curto prazo: De uma hora para várias horas à frente.
- Previsão de médio prazo: De várias horas a 1 semana à frente.
- Previsão de longo prazo: A partir de 1 semana a 1 ano ou mais à frente.

Tabela 3.1 – Classificação das escalas de tempo para previsão do vento

Escala de Tempo	Alcance	Aplicações
Ultracurto prazo	De alguns minutos a 1 hora à frente	Compensação do mercado de eletricidade, Operações de rede em tempo real e Ações de regulação
Curto prazo	De uma hora para várias horas à frente	Planejamento do despacho econômico de carga, Decisões razoáveis de carga e Segurança operacional no mercado da eletricidade
Médio prazo	De várias horas a 1 semana à frente	Decisões de compromisso das unidades, Decisões de compromisso de reserva e Gerador <i>on-line/off-line</i> decisões
Longo prazo	A partir de 1 semana a 1 ano ou mais à frente	Planejamento da manutenção, Gestão da operação, Custo de funcionamento ótimo e Estudo de viabilidade para projetos de parques eólico

Fonte: (ZHAO; WANG; LI, 2011), (DONGMEI; YUCHEN; XU, 2011) e (WANG; GUO; HUANG, 2011),

### 3.4.1 Modelos Autorregressivos Integrados de Médias Móveis (ARIMA)

Um modelo ARIMA é a combinação de dois outros métodos de modelos estatísticos, modelo autorregressivo (AR) e de média móvel, e possui um processo não estacionário. A equação 3.8 representa um modelo ARIMA. (VALIPOUR; BANIHABIB; BEHBAHANI, 2013)

$$x_t = x_{t-1} + \phi x_{t-1} - \phi x_{t-2} + e_t - \theta_1 e_{t-1} \quad (3.8)$$

Onde  $x_t$  é uma variável que segue uma tendência, como se não houvesse um valor fixo para a média.

O modelo ARIMA é um tipo de modelo mais sofisticado, pois usa as correlações entre as observações em vários momentos. O modelo ARIMA possui uma estrutura um pouco complicada para ser identificada, porém, alguns softwares já fazem essa identificação

de forma automática da estrutura do modelo, assim consegue-se evitar o procedimento mais complicado. Modelos ARIMA costumam ser mais eficientes nos resultados quando a série temporal é relativamente longa.

### 3.4.2 Modelo auto-regressivo integrado sazonal de médias móveis (SARIMA)


Segundo (ALENCAR, 2018), o modelo ARIMA se propõe a fazer a exploração da autocorrelação entre os valores da série em momentos seguidos, porém quando os dados são observados em uma faixa de tempo menor que um ano, a série também pode apresentar autocorrelação para uma estação de sazonalidades. O SARIMA é um modelo que contempla as séries que apresentam autocorrelação sazonal. De modo geral o SARIMA é representado pela forma SARIMA  $(p,d,q)(P,D,Q)_s$ , onde  $q$  e  $p$  são as ordens da média móvel (MA) e do autoregressivo (AR), respectivamente,  $d$  se trata da ordem das diferenças, enquanto  $P$ ,  $D$  e  $Q$  são ordens sazonais correspondentes, e  $S$  é uma representação das etapas de diferenças sazonais. O modelo SARIMA possui processos que contém quatro etapas:

- Pré-tratamento da amostra
- Identificação e estimativa
- Diagnóstico e otimização
- Previsão

### 3.4.3 Redes Neurais Artificiais *Feedforward* e Profundas


As Redes Neurais Artificiais (RNA) são um grupo de neurônios, unidades de processamento de informações, conectados entre si, formando um sistema onde cada um desses neurônios faz uma colaboração com outro de uma camada posterior ou anterior. Para (HAYKIN, 2008) é possível associar uma RNA a uma rede neural do cérebro humano, principalmente ao expor dois aspectos: todo conhecimento é adquirido pela rede graças a um processo de aprendizagem que acontece no ambiente desta rede; com o aprendizado acontece uma generalização dos dados e memória por meio de parâmetros adaptáveis chamados de pesos sinápticos, sendo estes então responsáveis por armazenar o conhecimento obtido pela rede. Em uma Rede Neural Artificial os neurônios são separados em camadas devidamente categorizadas, como pode ser conferido na estrutura básica exposta na figura 3.5. As categorias destas camadas são conhecidas como camada de entrada, camada oculta e camada de saída, sendo que a oculta pode ser uma camada ou mais.

Figura 3.5 – Estrutura básica de uma RNA.



Fonte: [https://cerebromente.org.br/n05/tecnologia/rna\\_i.htm](https://cerebromente.org.br/n05/tecnologia/rna_i.htm)

Segundo (OLAOFE; FOLLY, 2012) esse conjunto de neurônios separados por camadas, assim como o padrão de conexão entre estas, é chamado de arquitetura da rede neural. Duas das principais arquiteturas de RNA são a rede *perceptron* multicamadas ou rede direta, ilustrada na figura 3.6, e a rede recorrente, ilustrada na figura 3.7. Estas arquiteturas possuem a função de determinar o número de pesos e camadas, assim como a maneira que os sinais de entrada serão processados.

Figura 3.6 – RNA *perceptron* multicamadas.

Fonte: <https://www.embarcados.com.br/redes-neurais-artificiais/>

A figura 3.6 faz uma representação de uma RNA do tipo rede profunda, sendo de arquitetura *perceptron* multicamadas (também conhecida como arquitetura *deep feedforward*). Neste tipo de RNA a estrutura começa pela camada de entrada, sendo que esta possui a responsabilidade de captar estímulos do ambiente ou sinais de entrada para

alimentar a rede no início. As saídas geradas pela primeira camada, criadas graças a uma função soma de cada entrada da rede vezes um peso sináptico, são passadas como entrada para cada neurônio da camada intermediária, como mostra a equação 3.9. Na camada oculta acontece a maior parte do processamento da rede, sendo ela responsável por gerar as entradas para a última camada. As entradas da camada de saída são geradas através de uma função soma similar a utilizada na saída da camada de entrada, porém com a adição de uma função de ativação, alimentada pela saída da camada anterior, na fórmula da equação, ficando como exposto em 3.10, onde é utilizada a função de ativação sigmóide,  $\text{relu}$ , entre outras. Caso haja mais de uma camada interna, a partir da segunda camada oculta é utilizada a equação 3.11. Na camada de saída é aplicada a equação 3.11 para gerar um resultado de classificação ou predição de um registro da base de dados após o processamento de todas as informações anteriores. Esse procedimento das camadas ocorre  $n$  vezes, graças a um processo de aprendizado realizado por um algoritmo de aprendizagem, pois é criado um ciclo de adaptação para encontrar um padrão, e a cada nova rodada o aprendizado melhora com base no ajuste de pesos a partir de erros obtidos anteriormente. Em resumo, os sinais obtidos na entrada são propagados por toda a rede gerando pesos e erro, ao chegar na saída o erro é retropropagado até a entrada, assim os sinais são propagados novamente para ajustar os pesos com base nesse erro enviado a partir da saída.

$$z = \sum_{i=0}^n x_i \cdot w_i \quad (3.9)$$

Onde  $z$  é a saída da camada de entrada,  $x_i$  é a entrada de cada neurônio da camada de entrada e  $w_i$  é o peso sináptico de cada ligação de um neurônio da camada de entrada com outro da camada oculta.

$$h1 = \sum_{i=0}^n \frac{1}{1 + \exp^{z_i}} \cdot w_i \quad (3.10)$$


Onde  $h1$  é a saída da primeira camada oculta,  $z_i$  é a entrada de cada neurônio da primeira camada oculta (saídas da camada de entrada), e  $w_i$  é o peso sináptico de cada ligação de um neurônio da primeira camada oculta ou com outro da camada posterior (podendo ser outra camada oculta ou a camada de saída).

$$h2 = \sum_{i=0}^n \frac{1}{1 + \exp^{h1_i}} \cdot w_i \quad (3.11)$$

Onde  $h2$  é a saída da segunda camada oculta,  $h1_i$  é a entrada de cada neurônio da primeira camada oculta (saídas da primeira camada oculta), e  $w_i$  é o peso sináptico de cada ligação de um neurônio da segunda camada oculta ou com outro da camada posterior (podendo ser outra camada oculta ou a camada de saída).

A rede descrita com arquitetura *perceptron* é chamada de *feedforward*, caso tenha somente uma camada, ou rede profunda, caso tenha mais de uma camada. Uma rede *perceptron*, seja multicamadas ou não, é treinada com base no ajuste de pesos e com a adição de um bias em cada camada com exceção da saída, e este bias é um elemento que serve para aumentar o grau de liberdade dos ajustes dos pesos. Com esse ajustamento de pesos ocorre o aumento de eficiência no processo de classificação ou predição da rede. O processo de ajuste na rede acontece através do algoritmo *backpropagation*, uma generalização da regra delta proposta por Widrow e Hoff (DEMUTH; HAGAN; BEALE, 2008), responsável pelo ajuste dos pesos a partir de erros obtidos a fim de diminuir estes a cada nova etapa de simulação.

Figura 3.7 – RNA recorrente.



Fonte: <https://www.embarcados.com.br/redes-neurais-artificiais/>

As RNAs recorrentes são parecidas com as RNAs *feedforward* ou profunda, mas possuem memória, elas têm a capacidade de persistir informações por meio de *loops*. Uma rede recorrente não recebe como entrada apenas as informações de entrada atuais, e sim também o que perceberam antes no tempo, ou seja, esta rede recebe como entrada em uma camada o passado e o presente combinados, para que seja decidido qual será a resposta a novos dados. As redes neurais recorrentes conseguem preservar a informação em sequência nas camadas intermediárias, e passa por diversas etapas de tempo ao prosseguir em cascata, o que afeta o processamento de cada novo exemplo na rede. Resumindo, uma RNA recorrente é caracterizada por ter a capacidade de compartilhar pesos no decorrer do tempo. Este tipo de rede funciona com uma versão modificada do algoritmo de aprendizado *backpropagation*, sendo esta versão conhecida como *backpropagation through time* (BPTT).

O algoritmo de aprendizagem *backpropagation* é baseado em aprendizado a partir da correção de erros, sendo que esta correção acontece graças ao ajuste de pesos na rede. O processo do *backpropagation* é dividido em duas etapas. Na primeira etapa um padrão é reconhecido por meio da entrada da rede, e este se propaga pelas camadas a partir de operações, principalmente de somatório. Na segunda etapa o resultado obtido é comparado com o esperado, a partir dessa comparação o erro é calculado e retropropagado da saída até a camada de entrada, e posteriormente segue o fluxo normal para que os pesos sejam ajustados a partir do erro calculado. A evolução da redução de erro acontece até ser alcançado um valor com estabilidade e satisfatório, com base em um erro mínimo pré-estabelecido ou até que seja alcançado a quantidade de interações configurada no algoritmo.

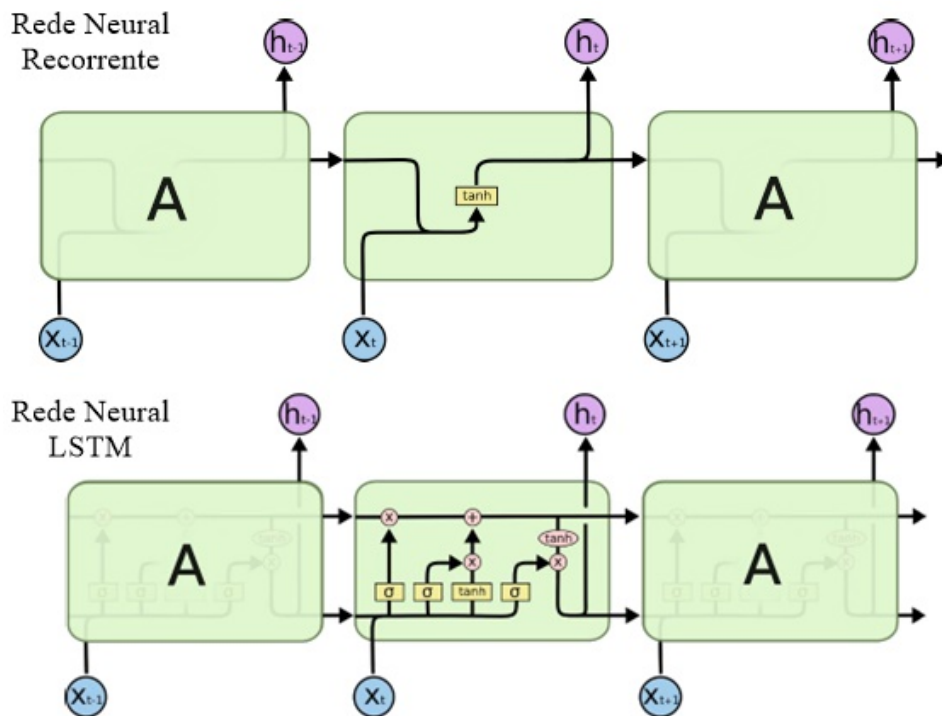
#### 3.4.4 Redes Neurais Artificiais LSTM

A rede LSTM é um tipo de rede neural artificial recorrente, e possui a capacidade de resolver o problema de desaparecimento da variação gradativa na RNA, aumentando assim o desempenho. Uma rede LSTM consegue ainda proporcionar a uma RNA a capacidade de recordar relações durante um longo período de tempo, o que caracteriza esse tipo de rede como sendo uma RNA com memória a longo prazo. Em redes recorrentes comuns é normal existir o desaparecimento da variação gradativa durante o treinamento, especialmente

quando a sequência de dados é longa. O desaparecimento da variação gradativa ou gradiente acontece em caso de o sinal de erro ser pequeno durante a propagação pelo *Backpropagation Through Time* (BPTT), pois isso acarreta em uma diminuição desse gradiente e como consequência isso acaba prejudicando a atualização de pesos na rede, e logo implica também em um aprendizado ineficiente. A solução para esse problema, proposta pela rede LSTM, é manter o fluxo de erro constante utilizando unidades conhecidas como "portões", e estas têm a função de fazer o ajuste dos pesos e ainda de truncar a sequência de dados quando é notado que um ou mais desses dados não são necessários, ou seja, os portões podem executar um esquecimento na rede.

Segundo (PEREIRA, 2017) uma rede LSTM possui uma estrutura com forma de uma cadeia de módulos de repetição, tal como uma rede neural recorrente normal, porém o módulo repetido é diferente na sua estrutura. Na rede LSTM há quatro camadas de rede neural ao invés de ter apenas uma como acontece com uma rede recorrente padrão, e estas quatro camadas fazem uma interação de uma forma bem específica, o que pode ser visto na figura 3.8, onde é apresentada a estrutura de uma rede neural recorrente normal e uma LSTM. Em uma rede LSTM, além das camadas de rede neural, há diversas células de memória e três portões, sendo que as células de memória têm a função de armazenar informação, enquanto os portões gerenciam.

Figura 3.8 – Estrutura de RNA recorrente e LSTM.




Fonte: OLAH, 2015

A rede LSTM possui a capacidade de fazer a adição ou remoção de dados no estado de uma célula, e estes dados são cuidadosamente regulados pelas portas, estruturas já citadas anteriormente e que compõe uma rede LSTM. As portas podem opcionalmente selecionar algumas informações para passarem na rede. As portas são compostas por uma camada sigmoide de uma rede neural e uma multiplicação *pointwise* (ponto a ponto), sendo que a sigmoide faz a produção de números entre zero e um para descrever quanta

informação deve ser liberada de cada componente, onde zero indica que não deve passar nada e um é exatamente o contrário. Na figura 3.9 é possível ver a estrutura de um portão, sendo que estes totalizam três em uma rede LSTM, como pode ser conferido na descrição abaixo:

- *Forget Gate*: Possui a função de definir quais informações e dados são úteis para continuarem no estado da célula.
- *Input Gate*: Possui a função de adicionar ao estado de uma célula as informações que foram selecionadas no portão de esquecimento (*Forget Gate*).
- *Output Gate*: Possui a função de extrair informações úteis da célula para apresentar como uma saída.

Figura 3.9 – Estrutura de um portão na rede LSTM.



Fonte: OLAH, 2015

Na figura 3.8 é possível ver a recursividade no estado da célula representada por setas em *loop*, e isso evidencia que as informações dos intervalos anteriores são armazenadas na célula LSTM. Dentro da célula acontece um processo de modificação do estado da mesma por meio do *forget gate* localizado abaixo do estado da célula, e ocorre ainda um ajuste pela porta de modulação localizada na entrada da célula. Nesse procedimento descrito o estado da célula anterior passa por um esquecimento, é multiplicado com a *forget gate* e adiciona mais informações e dados através da saída das portas de entrada da célula.

Descrevendo mais detalhadamente o que ocorre em um processo na rede LSTM temos como primeiro passo a tarefa de determinar e selecionar quais informações e dados não são necessários para continuar nas células memória, ou seja, é definido quais informações serão descartadas por meio de uma função de ativação sigmoide ligada ao portão de esquecimento. Esse processo inicial é representado pela equação 3.12.

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (3.12)$$

Onde  $f_t$  é igual a *forget gate*,  $b_f$  e  $W_f$  são o bias e as matrizes de peso respectivamente,  $\sigma$  é a função sigmoide,  $h_{t-1}$  é a saída da última unidade LSTM no tempo t-1, e por fim  $X_t$  é a entrada mais atual.

Após determinar quais informações não permanecem na rede é chegada a hora de selecionar quais das informações restantes devem ser guardadas no estado da célula. Esse processo de decisão começa pelo *input gate*, onde será decidido quais valores serão atualizados. Logo em seguida uma camada com tangente hiperbólica faz a criação de um vetor de valores candidatos ( $C_t$ ) a serem ou não incluídos no estado da célula. A atualização no estado da célula acontece após a combinação das duas saídas. Após esses passos o processo recomeça fazendo as mesmas etapas até chegar de novo na camada

de tangente hiperbólica, ao chegar nesta camada pesos são atribuídos aos valores que conseguiram passar para determinar seu nível de importância (faixa de -1 a 1). Acontece uma multiplicação das saídas dessa nova execução de etapas para que seja atualizado o estado da célula. É adicionada à memória antiga  $C_{t-1}$  a memória que acaba de ser gerada, e esse processo tem como resultado  $C_t$ . Esse passo da rede LSTM é expresso pelas equações 3.13, 3.14 e 3.15.

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (3.13)$$

$$M_t = \tanh(W_m \cdot [h_{t-1}, X_t] + b_m) \quad (3.14)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot M_t \quad (3.15)$$

Na etapa final, o cálculo da saída LSTM ( $h_t$ ) é feito baseado no estado da célula filtrada ( $o_t$ ). É calculado um sigmóide para decidir quais as partes do estado da célula chegarão na saída. A saída do estado da célula filtrada é multiplicada pelos valores novos que foram gerados pela camada de tangente hiperbólica do estado da célula com um valor tendo uma variação entre -1 e 1. As equações 3.16 e 3.17 demonstram essa etapa final dos processos de uma camada LSTM.

$$h_t = o_t \cdot \tanh(C_t) \quad (3.16)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (3.17)$$

## 4 MATERIAL E MÉTODOS

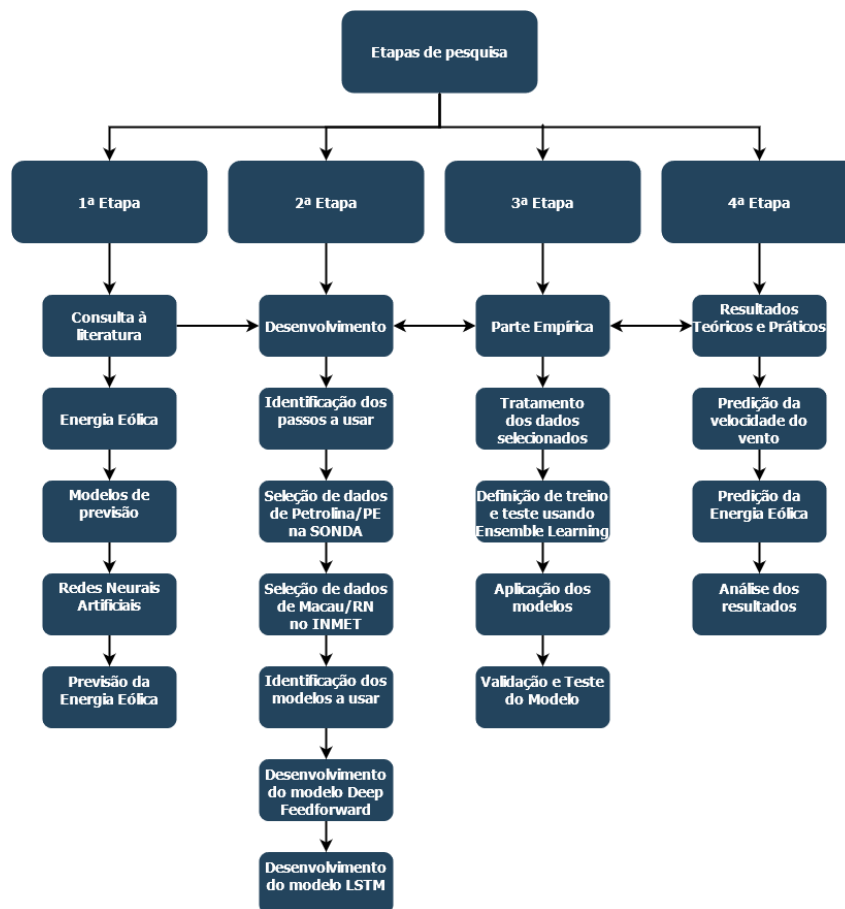
### 4.1 Introdução

Nesse capítulo são apresentados os procedimentos metodológicos de nossa pesquisa, as etapas adotadas durante o planejamento e execução da mesma, os bancos de dados usados para treinamento e validação pelos algoritmos de Redes Neurais Profundas, como os mesmos foram obtidos, a amostragem do dados, quais as bibliotecas foram utilizadas durante os experimentos, as métricas utilizadas para medir o desempenho dos modelos e por fim é apresentado também como foram feitos os experimentos e quais técnicas foram usadas para obter os modelos de predição.

### 4.2 Etapas da pesquisa

Na figura 4.1 estão expostas as etapas executadas neste trabalho, sendo descritas textualmente a seguir.

Figura 4.1 – Etapas de pesquisa.



Fonte: Autor

Primeira etapa: Nesta etapa foi definido o problema de pesquisa através de uma profunda revisão da literatura. Foram realizados estudos preliminares sobre a energia

eólica e como se dá o processo de geração desse tipo de energia. Também foi realizada uma profunda revisão da literatura sobre energia eólica, métodos de previsão da energia eólica, identificando as lacunas nesta área do conhecimento.

Segunda etapa: Foram identificados os diferentes passos de previsão os quais foram usados nas simulações. Nesta etapa, também foram coletados os dados meteorológicos das estações de Petrolina (PE) e Macau (RN), retirados dos repositórios do SONDA (Sistema de Organização Nacional de Dados Ambientais), (SONDA, 2020) e do INMET (Instituto Nacional de Meteorologia), (INMET, 2020), respectivamente. Adicionalmente, foram identificados os modelos a usar, bem como a implementação dos algoritmos para Redes Neurais Profundas Diretas (*Deep FeedForward*) e Redes Recorrentes (*Long Short Term Memory*) usando a API *Keras* com o *backend Tensorflow*.

Nas implementações desses algoritmos de Redes Neurais Profundas foram usadas, em ordem, as seguintes bibliotecas e funções para desenvolver os modelos:

- *pandas*: Biblioteca para manipulação e análise de dados.
  - *read\_csv*: Faz a leitura da base de dados.
  - *dropna*: Remove as linhas onde há colunas com valores faltantes na base lida.
  - *iloc*: Particiona a base de dados, no caso essa função foi usada para remover a primeira coluna, pois esta trata-se apenas da informação temporal do registro (dia, hora ou minuto).
  - *concat*: É usada para concatenação de estruturas de dados. No caso foi usada para juntar a base de treino com a de teste, tendo assim uma base completa dos dados.
  - *drop*: Remove linhas ou colunas específicas, identificando pela *label*. Por exemplo, neste trabalho são removidas colunas de atributos temporais, como data e hora.
- *scikit-learn*: Esta biblioteca dispõe de ferramentas simples e eficientes para análise preditiva de dados.
  - *MinMaxScaler*: Define o intervalo referente a normalização dos dados. No caso foi definido o intervalo de 0 a 1, referente ao requisito da função de ativação.
  - *fit\_transform*: Normaliza os dados com base no *MinMaxScaler* definido.
- *numpy*: É uma poderosa biblioteca *Python* que é usada principalmente para realizar cálculos em *arrays* multidimensionais.
  - *array*: Adapta as estruturas de dados criadas para usarem as funções da *numpy*.
- *keras*: É uma das principais APIs de redes neurais de alto nível. Ele é escrito em *Python* e suporta vários mecanismos de computação de rede neural de *backend*.
  - *Sequential*: Cria uma estrutura para agrupar camadas da rede neural.
  - *add*: Cria camadas da rede neural com as devidas configurações, como função de ativação e quantidade neurônios.
  - *optimizers*: Define o otimizador da rede neural.
  - *compile*: Configura a rede com otimizador, perda e métricas.
  - *fit*: Treina a rede.
  - *predict*: Faz a predição, no caso usando a base de teste.
  - *inverse\_transform*: Desfaz a normalização feita anteriormente, porém apenas para as previsões oriundas do resultado da função *predict*.
  - *evaluate*: Avalia o modelo aplicado.
- *Keras Tuner*: Biblioteca para automatizar o processo de busca por hiper parâmetros.
- *Matplotlib*: Biblioteca para plotar gráficos.

Terceira Etapa: Esta etapa correspondeu a seleção, pré-processamento e formatação dos dados descritos na segunda etapa. Os dados foram tratados, passando por algumas etapas de pré-processamento e normalização de dados. Como já mencionado,

esses tratamentos de dados geraram diferentes bases de dados com diversas quantidades de registros, como mostra a Tabela 4.1. Essas atividades são descritas em detalhes na seção 4.3. Posteriormente realizaram-se os treinamentos e validações de diversos modelos de Redes Neurais Profundas considerando horizontes de previsões a 20 passos à frente, selecionando os que obtiveram menores erros.

Quarta Etapa: Nesta etapa foram apresentados os resultados depois de ter aplicado os modelos programados e comparados os resultados. Realizaram-se a interpretação e visualização dos resultados, foram geradas tabelas e curvas de predição da velocidade do vento para diferentes cenários de tempo, para determinada turbina eólica.

### 4.3 Banco de dados e Pré-processamento de dados

#### 4.3.1 Pré-processamento de dados

As séries de dados históricos utilizadas neste trabalho foram retiradas, como já mencionado, dos repositórios do SONDA (Sistema de Organização Nacional de Dados Ambientais), (SONDA, 2020), no caso da estação eólica de Petrolina (PE), e do INMET (Instituto Nacional de Meteorologia), (INMET, 2020), no caso da estação eólica de Macau (RN).

Os dados da série de Petrolina/PE estavam disponibilizados originalmente em minutos, portanto foi necessário fazer uma transformação de dados, visando obter novas bases de dados em escalas adequadas (horas e dias) para que os modelos pudessem, também, fazer previsões a curto e médio prazo. Para realizar essas mudanças de escalas, inicialmente, utilizou-se a média dos minutos em cada dia, para se obter a velocidade do vento média de cada dia. Com relação a base dados obtida com dados em dias, cada registro passou a ter as variáveis calculadas pela média de 1440 minutos (quantidade de minutos em 24 horas) e a base de dados em horas têm cada registro calculado pela média de 60 minutos. Com as conversões feitas foi possível obter todas as bases usadas neste trabalho e mencionadas na Tabela 4.1. A base de Macau/RN foi extraída originalmente em horas e dias, não existindo uma base em minutos no repositório, portanto para a base de Macau/RN não foram desenvolvidos modelos para predição a ultra curto prazo.

As descrições das bases de dados, apresentadas na tabela 4.1, estão com registros na escala de minutos, horas e dias. Para as obtenções e validações dos modelos baseados em Rede Neurais Profundas (*Deep Feedforward* e Redes LSTM), utilizaram-se a linguagem Python e as bibliotecas auxiliares *Numpy*, *Pandas*, *Keras/Tensorflow*, dentre outras. Os modelos foram ajustados para fazer previsões a 20 passos à frente. Os resultados obtidos foram tabulados e comparados com os de modelos obtidos pelo sistema híbrido proposto por (ALENCAR, 2018).

Com a base de dados pronta foi possível usar como entrada nos algoritmos utilizados, onde, dependendo do *Ensemble Method* utilizado, há variação na partição de dados. Ao separar a base em treino e validação foi necessário fazer uma série de pré-processamentos para iniciar o treinamento da rede. As colunas de atributos temporais precisaram ser eliminadas para construir estruturas de dados previsoires contendo apenas os dados dos atributos meteorológicos da base de dados. Tendo as estruturas de dados prontas foi feita uma normalização dos dados antes do treinamento, isso se fez necessário por conta das funções de ativação usadas nos experimentos, como a sigmoide, que necessitam que os dados estejam em um intervalo entre 0 e 1. Foram criadas estruturas de previsoires, atributos usados na predição, e velocidade real, que é o valor da velocidade contido na base de dados em uso, sendo que a base de dados é particionada de acordo com a quantidade

de passos adotada. Por exemplo, se for adotada a quantidade de 20 passos, a estrutura velocidade real terá 20 registros, ou seja, o histórico de 20 registros da velocidade do vento é usado para prever o próximo.

#### 4.3.2 Banco de dados

A série histórica, completa, utilizada se estende de 01 de janeiro de 2004 a 31 de maio de 2017, sendo que os registros estão na grandeza de dias. Essa base foi utilizada considerando-se, inicialmente, a escala de dias, enquanto para minutos e horas foi usado um período diferente para que os dados não se diferenciasssem muito com relação ao tamanho da base de dados, por exemplo, como consta na Tabela 4.1, a base em dias possui 4900 dados, enquanto a em horas possui 8760, então para essas quantidades ficarem balanceadas foi adotado um período diferente na base de horas, sendo este de 01 de junho de 2016 a 31 de maio de 2017. As escalas de tempo usadas foram as mesmas do trabalho de (ALENCAR, 2018), para que os experimentos dele fossem replicados. As bases de dados originais apresentam diversas variáveis, porém foram selecionadas apenas as cinco citadas na Tabela 4.2 por conta de terem mais influência na velocidade do vento. O intervalo temporal, mostrado na tabela 4.1, foi adotado seguindo o trabalho de (ALENCAR, 2018), pois foi necessário criar uma replicação dos dados para que as comparações entre experimentos tivessem propriedades semelhantes nas bases de dados utilizadas, ou seja, para que os experimentos pudessem ser replicados em partes. Fora as bases de dados apresentadas, há também uma base alternativa utilizada por apenas um dos modelos apresentados na seção 5, e que foi trabalhada inicialmente no artigo de (FIGUEIREDO; CAMPOS, 2021). A série histórica da base alternativa se estende do período de 1 de janeiro de 2015 a 31 de julho de 2018, totalizando 1308 registros.

Tabela 4.1 – Período, grandeza e quantidade de registros das bases de dados

Caracterização das bases de dados	Quantidade de registros	Data
Ultracurto prazo (minutos)	7200	27/05/2017 a 31/05/2017
Curto prazo (horas)	8760	01/06/2016 a 31/05/2017
Médio prazo (dias)	4900	01/01/2004 a 31/05/2017

Fonte: Autor

A tabela 4.2 mostra quais as variáveis selecionadas da base original, informa também qual o nome, mostrado entre parênteses, que identifica cada variável nas bases de dados utilizadas, e por fim ainda é deixado explícito qual a unidade associada às variáveis.

Tabela 4.2 – Atributos das variáveis selecionadas do banco de dados

Variáveis meteorológicas	Unidade
Temperatura do ar (tp_sfc)	Temperatura do ar superficial em °C
Umidade do ar (humid)	Umidade relativa do ar em %
Pressão atmosférica (press)	Pressão atmosférica em milibares
Velocidade média do vento a 10m (ws_10m)	Velocidade média do vento a 10m em m/s
Direção do vento (wd_10m)	Direção média do vento a 10m de 0° a 360° (horário)

Fonte: (SONDA, 2020)

No trabalho de (ALENCAR, 2018) foi feito um estudo para selecionar as variáveis mencionadas, onde foi identificada a correlação existente entre as variáveis explanatórias, medindo assim o grau de concordância relativo ao sentido da evolução dos valores que cada variável assume ao longo do tempo. Com o estudo de correlação, exposto na tabela 4.3, foi possível dizer que a velocidade possui uma correlação maior com a umidade, num sentido negativo, e com a pressão de forma positiva. A correlação medida indica que a velocidade tende a aumentar se a pressão aumenta, por ser uma correlação positiva, e a velocidade tende a diminuir em caso de a umidade aumentar, por se tratar de uma correlação negativa. Segundo (ALENCAR, 2018), a correlação foi medida utilizando o *software IBM SPSS MODELER PROFESSIONAL* versão 18.0, que é uma plataforma de análise preditiva. Para complementar foi observado ainda o padrão de comportamento das variáveis presentes no banco de dados original, onde foi possível notar a semelhança no padrão das variáveis selecionadas, como explicado mais abaixo e mostrado na figura 4.2. Devido a esse estudo as mesmas variáveis foram adotadas para trabalhar em modelos para ajudar no problema apresentado neste trabalho, que no caso é a predição da velocidade do vento.


Tabela 4.3 – Correlação entre as séries temporais

	Temperatura	Umidade	Pressão	Velocidade	Direção
Temperatura	1,000				
Umidade	-0,663	1,000			
Pressão	-0,182	0,042	1,000		
Velocidade	-0,097	-0,427	0,125	1,000	
Direção	-0,313	0,536	-0,005	-0,389	1,000

Fonte: (ALENCAR, 2018)

Na figura 4.2 é possível ver o comportamento das variáveis meteorológicas utilizadas nas tarefas de predição. O padrão de comportamento apresentado na figura é semelhante entre todas as variáveis, e isso justifica o uso de temperatura, umidade e pressão para a predição de velocidade do vento, por conta da influência exercida na medição da velocidade do vento.

Figura 4.2 – Comportamento das séries temporais que compõe o banco de dados utilizado.



Fonte: (SONDA, 2020)

A tabela 4.4 apresenta as localizações das estações onde foram coletados os dados, para isso são utilizadas informações como coordenadas geográficas e UF referentes às estações eólicas que são fonte de dados para este estudo.

Tabela 4.4 – Localização das estações eólicas.

Estação (sigla)	UF	Latitude	Longitude
Petrolina (PTR)	PE	09°04'08"S	40°19'11"O
Macau	RN	-5.151136	-36.573001

Fonte: (ALENCAR, 2018)

As Figuras 4.3 e 4.4 apresentam a localização das cidades onde as estações eólicas trabalhadas estão presentes. A indicação não é na coordenada exata, mas mostra a cidade onde cada estação eólica está instalada.

Figura 4.3 – Localização da estação eólica de Petrolina/PE.



Fonte: (JFPE, 2021)


Figura 4.4 – Localização da estação eólica de Macau/RN.



Fonte: (MAPAS, 2021)

Segundo (ALENCAR, 2018), a rede SONDA de dados, antes de disponibilizar os dados de suas estações, submete-os a um processo de validação que objetiva identificar os dados suspeitos, através desse processo foi possível garantir a confiabilidade dos dados. Um exemplo do gráfico dos resultados pode ser observado na Figura 4.5, a qual apresenta um exemplo da validação dos dados do ano de 2014, essa validação foi realizada em todas as bases de dados utilizadas. Dados que não passam por esse processo de validação são pouco confiáveis, pois se torna muito difícil deduzir se o dado é referente a um evento inconsistente ou até mesmo raro. Em suma, com dados não validados a base teria pouca utilidade para fins, por exemplo, de previsão, sendo necessária uma série de formatações para tratar os inúmeros dados inconsistentes.

Figura 4.5 – Exemplo de validação dos dados da SONDA.



Fonte: (SONDA, 2020)

#### 4.4 Modelo de previsão proposto

Conforme mencionado na seção 4.2, para este estudo foram utilizados dados das estações eólicas de Petrolina e Macau, localizadas em Pernambuco e Rio Grande do Norte, respectivamente. A série temporal estava na grandeza de minutos, no caso da estação de Petrolina/PE, e foi adaptada também para horas e dias, conforme procedimentos apresentados na seção 4.3, para que fossem realizados experimentos com diferentes quantidades de dados e faixa temporal. No caso da estação de Macau/RN, já haviam bases prontas na escala de hora e dia no repositório, porém a base em minutos é inexistente, não tendo portanto modelos de ultra curto prazo para essa estação. As simulações foram feitas visando prever a velocidade do vento, que é a variável que mais influencia a avaliação de possibilidade de geração de energia eólica, com 20 passos à frente.

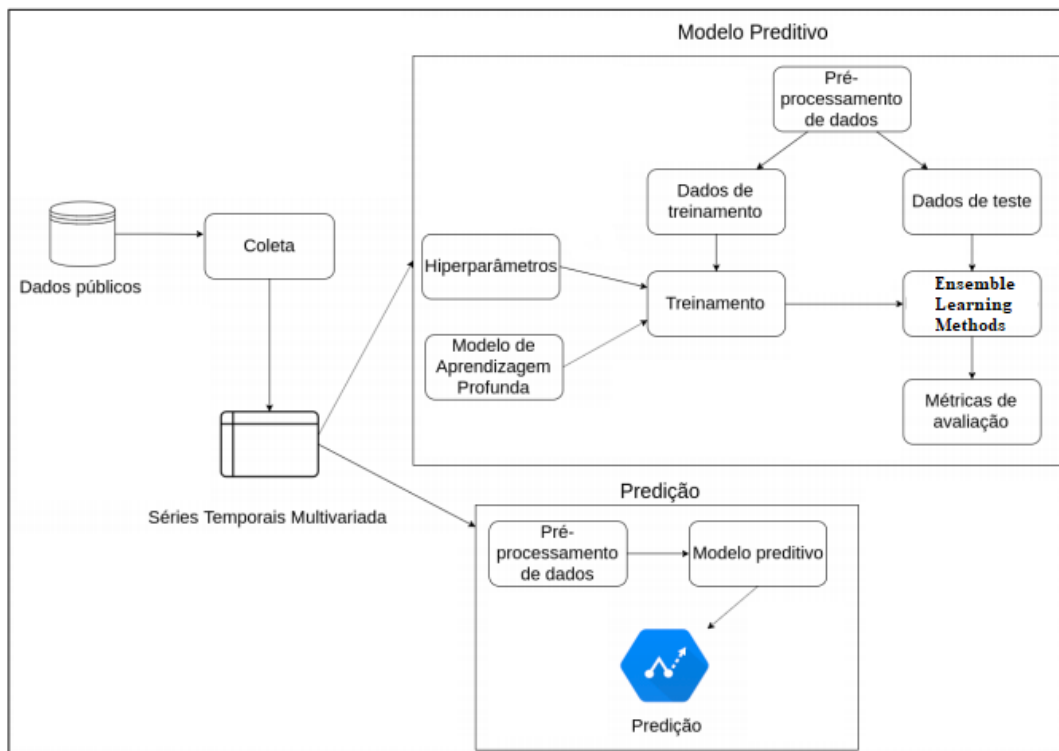
Cada base de dados foi usada como fonte de alimentação para treino e validação de algoritmos de Redes Neurais Artificiais: *Deep Feedforward* e *LSTM (Long Short Term Memory)*. Nos algoritmos foram sendo variados, a cada nova simulação, os diferentes hiper parâmetros das redes neurais treinadas (como otimizador, função de ativação, taxa de aprendizagem, número de neurônios nas camadas ocultas e número de épocas), sendo que isso foi feito de forma automatizada com o uso da biblioteca *Keras Tuner*. O experimento inicial de cada horizonte e base foi feito usando a biblioteca *keras tuner*, que têm a função de automatizar o processo de busca de hiper parâmetros. O *keras tuner* selecionou de forma automatizada a taxa de aprendizado e a quantidade de neurônios nas camadas internas, enquanto outros parâmetros, como otimizador e função de ativação, foram fixados manualmente.

Nas simulações com Redes Neurais Profundas Diretas utilizou-se o algoritmo de treinamento de retropropagação do erro, em inglês *backpropagation*, que ajusta os pesos da rede, por meio de um otimizador, com objetivo de minimizar o erro entre os valores reais da(s) variável(is) de saída e as saídas previstas. Os otimizadores usados foram Adam

e SGD. A técnica utilizada para particionamento de dados foi a *hold-out*, com 80% de dados para treino e 20% para teste. Já nas simulações com a Rede LSTM teve um cenário igual em questão de particionamento de dados. Além do Adam e SGD, foi usado também o otimizador RMSprop nas simulações feitas, que contaram com as bases particionadas da mesma forma usada com a *Rede Feedforward*. A técnica *hold-out* foi escolhida por se adaptar melhor a predição, já que mantém íntegra a sequência de dados, enquanto uma técnica como a *k-fold* não preserva a sequência dos registros na base de dados, o que é obrigatório na predição, pois a escolha dos *folds* é feita de maneira aleatória. A figura 4.6 representa, de forma geral, todos os passos que foram utilizados no processo de predição proposto por este trabalho.

Quanto aos experimentos, foram realizados diversos para cobrir muitas possibilidades de cada hiper parâmetro, por exemplo, quando é variado o número de épocas são testados experimentos alterando somente essa configuração, deixando os outros hiper parâmetros inalterados. Ao terminar os experimentos com a configuração atual, foi selecionado outro hiper parâmetro para passar pelo mesmo processo a fim de encontrar um modelo cada vez mais otimizado ou definir um anterior como o melhor da rede e da grandeza trabalhadas nos experimentos em andamento, e a variação de parâmetros parte a partir dos parâmetros obtidos ao usar o *keras tuner* em um primeiro experimento da base e horizonte atual. Os algoritmos, tanto de rede *feedforward* quanto LSTM, param a simulação quando é atingido o número de épocas estabelecido, disponibilizando o valor de métrica atingido, os pesos da rede e uma visualização gráfica comparando os dados de velocidade do vento preditos com os reais.

Figura 4.6 – Diagrama do processo de predição de série temporal.



## 4.5 Arquitetura de computador utilizada e esforço computacional

Para realizar os experimentos com os modelos desenvolvidos foram utilizadas duas máquinas com especificações similares: ambas com processador Intel Core i5 e sem placa de vídeo dedicada, onde a diferença maior fica por conta da memória RAM, onde em uma máquina é 8GB e na outra é 4GB. A máquina com mais memória RAM também possui um *upgrade* de velocidade no sistema operacional por conta do uso de um SSD (*Solid State Drive*) como *drive* de armazenamento.

Quanto ao esforço computacional, no geral os experimentos com a rede LSTM precisaram de um tempo bem maior para serem finalizados, principalmente nos modelos que usaram a biblioteca *keras tuner* para automatizar a escolha de hiper parâmetros, pois o mesmo modelo é executado mais de uma vez em uma mesma etapa de simulação. O esforço computacional foi maior dependendo do prazo utilizado na predição, por conta do uso de uma quantidade maior ou menor de dados, onde a ordem de prazos que necessitaram de mais esforço, considerando do que levou mais tempo para finalizar a execução para o que levou menos tempo, é CP, UCP e MP. Uma estimativa de tempo (considerando os casos de maior esforço computacional, que no caso foi ao utilizar o *keras tuner*) para cada tipo de modelo é listada a seguir.

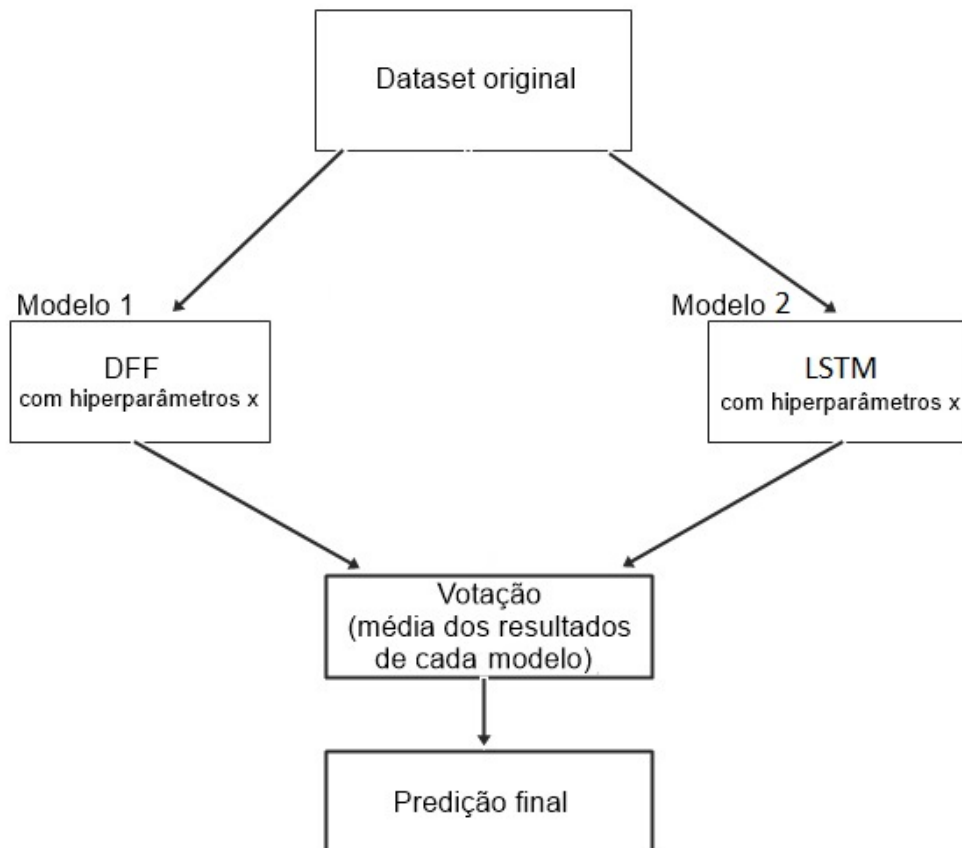
- Modelo UCP com rede DFF: Aproximadamente 7 horas.
- Modelo UCP com rede LSTM: Aproximadamente 12 horas.
- Modelo CP com rede DFF: Aproximadamente 9 horas.
- Modelo CP com rede LSTM: Aproximadamente 16 horas.
- Modelo MP com rede DFF: Aproximadamente 4 horas.
- Modelo MP com rede LSTM: Aproximadamente 9 horas.

## 4.6 Experimentos e Validação - Métodos de construção de modelos (*Ensemble Learning Methods*)

Para otimizar o processo de busca de modelos mais eficientes, foram usadas também *Ensemble Learning Methods*, que são um conjunto de técnicas que trabalham com mais de um modelo na mesma etapa de simulação a fim de selecionar o melhor. Para os experimentos foram usados dois tipos de *Ensemble Methods*, sendo o *voting* e o *bagging*.

### 4.6.1 *Voting*

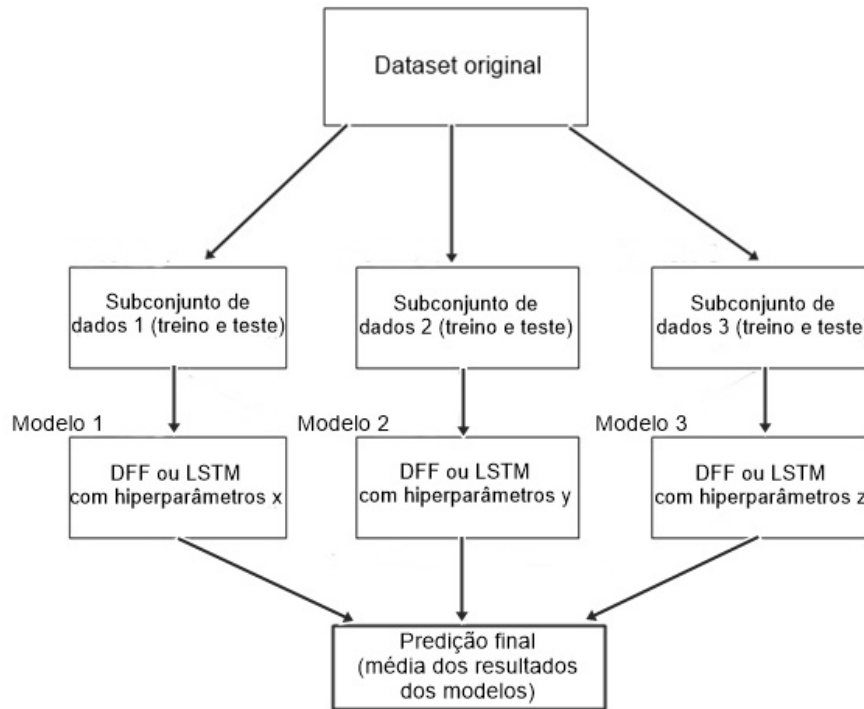
*Voting* é um modelo de aprendizado de máquina de conjunto que combina as predições de vários outros modelos. É uma técnica que pode ser usada para melhorar o desempenho do modelo, idealmente alcançando um melhor desempenho do que qualquer modelo único usado no conjunto. Essa técnica não requer que os modelos sejam homogêneos, em outras palavras pode-se treinar diferentes modelos, com a mesma base de dados original sendo usada como treino e validação dos modelos. No caso específico do uso de *voting* para predição de séries temporais, ao treinar e validar cada modelo, a predição final se dá pela média dos resultados dos modelos. A Figura 4.7 ilustra o processo descrito.

Figura 4.7 – Funcionamento do *voting*.

Fonte: Autor

#### 4.6.2 *Bagging*

Uma das formas de reduzir a variância das estimativas é fazer a média das várias estimativas. No *bagging* o *dataset* original é dividido em *subdatasets*, gerando diversos modelos diferentes que usam cada *dataset* gerado na partição, ou seja, os modelos são gerados com *datasets* diferentes além de hiper parâmetros diferentes, e ao final das simulações dos modelos é gerada uma média dos resultados. O *bagging*, diferentemente do *voting*, usa apenas um algoritmo em todos os modelos gerados e diferentes configurações de hiper parâmetros para cada modelo, como mostra a figura 4.8.

Figura 4.8 – Funcionamento do *bagging*.

Fonte: Autor

#### 4.7 Métricas utilizadas

As métricas usadas para medir o desempenho dos modelos foram MAE (*Mean Absolute Error*), MAPE (*Mean Absolute Percentage Error*), RMSE (*Root Mean Squared Error*) e VMED (velocidade média). A escolha de grandezas em minutos, horas e dias foi feita a fim de medir o desempenho dos modelos para os fins apresentados na tabela 3.1. Segundo (ALENCAR, 2018), é bastante útil prever a velocidade um tempo à frente, tendo em vista que há uma grande variação da disponibilidade do recurso vento.

A seguir são feitas breves descrições a respeito das métricas utilizadas para medir o desempenho dos modelos configurados neste estudo, tanto em rede *Deep Feedforward* quanto LSTM.

MAE representa a precisão nas mesmas unidades dos dados utilizados, o que contribui para obter a magnitude do erro. Seu valor representa o desvio médio entre o dado observado e o predito. A equação 4.1 mostra a equação que expressa essa métrica. Na fórmula o  $n$  representa o número de amostras,  $V_i^{real}$  é valor real da velocidade e  $V_i^{prev}$  é o valor da velocidade predita.

$$MAE = \frac{1}{n} \sum_{i=1}^n |V_i^{real} - V_i^{prev}| \quad (4.1)$$

MAPE representa, assim como MAE, a precisão, porém em formato de porcentagem do erro. A equação 4.2, segundo (ALENCAR, 2018), mostra a equação que expressa

essa métrica. Na fórmula existe, assim como em MAE, a subtração entre velocidade real e predita, sendo que a novidade fica por conta da velocidade média presente no denominador.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|V_i^{real} - V_i^{prev}|}{V_{med}} \quad (4.2)$$

RMSE é uma métrica com uma unidade igual à dimensão dos valores observados e preditos. O valor dessa métrica é interpretado como uma medida do desvio médio entre o valor de velocidade observado e o predito, mas com a diferença desses valores elevada ao quadrado. A equação 4.3 representa a equação desta métrica.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (V_i^{real} - V_i^{prev})^2} \quad (4.3)$$

VMED trata-se do cálculo da média da velocidade do vento. A equação 4.4 representa a equação dessa métrica. Como nas outras equações, n é o número de amostras e o V é o valor real da velocidade.

$$VMED = \frac{1}{n} \sum_{i=1}^n V_i^{real} \quad (4.4)$$

## 5 RESULTADOS

### 5.1 Introdução

Neste capítulo são apresentados os resultados dos experimentos de predições da velocidade do vento realizados com as bases de dados das estações eólicas de Petrolina/PE e Macau/RN. Além do caráter exploratório sobre a capacidade de geração de energia elétrica, neste capítulo são apresentadas também uma série de comparações com os resultados obtidos por (ALENCAR, 2018). As predições feitas consideraram três horizontes de tempo, conforme mencionado no capítulo 4, que são: ultra curto, curto e médio prazos, gerando predições de 20 passos à frente.

Os resultados foram obtidos utilizando-se algoritmos de Redes Neurais Artificiais profundas programados utilizando-se as bibliotecas como *keras*, *pandas*, *numpy*, *matplotlib* e *keras tuner*. Especificamente, foram implementados códigos para redes *Deep Feedforward* e LSTM. A tabela 5.1 mostra todos os modelos validados a partir dos resultados de experimentos, onde cada um dos modelos é gerado pela aplicação dos *Ensemble Learning Methods* sob um conjunto de simulações feitas, cujos resultados são apresentados em detalhes no apêndice A. Na tabela 5.1 é apresentado qual *Ensemble Learning Method* foi utilizado para gerar cada modelo.

Todos os modelos foram criados a partir das mesmas bases de dados em cada um dos prazos, com exceção do modelo 10, que usa a base de dados alternativa citada na subseção 4.3.2. Os modelos expostos na tabela 5.1, referentes ao produto da aplicação dos *Ensemble method* (métodos de agrupamento) *voting* e *bagging*, serão comparados uns com os outros e com o modelo híbrido de (ALENCAR, 2018), que usa duas Redes Neurais Artificiais com estrutura MLP (*Multilayer Perceptron*) mais um modelo SARIMA (Modelo Auto-Regressivo Integrado Sazonal de Médias Móveis). Os resultados de cada modelo serão comparados com os de mesmo horizonte, ou seja, curto prazo será comparado com curto prazo, por exemplo.

### 5.2 Apresentação dos modelos propostos e Análises dos resultados

Para este trabalho, foram estimados quinze modelos finais de predição que geraram os resultados apresentados na tabela 5.1. Cada modelo foi obtido, aplicando-se um *Ensemble Learning Method*, onde no caso do *voting* estima-se vários modelos diferentes, com o mesmo conjunto de dados e usa-se votação para combinar as predições individuais visando chegar ao modelo final por meio da média dos resultados. Já no caso do *bagging* treinam-se diferentes modelos, com diferentes subconjuntos de dados (escolhidos aleatoriamente) e por fim calcula-se a média do conjunto de treinamentos, e essa média normalmente resulta em melhores predições do que um único modelo. Os resultados dos conjuntos de treinamentos para cada estratégia, utilizando-se redes *Deep Feedforward* e LSTM, são apresentados no apêndice A.

Tabela 5.1 – Modelos finais

ID	Base	Prazo	ELM	MAE	MAPE	RMSE	VMED
1	Petrolina	UCP	Voting	0,051	0,025	0,0708	2,0417
2	Petrolina	UCP	Bagging	0,0667	0,0338	0,089	2,2711
3	Petrolina	UCP	Bagging	0,0787	0,0385	0,104	2,2711
4	Petrolina	CP	Voting	0,006	0,0023	0,0213	2,6378
5	Petrolina	CP	Bagging	0,0036	0,0012	0,0143	3,1062
6	Petrolina	CP	Bagging	0,0099	0,0032	0,0323	3,1062
7	Macau	CP	Voting	0,0705	0,0211	0,0933	3,3402
8	Macau	CP	Bagging	0,0323	0,0065	0,0531	5,0354
9	Macau	CP	Bagging	0,138	0,0293	0,1779	5,0354
10	Petrolina	MP	Voting	0,0044	0,0016	0,0045	2,7714
11	Petrolina	MP	Bagging	0,0734	0,009	0,0954	8,3431
12	Petrolina	MP	Bagging	0,1098	0,0132	0,139	8,3431
13	Macau	MP	Voting	0,0583	0,0112	0,0747	5,2154
14	Macau	MP	Bagging	0,083	0,0171	0,1108	4,8425
15	Macau	MP	Bagging	0,1177	0,0244	0,1486	4,8425
ELM = <i>Ensemble Learning Methods</i>							

Fonte: Autor

Para efeitos de comparação com os resultados de (ALENCAR, 2018), foram compilados os resultados de modelos de mesmo horizonte, por exemplo, os modelos de horizonte ultra curto prazo foram comparados com o modelo híbrido de (ALENCAR, 2018) que usou horizonte ultra curto prazo, assim como os modelos de curto prazo foram comparados com o de curto prazo, o mesmo procedimento foi adotado para o médio prazo. As comparações foram feitas tomando por base as métricas utilizadas para avaliar os modelos, que no caso são: MAE, MAPE e RMSE. Em suma, se um modelo possui duas ou mais métricas com um valor menor que o modelo de horizonte equivalente de (ALENCAR, 2018), então o modelo é considerado melhor.

### 5.2.1 Modelos de Ultra Curto Prazo

Os modelos de 1 a 3 da tabela 5.1 são referentes aos que usaram a base de dados de ultra curto prazo, ou seja, a base onde os registros estão na escala de minutos. Essa base de dados, estava disponível no repositório de (SONDA, 2020), apenas para a estação eólica de Petrolina, portanto não houveram modelos do horizonte UCP (Ultra Curto Prazo) para a estação de Macau.

O modelo 1, estimado por meio da estratégia *voting*, usou a base de dados UCP completa, com 7200 registros, onde 80% dos mesmos foram usados para treinar as redes e 20% para validar. O *keras tuner*, que é uma biblioteca para *auto-tunning* dos hiper parâmetros das redes neurais profundas, indicou, em um primeiro experimento, uma taxa de aprendizado de 0,01 para a rede LSTM e 0,1 para DFF (*Deep Feedforward*). As taxas de aprendizado indicadas foram sendo ajustadas de forma manual, com a quantidade de neurônios nas camadas ocultas, a fim de otimizar os valores dos erros de predições. Após esses ajustes, as redes que melhor responderam foram aquelas que foram treinadas e validadas com um valor menor da taxa de aprendizado, especificamente nesse caso 0,009 para as LSTM e 0,006 para as DFF. A função de ativação ideal para camada de saída foi a

linear em ambas as arquiteturas de redes, enquanto nas camadas ocultas a tanh (tangente hiperbólica) foi a melhor para as LSTM e a relu (ativação linear retificada) foi melhor para as DFF. Com relação aos otimizadores, o RMSprop foi o que proporcionou melhores resultados para as redes LSTM e o Adam nas redes DFF.

Os modelos 2 e 3 foram estimados por meio do *Ensemble method* (método de agrupamento) *bagging*, e, portanto, a base de dados UCP foi particionada em três partes, contendo cada conjunto de dados 2400 registros. O *keras tuner*, biblioteca para *auto-tunning* dos hiper parâmetros da redes neurais profundas, indicou, uma taxa de aprendizado na faixa de  $10^{-3}$ , e inclusive acabou sendo a que gerou melhores resultados nos dois modelos, o que se confirmou nos experimentos com configuração manual de hiper parâmetros. Função de ativação e otimizadores foram iguais aos do modelo 1.

Os melhores hiper parâmetros, que deram origem aos modelos finais UCP após aplicação dos métodos *voting* e *bagging*, podem ser vistos na tabela 5.2.

Tabela 5.2 – Melhores hiper parâmetros dos modelos UCP

ID	Rede	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
1	LSTM	4000	RMSprop	230	170	120	tanh	linear	0,009
	DFF	20000	Adam	120	150	130	relu	linear	0,006
2	LSTM	3000	RMSprop	220	160	130	tanh	linear	0,003
	LSTM	4000	RMSprop	110	250	110	tanh	linear	0,004
	LSTM	5000	RMSprop	180	130	110	tanh	linear	0,003
3	DFF	20000	Adam	210	180	210	relu	linear	0,001
	DFF	20000	Adam	140	140	210	relu	linear	0,002
	DFF	25000	Adam	180	180	220	relu	linear	0,006

Fonte: Autor

Na tabela 5.2 as siglas do cabeçalho representam: ID = Identificação; EP = Épocas; OT = Otimizador; NINT = Número de neurônios das camadas internas; FAI = Função de ativação das camadas internas; FAS = Função de ativação da camada de saída; TAP = Taxa de aprendizado.

#### 5.2.1.1 Predição a ultra curto prazo - UCP (minutos)

Para esse horizonte a base de dados usada possui 7200 registros, com cinco atributos usados na predição (velocidade, umidade, pressão, direção e temperatura) e também os atributos identificadores como id, dia, ano e, obviamente, minuto. A base de dados contempla cinco dias, onde o período se estende de 27 de maio de 2017 a 31 de maio de 2017.

A tabela 5.3 mostra os resultados dos modelos de ultra curto prazo, juntamente com o modelo híbrido de (ALENCAR, 2018) que usou o mesmo horizonte e a mesma base de dados. Foi predita a velocidade do vento da estação eólica de Petrolina 20 minutos a frente. As numerações identificando os modelos em cada coluna fazem referência a identificação presente na tabela 5.1.

Tabela 5.3 – Resultados dos erros para predição multipassos Ultra Curto Prazo (Minutos)

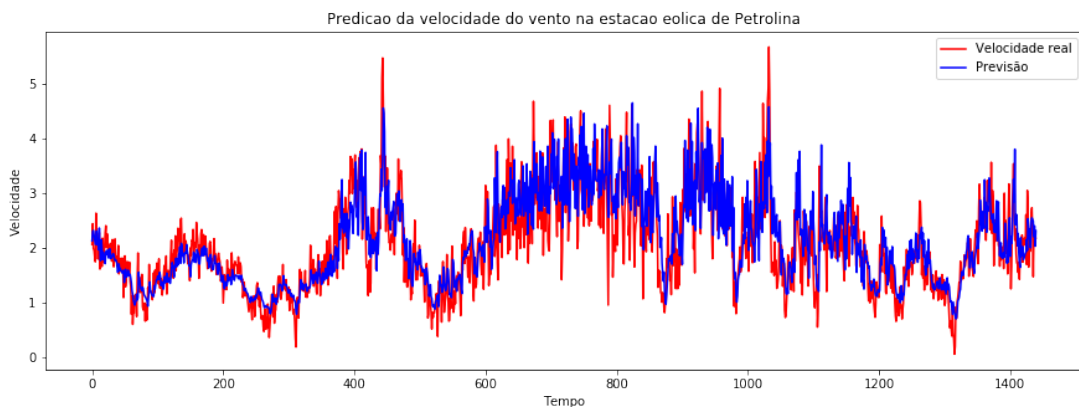
Métricas	Modelo 1	Modelo 2	Modelo 3	Modelo híbrido
VMED	2,0417	2,2711	2,2711	5,769
MAE	0,051	0,0667	0,0787	0,286
RMSE	0,0708	0,089	0,104	1,281
MAPE(%)	0,025	0,0338	0,0385	0,0499

Fonte: Autor

Analisando a tabela 5.3 é possível notar que todos os modelos destacados, comparados com o de (ALENCAR, 2018) (Modelo Híbrido) tiveram desempenho melhor, ou seja, obtiveram menores valores de erros (RMSE, MAE e MAPE) do que o Modelo Híbrido. O modelo 1 foi o que obteve melhor desempenho para todas métricas (RMSE, MAE e MAPE), dentre os demais, ou seja, o uso da base de dados completa acabou influenciando em uma predição mais otimizada da velocidade do vento para a estação eólica de Petrolina, a única trabalhada no horizonte UCP, da mesma forma que no modelo estimado, pelo modelo híbrido, (ALENCAR, 2018). O segundo melhor modelo foi o 2, onde foi aplicado o método bagging usando rede LSTM. No modelo 1, o de melhor desempenho, foram obtidos MAE de 0,051, MAPE de 0,025% e RMSE de 0,0708.


As Figuras 5.1 e 5.2, mostram os valores da velocidade do vento previstos, vinte passos à frente, para o horizonte de ultra curto prazo, para as Redes LSTM e DFF, respectivamente. Conforme esses gráficos é possível ver que as predições da rede LSTM se aproximam mais dos valores reais do que as redes DFF, considerando os valores ponto a ponto.

Figura 5.1 – Modelo LSTM do modelo 1 (segundo a tabela 5.2)



Fonte: Autor

Figura 5.2 – Modelo DFF do modelo 1 (segundo a tabela 5.2)



Fonte: Autor

### 5.2.2 Modelos de Curto Prazo

Os modelos de 4 a 9 da tabela 5.1 são os referentes ao seguinte horizonte de tempo: curto prazo, onde os dados estão na grandeza de horas.

Os modelos 4 e 7 foram estimados por meio do *Ensemble method* (método de agrupamento) *voting*, com as bases de Petrolina e Macau, respectivamente. Tal como no modelo 1, foram usadas as bases de dados completa das duas estações, que possuem 8760 registros, particionadas em 80% para treinamento das redes e 20% para testes. Em relação ao otimizador e funções de ativação, o melhor desempenho foi obtido com os mesmos já utilizados nos modelos de UCP, conforme ilustra a tabela 5.4, a taxa de aprendizado mais indicada ficou em torno de  $10^{-3}$  em todos os melhores resultados.

Os modelos 5, 6, 8 e 9 foram estimados por meio do *Ensemble method* (método de agrupamento) *bagging*, e, portanto, usaram 1/3 da base completa de cada estação, tendo a mesma partição dos modelos anteriores para criar bases de treino e teste das redes. O otimizador e funções de ativação que geraram melhores desempenhos também foram iguais aos modelos citados anteriormente, ou seja, Adam e RMSprop para DFF e LSTM, respectivamente, e relu e tanh para DFF e LSTM, também respectivamente. Quanto a taxa de aprendizado na maioria dos casos o valor de  $10^{-3}$  foi o que gerou o melhor resultado em relação as métricas MAE, MAPE e RMSE, onde em apenas um caso o valor de  $10^{-2}$  gerou o resultado mais satisfatório, especificamente o terceiro submodelo, segundo a tabela 5.4, do modelo 8.

Tabela 5.4 – Melhores hiper parâmetros dos modelos CP

ID	Rede	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
4	DFF	30000	Adam	200	100	130	relu	linear	0,009
	LSTM	4000	RMSprop	220	170	190	tanh	linear	0,003
5	LSTM	4000	RMSprop	110	220	240	tanh	linear	0,003
	LSTM	4000	RMSprop	120	210	100	tanh	linear	0,002
	LSTM	4000	RMSprop	110	180	210	tanh	linear	0,003
6	DFF	30000	Adam	250	140	230	relu	linear	0,003
	DFF	30000	Adam	200	120	200	relu	linear	0,004
	DFF	35000	Adam	150	170	110	relu	linear	0,009
7	DFF	40000	Adam	120	170	110	relu	linear	0,001
	LSTM	5000	RMSprop	150	250	210	tanh	linear	0,005
8	LSTM	5000	RMSprop	250	150	210	tanh	linear	0,004
	LSTM	5000	RMSprop	230	250	250	tanh	linear	0,002
	LSTM	4000	RMSprop	100	130	120	tanh	linear	0,01
9	DFF	35000	Adam	240	140	170	relu	linear	0,001
	DFF	35000	Adam	220	160	130	relu	linear	0,001
	DFF	30000	Adam	150	120	200	relu	linear	0,001

Fonte: Autor

### 5.2.2.1 Predição a curto prazo - CP (horas)

No horizonte de curto prazo foram usadas bases de dados com 8760 registros de cada estação eólica, Petrolina e Macau. Os atributos previsores são iguais aos do horizonte de ultra curto prazo, porém os atributos identificadores são a data e a hora. As bases de dados, tanto de Petrolina quanto Macau, contemplam uma série histórica de 1 ano, cobrindo o período de 1 de junho de 2016 a 31 de maio de 2017.

A tabela 5.5 mostra os resultados dos modelos de curto prazo, e do modelo híbrido de (ALENCAR, 2018). A predição da velocidade do vento, nas estações de Petrolina e Macau, foi feita 20 horas a frente. Como já dito, a numeração dos modelos faz referência a identificação exposta na tabela 5.4.

Tabela 5.5 – Resultados dos erros para predição multipassos Curto Prazo (Horas)

Métricas	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo híbrido
VMED	2,6378	3,1062	3,1062	3,3402	5,0354	5,0354	7,291
MAE	0,006	0,0036	0,0099	0,0705	0,0323	0,138	0,176
RMSE	0,0213	0,0143	0,0323	0,0933	0,0531	0,1779	0,784
MAPE(%)	0,0023	0,0012	0,0032	0,0211	0,0065	0,0293	0,0242

Fonte: Autor

Analisando a tabela 5.5 é possível concluir que os modelos de CP apresentados nessa tabela obtiveram melhor desempenho considerando as métricas MAE e RMSE em todos os casos quando comparadas ao modelo híbrido de (ALENCAR, 2018), com relação ao MAPE, apenas o Modelo 9, obteve um valor maior do que o obtido pelo modelo híbrido de (ALENCAR, 2018). De forma geral, o modelo 5 teve indiscutivelmente o melhor

desempenho, obtendo MAE de 0,0036, MAPE de 0,0012% e RMSE de 0,0143. Esse modelo foi estimado usando o método *bagging* com redes LSTM, portanto foi estimado a partir da combinação de três modelos, onde cada um contém uma das três frações da base de dados completa da estação eólica de Petrolina.

As figuras 5.3 e 5.4 apresentam os gráficos indicadores de quão próximo os valores de velocidade preditos ficaram dos valores reais no submodelo 2 do modelo 5 (item 2 do modelo de ID 5, segundo a tabela 5.4), pois este proporcionou um resultado gráfico melhor, ou seja, os experimentos que usaram a partição do 2 da base de dados de Petrolina, presentes na tabela A.10 do apêndice A, geraram previsões melhores, mesmo aqueles que não foram selecionados para serem submodelos do modelo final, como é o caso do gráfico da figura 5.4. O gráfico 5.3 representa o submodelo 2 do modelo 5, o mesmo ilustra uma ótima previsão, pois os valores preditos ficaram bem próximos dos reais, além dos padrões de aumento e diminuição da velocidade do vento serem bastantes similares. O gráfico da figura 5.4 possui um desempenho melhor ainda, mesmo não pertencendo a um modelo que teve as melhores métricas.

Figura 5.3 – Submodelo 2 do modelo 5 (segundo a tabela 5.4)



Fonte: Autor

Figura 5.4 – Submodelo 5b5-LSTM do modelo 5 (segundo a tabela A.10)



Fonte: Autor

### 5.2.3 Modelos de Médio Prazo

Os modelos de 10 a 15 são referentes aos de médio prazo, onde os dados estão na escala de dias. O modelo 10 é o único que não teve nenhum experimento realizado com o uso de *keras tuner*, além disso, ele utilizou uma base de dados com um intervalo de tempo diferente, conforme descrito na subseção 4.3.2, e uma arquitetura de rede diferente e com hiper parâmetros diferentes da rede, com apenas duas camadas ocultas, ao invés de três como nos outros modelos.

Os modelos 10 e 13 foram estimados por meio do *Ensemble method* (método de agrupamento) *voting*, portanto a base de dados utilizada foi a completa e com o mesmo particionamento de dados para treino e teste dos modelos apresentados nas subseções 5.2.1 e 5.2.2, ou seja, 80% dos registros para treinar a rede e 20% para validar. Para o modelo 10, que utilizou a base dados da estação eólica de Petrolina que possui 1308 registros, foi preciso usar uma taxa de aprendizado maior ou igual a 0.3, para as redes DFF, para se obter o melhor resultado, enquanto para as redes LSTM uma taxa de faixa  $10^{-3}$  foi a melhor em boa parte dos modelos apresentados. O otimizador e funções de ativação, utilizados para esse modelo, foram iguais aos dos modelos expostos até o momento nas seções anteriores, como ilustra a tabela 5.6, enquanto a quantidade neurônios nas camadas ocultas e número de épocas foram bem menores se comparados com os já usados (como pode ser visto tabela 5.6).

Em relação ao modelo 13, referente a base de Macau que possui 4900 registros, os melhores hiper parâmetros seguem o padrão mais recorrente dentre os modelos expostos nas seções 5.2.1 e 5.2.2, como mostra a tabela 5.6, portanto os otimizadores mais indicados foram Adam e RMSprop, para redes DFF e LSTM, respectivamente, funções de ativação relu e tanh, para DFF e LSTM e taxa de aprendizado na faixa de  $10^{-3}$ .

Os modelos 11 e 12, referentes a estação eólica de Petrolina, e modelos 14 e 15, referentes a estação eólica de Macau, utilizaram a base de dados particionada, ou seja, 1/3 da base de dados de determinada estação eólica para cada submodelo dos modelos 11, 12, 14 e 15. A base completa de cada estação foi dividida em três partes, gerando então três resultados em cada um dos modelos, cada resultado referente ao melhor de cada base particionada (1/3 da original). Os hiper parâmetros também seguem o mesmo padrão dos modelos anteriores (otimizadores RMSprop e Adam, para LSTM e DFF, funções de ativação tanh e relu, para LSTM e DFF e taxa de aprendizado de  $10^{-3}$ ), na grande maioria dos casos, onde somente nos modelos 12 e 15 houveram casos fora desse padrão, que no caso foi a utilização de uma taxa de aprendizado na faixa de  $10^{-2}$ .

A tabela 5.6 ilustra todos os hiper parâmetros usados nos melhores experimentos dos modelos de médio prazo.

Tabela 5.6 – Melhores hiper parâmetros dos modelos MP

ID	Rede	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
10	DFF	10000	Adam	90	80		relu	linear	0,3
	LSTM	3000	RMSprop	110	90		tanh	linear	0,003
11	LSTM	4000	RMSprop	230	220	220	tanh	linear	0,003
	LSTM	4000	RMSprop	240	230	250	tanh	linear	0,002
	LSTM	4000	RMSprop	180	220	150	tanh	linear	0,003
12	DFF	30000	Adam	240	110	250	relu	linear	0,01
	DFF	40000	Adam	150	250	140	relu	linear	0,001
	DFF	40000	Adam	250	130	250	relu	linear	0,005
13	DFF	40000	Adam	250	250	250	relu	linear	0,001
	LSTM	5000	RMSprop	200	250	240	tanh	linear	0,003
14	LSTM	4000	RMSprop	110	140	190	tanh	linear	0,003
	LSTM	4000	RMSprop	200	180	160	tanh	linear	0,003
	LSTM	5000	RMSprop	220	210	230	tanh	linear	0,003
15	DFF	30000	Adam	110	220	240	relu	linear	0,003
	DFF	30000	Adam	220	200	170	relu	linear	0,003
	DFF	40000	Adam	240	250	240	relu	linear	0,01

Fonte: Autor

### 5.2.3.1 Predição a médio prazo - MP (dias)

No horizonte de médio prazo foram usados 4900 registros para os modelos de 11 a 15, enquanto para o 10 foram usados 1308 registros. Os 4900 registros cobrem uma série histórica no período de 1 de janeiro de 2004 a 31 de maio de 2017, enquanto a base do modelo 10 contempla o período de 1 de janeiro de 2015 a 31 de julho de 2018.

A tabela 5.7 mostra os erros obtidos pelos modelos de médio prazo (Modelos 10 a 15), descritos nesse trabalho, e também pelo modelo híbrido de (ALENCAR, 2018). Foram preditos valores da velocidade do vento, em Petrolina e Macau, com 20 passos à frente, ou seja, 20 dias a frente.

Tabela 5.7 – Resultados dos erros para predição multipassos Médio Prazo (Dias)

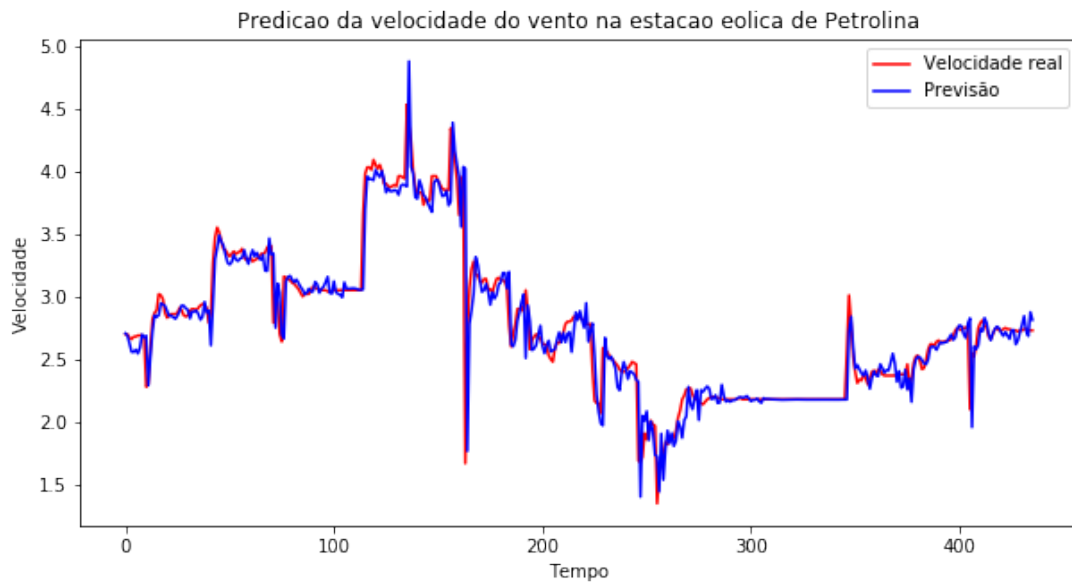
Métricas	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo híbrido
VMED	2,7714	8,3431	8,3431	5,2154	4,8425	4,8425	8,065
MAE	0,0044	0,0734	0,1098	0,0583	0,083	0,1177	0,342
RMSE	0,0045	0,0954	0,139	0,0747	0,1108	0,1486	1,53
MAPE(%)	0,0016	0,009	0,0132	0,0112	0,0171	0,0244	0,04

Fonte: Autor

Observando a tabela 5.7 é possível notar que todos os modelos de médio prazo, apresentaram valores de MAE, RMSE e MAPE(%) menores do que o modelo híbrido de (ALENCAR, 2018), ou seja todos os nossos modelos, superaram o modelo gerado pelo sistema híbrido. No geral o melhor modelo MP foi o 10, justamente o que utilizou uma base diferente com menor quantidade de registros. O modelo 10 obteve MAE de 0,0044, MAPE de 0,0016% e RMSE de 0,0045.

A figura 5.5 mostra o desempenho do melhor modelo de predição para MP, que foi o modelo 10, ou seja, aquele em que os valores preditos foram mais próximos dos reais. O gráfico pertence ao submodelo 10 da rede DFF, 10j-DFF segundo a tabela A.20 do apêndice A, apesar de não ser o modelo com melhores métricas foi o que proporcionou uma maior proximidade na predição da velocidade do vento. Na figura 5.5 é possível notar tanto uma grande similaridade entre valores reais e preditos da velocidade do vento quanto um padrão igual de aumento e diminuição do atributo predito.

Figura 5.5 – Modelo 10j-DFF do modelo 10 (segundo a tabela A.20)



Fonte: Autor

## 6 CONCLUSÃO

Dentre todos os modelos apresentados, considerando cada horizonte de médio, curto e ultra curto prazos, a maioria dos valores de erro MAE, MAPE e RMSE apresentados nesse trabalho foram melhores que os de (ALENCAR, 2018). No horizonte de ultra curto e médio prazos, os melhores modelos foram o 1 e 10, respectivamente, os quais foram estimados com o método *voting* para validar o modelo final, usando-se a base de dados completa da estação eólica de Petrolina. Quanto ao horizonte de médio prazo, o melhor resultado foi o do modelo 10, o qual utilizou a versão alternativa da base de dados de Petrolina, descrita na subseção 4.3.2.

No horizonte de curto prazo, o melhor modelo, foi o 5, o modelo final foi estimado por meio do método *bagging*, para esse modelo foram usadas partições da base de dados original da estação eólica de Petrolina. De forma geral, o modelo 5 foi o que obteve melhor desempenho, considerando os valores das seguintes métricas MAE 0.0036, MAPE 0.0012% e RMSE 0.0143. Como pode ser observado, diante dos melhores resultados expostos, as redes *Deep Feedforward* e LSTM, usadas nos experimentos, que originaram cada modelo, tiveram melhor desempenho, quando, as simulações foram feitas com a base de dados da estação eólica de Petrolina, esse aspecto pode inclusive ser observado na comparação de previsões feitas entre as duas estações eólicas no trabalho de (ALENCAR, 2018), especificamente na tabela 5.11, onde são apresentadas as métricas de erros entre as bases de Petrolina e Macau na grandeza de horas.

Segundo os dados descritos na tabela 3.1, pode-se concluir, que o melhor modelo estimado, foi o de curto prazo, dessa forma, pode-se deduzir que a melhor aplicação desse modelo é para o planejamento do despacho econômico de carga, onde para estações eólicas esse processo depende, principalmente, da disponibilidade de ventos, para que decisões razoáveis sobre a carga e segurança operacional no mercado de eletricidade, sejam tomadas de forma acertada.

Geralmente é possível observar melhores resultados no uso da rede LSTM em situações onde há uma maior quantidade de dados para treinar e validar a rede, enquanto para DFF a situação é oposta, o desempenho é superior quando há uma menor quantidade de dados aliada a um número maior de camadas ocultas. Entretanto, os resultados obtidos neste trabalho, apontam um melhor desempenho geral da rede LSTM tanto com maior quantidade de dados, usando a base completa das estações eólicas, quanto com menos dados, usando 1/3 da base completa. Somente em um modelo a rede DFF possui um desempenho claramente superior ao da rede LSTM, como foi o caso do modelo 10. O caso específico de superioridade da rede DFF no modelo 10, se deve justamente ao fato de ter sido usada a base de dados alternativa de Petrolina, citada na seção 4.3.2, onde a mesma possui apenas 1308 registros no total, então, apesar de também, desse modelo ter uma menor quantidade de camadas comparando com os demais, evidencia a afirmação de que a rede DFF possui um melhor desempenho ao ser utilizada uma base de dados com menos registros.

Apesar do melhor desempenho do modelo 5, os modelos 8, 9, 11 e 12 apresentam uma velocidade média do vento mais adequada para geração de energia eólica, onde segundo (ALENCAR, 2018), tendo como base um aerogerador WES100, para se ter um bom rendimento e gerar 100kWh de energia por mês é necessário pelo menos uma velocidade do vento de 5.4m/s. Apesar de não ter uma velocidade média favorável, o modelo 5 ainda sim é melhor, pois o objetivo era justamente prever a velocidade do vento,

então é mais válido apontar como um melhor modelo aquele que teve uma acurácia de 100% nas previsões, considerando o submodelo 2 exposto no gráfico 5.3, com uma margem de erro de 2% ou mais.

Para concluir os experimentos realizados e descritos no apêndice A, utilizar a biblioteca *keras tuner* foi de suma importância, pois uma ferramenta de *auto-tunning* como essa diminui o esforço para se encontrar bons hiper parâmetros e a partir deles tentar melhorar os resultados em experimentos com ajuste manual. Uma outra prática que ajudou na busca por modelos melhores, foi a utilização dos *Ensemble methods*, pois com o uso deles foi possível fazer combinações de resultados de um comitê de máquinas para gerar resultados mais satisfatórios.

### 6.0.1 Sugestões para trabalhos futuros

Para sugestão de trabalhos futuros pode-se indicar algumas aplicações de técnicas e métodos para otimizar ainda mais os resultados obtidos neste trabalho, como, por exemplo, otimização por enxame de partículas para *auto-tunning* dos hiper parâmetros das redes neurais profundas, onde de forma interativa seria otimizada ainda a busca dos hiper parâmetros, sendo esse processo direcionado pelas indicações iniciais feitas pelo *keras tuner*.

Uma outra abordagem interessante seria remover *outliers* das bases de dados utilizadas, pois podem haver inconsistências quando são medidas as variáveis meteorológicas registradas na base de dados original, portanto seria pertinente tentar balancear os dados a partir da remoção de *outliers* identificados.

## REFERÊNCIAS

- ABEÉOLICA. **Boletim anual 2020**. 2020. Disponível em: <[http://abeeolica.org.br/wp-content/uploads/2021/06/PT\\_Boletim-Anual-de-Gera%C3%A7%C3%A3o-2020.pdf](http://abeeolica.org.br/wp-content/uploads/2021/06/PT_Boletim-Anual-de-Gera%C3%A7%C3%A3o-2020.pdf)>. Acesso em: 20 de agosto de 2021. Citado na página 14.
- ADHIKARI, R.; AGRAWAL, R. K. An introductory study on time series modeling and forecasting. **CoRR**, abs/1302.6613, 2013. Disponível em: <<https://arxiv.org/abs/1302.6613>>. Citado na página 29.
- ALENCAR, D. B. de. **Modelo híbrido baseado em séries temporais e Redes Neurais para previsão de geração de energia eólica**. 2018. 120 f. Dissertação (Doutorado em Engenharia Elétrica) — Universidade Federal do Pará. Programa de Pós-Graduação em Engenharia Elétrica, Belém, PA, Brasil, 2018. Disponível em: <<http://repositorio.ufpa.br/jspui/handle/2011/10416>>. Citado 21 vezes nas páginas 16, 17, 18, 19, 22, 23, 25, 31, 40, 41, 42, 43, 44, 49, 51, 52, 53, 54, 56, 59 e 61.
- ALVES, J. J. A. Análise regional da energia eólica no brasil. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 6, n. 1, p. 165 – 188, 2010. ISSN 1809-239X. Disponível em: <<https://www.rbhdr.net/revista/index.php/rbhdr/article/view/266>>. Citado na página 23.
- ASSEISS, M. da S. G. **Aplicação do processo de descoberta de conhecimento em banco de dados acadêmico utilizando as tarefas de agrupamento e classificação**. 2017. 117 f. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Estadual Paulista. Programa de Pós-Graduação em Engenharia Elétrica, Ilha Solteira, SP, Brasil, 2017. Citado 2 vezes nas páginas 27 e 28.
- AZANK, F. **Modelos de predição | KNN**. 2019. Disponível em: <<https://medium.com/turing-talks/turing-talks-13-modelo-de-predi%C3%A7%C3%A3o-knn-3be880c9b9d1>>. Acesso em: 02 de março de 2021. Citado na página 17.
- AZEVEDO, E. M. de. **Crescimento da energia eólica no Brasil**. 2020. Disponível em: <<https://administradores.com.br/artigos/crescimento-da-energia-e%C3%B3lica-no-brasil>>. Acesso em: 23 de abril de 2020. Citado na página 16.
- BEZERRA, E. C.; REGO, M. C. do; BRAGA, A. P. de S.; LEAO, R. P. S. Comparação entre modelos estatísticos e redes neurais usando persistência como referência para a previsão da velocidade do vento. In: **Simpósio Brasileiro de Automação Inteligente, São João del-Rei, Brasil**. [S.l.: s.n.], 2011. Citado na página 21.
- BOENTE, A. N. P.; GOLDSCHMIDT, R. R.; ESTRELA, V. V. Uma metodologia de suporte ao processo de descoberta de conhecimento em bases de dados. In: **Simpósio de Excelência em Gestão e Tecnologia, Rio de Janeiro, Brasi**. [S.l.: s.n.], 2008. p. 4–5. Citado 2 vezes nas páginas 27 e 28.
- DEMUTH, H. B.; HAGAN, M. T.; BEALE, M. H. **Neural network design**. 2<sup>a</sup>. ed. [S.l.]: Martin Hagan, 2008. ISBN 978-0971732117. Citado na página 33.

- DONGMEI, Z.; YUCHEN, Z.; XU, Z. Research on wind power forecasting in wind farms. **Power Engineering and Automation Conference (PEAM)**, p. 175 – 178, 2011. Citado na página 30.
- DUTRA, R. **Energia Eólica: Princípios e Tecnologia**. [S.l.]: Centro de Referência para Energia Solar e Eólica Sérgio Britto, 2011. Citado 2 vezes nas páginas 24 e 26.
- EHLERS, R. S. Análise de séries temporais. 2007. Disponível em: <<https://www.icmc.usp.br/pessoas/ehlers/stemp/stemp.pdf>>. Citado na página 29.
- FARIAS, J. B.; TREVISAN, L. V. Séries temporais. 2013. Citado na página 29.
- FARIAS, J. G. de. **Machine learning aplicado à previsão de geração de energia eólica com diferentes modelos de previsão numérica do tempo**. 2020. Dissertação (Tese de Mestrado) — Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil, 2020. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/220412>>. Citado 2 vezes nas páginas 15 e 21.
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, v. 17, p. 37 – 53, 1996. Citado 3 vezes nas páginas 26, 27 e 28.
- FEAM. Utilização da energia eólica no estado de minas gerais: aspectos técnicos e o meio ambiente. **Comunicado Técnico - Fundação Estadual do Meio Ambiente**, n. 2, 2013. Disponível em: <[http://www.feam.br/images/stories/materia/comunicado\\_tecnico2\\_gemuc.pdf](http://www.feam.br/images/stories/materia/comunicado_tecnico2_gemuc.pdf)>. Citado na página 23.
- FERRAZ, R. S. F.; CRUZ, F. da C.; FERRAZ, R. S. F.; CORREIA, A. F. S.; FILHO, E. F. de S. Previsão multi-passos da velocidade do vento através de redes neurais artificiais. In: **The 12th Latin-American Congress on Electricity Generation and Transmission - CLAGTEE 2017, Mar del Plata, Argentina**. [S.l.: s.n.], 2017. Citado 4 vezes nas páginas 16, 18, 21 e 22.
- FIGUEIREDO, Y.; CAMPOS, L. Machine learning for wind power forecasting. In: **The International Joint Conference on Neural Networks (IJCNN), 2021, Online, United States**. [S.l.: s.n.], 2021. Citado na página 41.
- FREIRE, M. **Utilização de Redes Neurais na Previsão da Velocidade do Vento**. 2014. Dissertação (Trabalho de Conclusão de Curso) — Universidade de Pernambuco, Recife, PE, Brasil, 2014. Citado na página 18.
- FUJISE, J. **Desenvolvimento de Modelo de Previsão de Geração Eólica para Planejamento Energético Utilizando Redes Neurais Artificiais**. 2018. Dissertação (Trabalho de Conclusão de Curso) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil, 2018. Disponível em: <<http://www.monografias.poli.ufrj.br/monografias/monopoli10027416.pdf>>. Citado na página 15.
- GLOBO, O. **Em dez anos, hidrelétricas perderão espaço na geração de energia para solar e eólica**. 2020. Disponível em: <<https://oglobo.globo.com/economia/em-dez-anos-hidreletricas-perderao-espaco-na-geracao-de-energia-para-solar-eolica-24242784>>. Acesso em: 23 de março de 2020. Citado na página 14.

GOLDSCHMIDT, R. R.; PASSOS, E. P. L. **Data mining: um guia prático - conceitos, técnicas, ferramentas, orientações e aplicações**. [S.l.]: Editora Campus, 2005. Citado na página 26.

HAN, J.; KAMBER, M. **Data mining: concepts and techniques**. 3<sup>a</sup>. ed. [S.l.]: Elsevier Science, 2006. Citado na página 28.

HAYKIN, S. S. **Neural Networks and Learning Machines**. 3<sup>a</sup>. ed. [S.l.]: Prentice Hall, 2008. ISBN 978-0131471399. Citado na página 31.

INMET. **Banco de Dados**. 2020. Disponível em: <<https://bdmep.inmet.gov.br/>>. Citado 2 vezes nas páginas 39 e 40.

JFPE. **Mapa de Pernambuco**. 2021. Disponível em: <<https://www.jfpe.jus.br/index.php/institucional/secao-subsecoes.html>>. Citado na página 44.

MAGALHAES, A.; CHAGAS, T. P. das. Predição da velocidade do vento utilizando redes neurais wavelet. **Anais do 14<sup>o</sup> Simpósio Brasileiro de Automação Inteligente**, v. 1, 2019. ISSN 2358-4483. Disponível em: <<https://proceedings.science/sbai-2019/papers/predicao-da-velocidade-do-vento-utilizando-redes-neurais-wavelet#>>. Citado na página 16.

MAPAS, B. **Mapa do Rio Grande do Norte**. 2021. Disponível em: <<https://www.baixarmapas.com.br/mapa-do-rio-grande-do-norte/>>. Citado na página 44.

MOURAO Ícaro de S. **Predição de séries temporais climáticas com aprendizagem profunda**. 2019. Dissertação (Trabalho de Conclusão de Curso) — Universidade Federal do Ceará, Crateús, CE, Brasil, 2019. Disponível em: <<http://www.repositorio.ufc.br/handle/riufc/49168>>. Citado na página 46.

NASCIMENTO, T. C.; MENDONÇA, A. T. B. B. de; CUNHA, S. K. da. Inovação e sustentabilidade na produção de energia: o caso do sistema setorial de energia eólica no brasil. **Cadernos EBAPE.BR**, v. 10, n. 3, p. 630 – 651, 2012. Disponível em: <<http://bibliotecadigital.fgv.br/ojs/index.php/cadernosebape/article/view/5488>>. Citado na página 23.

OLAOFE, Z.; FOLLY, K. Wind power estimation using recurrent neural network technique. In: **Power Engineering Society Conference and Exposition in Africa (PowerAfrica), 2012 IEEE, Johannesburg, South Africa**. [S.l.: s.n.], 2012. p. 1–7. Citado na página 32.

OLIVEIRA, F. M. B. **Previsão da velocidade do vento utilizando redes neurais artificiais e modelos autorregressivos**. 2020. Dissertação (Tese de Mestrado) — Universidade Tecnológica Federal do Paraná, Curitiba, PR, Brasil, 2020. Disponível em: <<http://riut.utfpr.edu.br/jspui/handle/1/23577>>. Citado 4 vezes nas páginas 16, 17, 18 e 21.

PEREIRA, M. de M. **Aprendizado profundo: Rede LSTM**. 2017. Dissertação (Trabalho de Conclusão de Curso) — Universidade Federal da Grande Dourados, Dourados, MS, Brasil, 2017. Disponível em: <<http://repositorio.ufgd.edu.br/jspui/handle/prefix/2887>>. Citado na página 35.

PICOLO, A. P.; RÜHLER, A. J.; RAMPINELLI, G. A. Uma abordagem sobre a energia eólica como alternativa de ensino de tópicos de física clássica. **Revista Brasileira de Ensino de Física**, v. 36, n. 4, 2014. ISSN 1806-1117. Disponível em: <[https://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1806-11172014000400007&lng=pt&tlng=pt](https://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-11172014000400007&lng=pt&tlng=pt)>. Citado 2 vezes nas páginas 24 e 25.

RAMALHO, G. L. B.; DIAS, S. V. Estimativa da velocidade média diária do vento no município de Fortaleza utilizando redes neurais artificiais. **Conexões - Ciência e Tecnologia**, v. 3, p. 12 – 15, 2009. ISSN 2176-0144. Disponível em: <<http://conexoes.ifce.edu.br/index.php/conexoes/article/view/123/114>>. Citado 2 vezes nas páginas 17 e 21.

ROSSI, D. J. **Previsão da velocidade dos ventos por Redes Neurais Artificiais e ARIMA de Box Jenkins**. 2013. 76 f. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Estadual Paulista. Programa de Pós-Graduação em Engenharia Elétrica, Ilha Solteira, SP, Brasil, 2013. Disponível em: <<https://repositorio.unesp.br/bitstream/handle/11449/111121/000795776.pdf?sequence=1&isAllowed=y>>. Citado na página 15.

SANTOS, J. A. A. dos; SPANCERSKI, J. Aplicação de redes neurais recorrentes na previsão de geração eólica. **Revista CEREUS**, v. 13, n. 1, p. 217 – 227, 2021. Disponível em: <<http://ojs.unirg.edu.br/index.php/1/article/view/3385>>. Citado na página 16.

SIMAS, M.; PACCA, S. Energia eólica, geração de empregos e desenvolvimento sustentável. **Estudos Avançados**, v. 27, n. 77, 2013. ISSN 0103-4014. Disponível em: <[https://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-40142013000100008](https://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-40142013000100008)>. Citado na página 24.

SONDA. **Estação de Petrolina - Base de Dados**. 2020. Disponível em: <<http://sonda.ccst.inpe.br/basedados/petrolina.html>>. Citado 6 vezes nas páginas 39, 40, 42, 43, 45 e 52.

VALIPOUR, M.; BANIHABIB, M. E.; BEHBAHANI, S. M. R. Comparison of the arma, arima, and the autoregressive artificial neural network models in forecasting the monthly inflow of dez dam reservoir. **Journal of hydrology**, v. 476, p. 433–441, 2013. ISSN 0022-1694. Citado na página 30.

WANG, X.; GUO, P.; HUANG, X. A review of wind power forecasting models. **Energy Procedia**, v. 12, p. 770 – 778, 2011. ISSN 1876-6102. Citado na página 30.

YONGQIAN, L.; SUN, Y.; INFELD, D.; ZHAO, Y.; HAN, S.; YAN, J. A hybrid forecasting method for wind power ramp based on orthogonal test and support vector machine (ot-svm). **IEEE Transactions on Sustainable Energy**, v. 8, p. 451 – 457, 2017. ISSN 1949-3029. Disponível em: <<https://ieeexplore.ieee.org/document/7557081>>. Citado 2 vezes nas páginas 16 e 21.

ZHANG, Y.; WANG, J.; WANG, X. Review on probabilistic forecasting of wind power generation. **Renewable and Sustainable Energy Reviews**, v. 32, p. 255 – 270, 2014. ISSN 1045-9227. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1364032114000446>>. Citado na página 21.

ZHAO, X.; WANG, S.; LI, T. Review of evaluation criteria and main methods of wind power forecasting. **Energy Procedia**, v. 12, p. 761 – 769, 2011. ISSN 1876-6102. Citado na página 30.

## Apêndices

## APÊNDICE A – Resultados de todas as simulações realizadas

As tabelas listadas neste apêndice mostram todos os experimentos feitos e que deram origem aos modelos finais, somente os modelos em destaque, presentes na tabela 5.1. Em seguida são apresentados os significados de cada sigla presente nos cabeçalhos das tabelas deste apêndice.

- ID: Identificação do submodelo, onde a depender do método utilizado, *voting* ou *bagging*, há um padrão diferente de identificação, como mostrado abaixo.
  - *Voting*: Para o *voting* os submodelos seguiram um padrão como, por exemplo, 1a-LSTM, onde o 1 representa o ID do modelo final, "a" representa a identificação de ordem do submodelo e "LSTM" representa o tipo de Rede Neural Artificial utilizada.
  - *Bagging*: Para o *bagging* os submodelos seguiram um padrão como, por exemplo, 2a1-LSTM, onde o 2 representa o ID do modelo final, o "a" informa que foi usada a partição 1 da base de dados, o 1 representa a identificação de ordem do submodelo e "LSTM" representa o tipo de Rede Neural Artificial utilizada.
- EP: Número de épocas.
- OT: Otimizador.
- NINT: Número de neurônios das camadas internas.
- FAI: Função de ativação das camadas internas.
- FAS: Função de ativação da camada de saída.
- TAP: Taxa de aprendizado.

Tabela A.1 – Hiper parâmetros das simulações do modelo 1

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
1a-LSTM	4000	RMSprop	230	170	120	tanh	linear	0,01
1b-LSTM	3000	RMSprop	250	190	120	tanh	linear	0,001
1c-LSTM	3000	RMSprop	270	210	150	tanh	linear	0,006
1d-LSTM	3000	RMSprop	180	120	140	tanh	linear	0,002
1e-LSTM	4000	RMSprop	230	170	120	relu	linear	0,01
1f-LSTM	4000	RMSprop	240	180	140	relu	linear	0,02
1g-LSTM	4000	RMSprop	230	170	120	tanh	linear	0,009
1h-LSTM	4000	RMSprop	250	190	140	tanh	linear	0,008
1i-LSTM	4000	Adam	230	170	120	tanh	linear	0,009
1j-LSTM	5000	RMSprop	260	200	150	tanh	linear	0,007
1a-DFF	20000	Adam	180	110	180	relu	linear	0,1
1b-DFF	20000	Adam	200	130	200	relu	linear	0,009
1c-DFF	15000	Adam	210	150	200	relu	linear	0,008
1d-DFF	15000	Adam	220	160	210	relu	linear	0,007
1e-DFF	15000	Adam	180	160	200	relu	linear	0,006
1f-DFF	15000	Adam	160	140	180	linear	linear	0,006
1g-DFF	20000	Adam	120	150	130	relu	linear	0,006
1h-DFF	20000	SGD	110	140	120	relu	linear	0,006
1i-DFF	20000	SGD	130	160	150	relu	linear	0,005
1j-DFF	25000	Adam	160	190	180	relu	linear	0,005

Tabela A.2 – Métricas das simulações do modelo 1

ID	MAE	MAPE	RMSE	VMED
1a-LSTM	0,067	0,0328	0,0886	2,0417
1b-LSTM	0,0671	0,0329	0,0889	2,0417
1c-LSTM	0,0754	0,0369	0,101	2,0417
1d-LSTM	0,0671	0,0329	0,0889	2,0417
1e-LSTM	0,0676	0,0331	0,0888	2,0417
1f-LSTM	0,0753	0,0369	0,1	2,0417
1g-LSTM	0,025	0,0122	0,0394	2,0417
1h-LSTM	0,0814	0,0399	0,1088	2,0417
1i-LSTM	0,067	0,0328	0,0887	2,0417
1j-LSTM	0,0767	0,0376	0,1018	2,0417
1a-DFE	0,0859	0,0421	0,1129	2,0417
1b-DFE	0,0811	0,0397	0,1075	2,0417
1c-DFE	0,0785	0,0384	0,1042	2,0417
1d-DFE	0,0789	0,0386	0,1046	2,0417
1e-DFE	0,0775	0,038	0,1033	2,0417
1f-DFE	0,0908	0,0445	0,1192	2,0417
1g-DFE	0,077	0,0377	0,1022	2,0417
1h-DFE	0,0855	0,0419	0,113	2,0417
1i-DFE	0,0853	0,0418	0,1129	2,0417
1j-DFE	0,0776	0,038	0,1033	2,0417

Fonte: Autor

Tabela A.3 – Hiper parâmetros das simulações do modelo 2

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
2a1-LSTM	3000	RMSprop	220	160	130	tanh	linear	0,003
2a2-LSTM	3000	RMSprop	230	170	140	tanh	linear	0,004
2a3-LSTM	4000	RMSprop	250	190	160	tanh	linear	0,002
2a4-LSTM	4000	RMSprop	240	190	130	tanh	linear	0,001
2a5-LSTM	5000	RMSprop	250	200	140	relu	linear	0,003
2b1-LSTM	3000	RMSprop	100	250	110	tanh	linear	0,001
2b2-LSTM	3000	RMSprop	110	260	120	tanh	linear	0,002
2b3-LSTM	4000	RMSprop	130	270	150	tanh	linear	0,003
2b4-LSTM	4000	RMSprop	110	250	110	tanh	linear	0,004
2b5-LSTM	4000	RMSprop	120	260	120	tanh	linear	0,009
2c1-LSTM	4000	RMSprop	190	140	120	tanh	linear	0,003
2c2-LSTM	4000	RMSprop	200	150	130	tanh	linear	0,004
2c3-LSTM	4000	RMSprop	220	170	150	tanh	linear	0,002
2c4-LSTM	5000	RMSprop	240	190	160	tanh	linear	0,001
2c5-LSTM	5000	RMSprop	180	130	110	tanh	linear	0,003

Fonte: Autor

Tabela A.4 – Métricas das simulações do modelo 2

ID	MAE	MAPE	RMSE	VMED
2a1-LSTM	0,074	0,0215	0,097	3,4496
2a2-LSTM	0,082	0,0238	0,1063	3,4496
2a3-LSTM	0,0773	0,0224	0,0998	3,4496
2a4-LSTM	0,078	0,0226	0,1001	3,4496
2a5-LSTM	0,0742	0,0215	0,0964	3,4496
2b1-LSTM	0,0685	0,0477	0,0914	1,4364
2b2-LSTM	0,0681	0,0474	0,0905	1,4364
2b3-LSTM	0,0674	0,0469	0,0898	1,4364
2b4-LSTM	0,0667	0,0464	0,089	1,4364
2b5-LSTM	0,0696	0,0485	0,0937	1,4364
2c1-LSTM	0,0643	0,0334	0,088	1,9273
2c2-LSTM	0,0655	0,034	0,0889	1,9273
2c3-LSTM	0,0653	0,0339	0,0886	1,9273
2c4-LSTM	0,0661	0,0343	0,0896	1,9273
2c5-LSTM	0,0643	0,0334	0,0877	1,9273

Fonte: Autor

Tabela A.5 – Hiper parâmetros das simulações do modelo 3

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
3a1-DFE	20000	Adam	210	180	210	relu	linear	0,001
3a2-DFE	25000	Adam	220	190	220	relu	linear	0,01
3a3-DFE	30000	Adam	250	220	250	relu	linear	0,002
3a4-DFE	30000	Adam	200	170	200	relu	linear	0,008
3a5-DFE	30000	Adam	180	150	180	relu	linear	0,009
3b1-DFE	20000	Adam	140	140	210	relu	linear	0,002
3b2-DFE	30000	Adam	160	160	230	relu	linear	0,02
3b3-DFE	30000	Adam	150	150	220	relu	linear	0,009
3b4-DFE	30000	SGD	200	200	250	relu	linear	0,001
3b5-DFE	30000	Adam	180	180	230	linear	linear	0,002
3c1-DFE	25000	Adam	180	180	220	relu	linear	0,006
3c2-DFE	30000	Adam	200	200	240	relu	linear	0,007
3c3-DFE	30000	Adam	210	210	250	relu	linear	0,009
3c4-DFE	30000	Adam	190	180	220	relu	linear	0,005
3c5-DFE	30000	Adam	200	200	210	relu	linear	0,06

Fonte: Autor

Tabela A.6 – Métricas das simulações do modelo 3

ID	MAE	MAPE	RMSE	VMED
3a1-DFF	0,088	0,0255	0,1138	3,4496
3a2-DFF	0,0909	0,0264	0,1171	3,4496
3a3-DFF	0,0892	0,0259	0,1152	3,4496
3a4-DFF	0,0895	0,0259	0,1156	3,4496
3a5-DFF	0,0919	0,0266	0,1183	3,4496
3b1-DFF	0,0749	0,0521	0,1001	1,4364
3b2-DFF	0,0839	0,0584	0,111	1,4364
3b3-DFF	0,0769	0,0535	0,1022	1,4364
3b4-DFF	0,0874	0,0608	0,1153	1,4364
3b5-DFF	0,0927	0,0645	0,122	1,4364
3c1-DFF	0,0731	0,0379	0,0982	1,9273
3c2-DFF	0,0892	0,0463	0,1203	1,9273
3c3-DFF	0,0891	0,0462	0,1203	1,9273
3c4-DFF	0,0891	0,0462	0,1203	1,9273
3c5-DFF	0,0891	0,0462	0,1203	1,9273

Fonte: Autor

Tabela A.7 – Hiper parâmetros das simulações do modelo 4

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
4a-DFF	20000	Adam	220	110	130	relu	linear	0,1
4b-DFF	30000	Adam	230	120	140	relu	linear	0,3
4c-DFF	30000	Adam	240	130	150	relu	linear	0,09
4d-DFF	30000	Adam	200	100	130	relu	linear	0,009
4e-DFF	30000	Adam	210	120	140	relu	linear	0,008
4f-DFF	40000	SGD	190	100	120	relu	linear	0,009
4g-DFF	40000	Adam	220	110	130	relu	linear	0,009
4h-DFF	40000	Adam	220	110	130	linear	linear	0,009
4i-DFF	40000	Adam	220	110	130	relu	relu	0,009
4j-DFF	40000	Adam	250	100	160	relu	linear	0,009
4a-LSTM	4000	RMSprop	220	170	190	tanh	linear	0,003
4b-LSTM	5000	RMSprop	230	180	200	tanh	linear	0,005
4c-LSTM	5000	RMSprop	250	210	220	tanh	linear	0,009
4d-LSTM	5000	RMSprop	240	200	210	tanh	linear	0,002
4e-LSTM	5000	RMSprop	230	190	200	tanh	linear	0,001
4f-LSTM	5000	RMSprop	200	160	170	tanh	linear	0,09
4g-LSTM	5000	RMSprop	190	150	160	relu	linear	0,003
4h-LSTM	5000	Adam	190	150	160	tanh	linear	0,003
4i-LSTM	5000	RMSprop	180	150	150	tanh	linear	0,004
4j-LSTM	5000	SGD	220	170	190	tanh	linear	0,003

Fonte: Autor

Tabela A.8 – Métricas das simulações do modelo 4

ID	MAE	MAPE	RMSE	VMED
4a-DFf	0,0108	0,0041	0,0335	2,6378
4b-DFf	0,1005	0,0381	0,1314	2,6378
4c-DFf	0,1005	0,0381	0,1313	2,6378
4d-DFf	0,0097	0,0037	0,0305	2,6378
4e-DFf	0,01	0,0038	0,0312	2,6378
4f-DFf	0,0101	0,0038	0,0315	2,6378
4g-DFf	0,0098	0,0037	0,0306	2,6378
4h-DFf	0,011	0,0042	0,0347	2,6378
4i-DFf	0,0098	0,0037	0,0305	2,6378
4j-DFf	0,0098	0,0037	0,0303	2,6378
4a-LSTM	0,0022	0,0008	0,012	2,6378
4b-LSTM	0,0102	0,0039	0,0324	2,6378
4c-LSTM	0,1005	0,0381	0,1131	2,6378
4d-LSTM	0,0022	0,0008	0,0121	2,6378
4e-LSTM	0,0025	0,0009	0,0127	2,6378
4f-LSTM	0,0025	0,0009	0,0127	2,6378
4g-LSTM	0,0063	0,0024	0,0151	2,6378
4h-LSTM	0,0023	0,0009	0,0132	2,6378
4i-LSTM	0,0033	0,0013	0,013	2,6378
4j-LSTM	0,0108	0,0041	0,0299	2,6378

Fonte: Autor

Tabela A.9 – Hiper parâmetros das simulações do modelo 5

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
5a1-LSTM	4000	RMSprop	110	220	240	tanh	linear	0,003
5a2-LSTM	5000	RMSprop	120	230	250	tanh	linear	0,004
5a3-LSTM	5000	RMSprop	150	250	220	tanh	linear	0,009
5a4-LSTM	5000	RMSprop	130	230	210	tanh	linear	0,002
5a5-LSTM	5000	Adam	110	220	240	tanh	linear	0,003
5b1-LSTM	4000	RMSprop	120	210	100	tanh	linear	0,002
5b2-LSTM	5000	RMSprop	130	220	110	tanh	linear	0,003
5b3-LSTM	5000	RMSprop	150	240	130	tanh	linear	0,004
5b4-LSTM	5000	RMSprop	140	230	120	tanh	linear	0,009
5b5-LSTM	5000	RMSprop	100	190	100	tanh	linear	0,001
5c1-LSTM	4000	RMSprop	110	180	210	tanh	linear	0,003
5c2-LSTM	5000	RMSprop	130	210	240	tanh	linear	0,004
5c3-LSTM	5000	RMSprop	160	240	250	tanh	linear	0,002
5c4-LSTM	5000	RMSprop	190	250	220	tanh	linear	0,001
5c5-LSTM	5000	Adam	110	180	210	tanh	linear	0,003

Fonte: Autor

Tabela A.10 – Métricas das simulações do modelo 5

ID	MAE	MAPE	RMSE	VMED
5a1-LSTM	0,0039	0,0011	0,0101	3,6253
5a2-LSTM	0,0093	0,0026	0,0238	3,6253
5a3-LSTM	0,0139	0,0038	0,0276	3,6253
5a4-LSTM	0,0052	0,0014	0,0125	3,6253
5a5-LSTM	0,0041	0,0011	0,0119	3,6253
5b1-LSTM	0,0038	0,0013	0,017	2,9914
5b2-LSTM	0,0042	0,0014	0,0176	2,9914
5b3-LSTM	0,0068	0,0023	0,0263	2,9914
5b4-LSTM	0,0181	0,0061	0,0478	2,9914
5b5-LSTM	0,0042	0,0014	0,0177	2,9914
5c1-LSTM	0,0032	0,0012	0,0158	2,702
5c2-LSTM	0,098	0,0363	0,1098	2,702
5c3-LSTM	0,0034	0,0013	0,0167	2,702
5c4-LSTM	0,006	0,0022	0,0225	2,702
5c5-LSTM	0,006	0,0022	0,0225	2,702

Fonte: Autor

Tabela A.11 – Hiper parâmetros das simulações do modelo 6

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
6a1-DFF	20000	Adam	250	120	200	relu	linear	0,1
6a2-DFF	30000	Adam	250	130	210	relu	linear	0,01
6a3-DFF	30000	Adam	210	100	180	relu	linear	0,001
6a4-DFF	30000	Adam	230	120	210	relu	linear	0,002
6a5-DFF	30000	Adam	250	140	230	relu	linear	0,003
6b1-DFF	20000	Adam	240	160	240	relu	linear	0,4
6b2-DFF	30000	Adam	250	170	250	relu	linear	0,04
6b3-DFF	30000	Adam	200	120	200	relu	linear	0,004
6b4-DFF	30000	Adam	220	140	220	relu	linear	0,003
6b5-DFF	30000	SGD	200	120	200	relu	linear	0,001
6c1-DFF	25000	Adam	150	170	110	relu	linear	0,5
6c2-DFF	30000	Adam	180	200	140	relu	linear	0,05
6c3-DFF	30000	Adam	200	220	160	relu	linear	0,005
6c4-DFF	35000	Adam	210	230	170	relu	linear	0,003
6c5-DFF	35000	Adam	150	170	110	relu	linear	0,009

Fonte: Autor

Tabela A.12 – Métricas das simulações do modelo 6

ID	MAE	MAPE	RMSE	VMED
6a1-DFF	0,0131	0,0036	0,0297	3,6253
6a2-DFF	0,0099	0,0027	0,0238	3,6253
6a3-DFF	0,0095	0,0026	0,0231	3,6253
6a4-DFF	0,0095	0,0026	0,0232	3,6253
6a5-DFF	0,0094	0,0026	0,0232	3,6253
6b1-DFF	0,0473	0,0158	0,0616	2,9914
6b2-DFF	0,0143	0,0048	0,04	2,9914
6b3-DFF	0,0118	0,0039	0,0369	2,9914
6b4-DFF	0,0119	0,004	0,0371	2,9914
6b5-DFF	0,015	0,005	0,042	2,9914
6c1-DFF	0,0335	0,0124	0,0717	2,702
6c2-DFF	0,0116	0,0043	0,0396	2,702
6c3-DFF	0,0084	0,0031	0,0367	2,702
6c4-DFF	0,0087	0,0032	0,0369	2,702
6c5-DFF	0,0084	0,0031	0,0367	2,702

Fonte: Autor

Tabela A.13 – Hiper parâmetros das simulações do modelo 7

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
7a-DFF	25000	Adam	120	170	110	relu	linear	0,4
7b-DFF	30000	Adam	140	190	130	relu	linear	0,04
7c-DFF	30000	Adam	160	220	150	relu	linear	0,004
7d-DFF	35000	Adam	200	250	190	relu	linear	0,001
7e-DFF	35000	SGD	210	240	200	relu	linear	0,006
7f-DFF	35000	Adam	220	250	210	relu	linear	0,009
7g-DFF	35000	Adam	250	210	240	relu	linear	0,007
7h-DFF	40000	Adam	200	170	190	relu	linear	0,003
7i-DFF	40000	Adam	180	150	170	linear	linear	0,001
7j-DFF	40000	Adam	120	170	110	relu	linear	0,001
7a-LSTM	4000	RMSprop	100	200	140	tanh	linear	0,001
7b-LSTM	5000	RMSprop	120	220	160	tanh	linear	0,002
7c-LSTM	5000	RMSprop	150	250	210	tanh	linear	0,005
7d-LSTM	5000	RMSprop	180	220	230	tanh	linear	0,009
7e-LSTM	5000	RMSprop	200	240	250	tanh	linear	0,003
7f-LSTM	5000	RMSprop	210	250	230	relu	linear	0,002
7g-LSTM	5000	RMSprop	200	240	220	relu	linear	0,005
7h-LSTM	5000	Adam	150	250	210	tanh	linear	0,005
7i-LSTM	5000	RMSprop	200	250	240	tanh	linear	0,006
7j-LSTM	5000	RMSprop	150	250	210	tanh	linear	0,004

Fonte: Autor

Tabela A.14 – Métricas das simulações do modelo 7

ID	MAE	MAPE	RMSE	VMED
7a-DFE	0,1529	0,0458	0,1948	3,3402
7b-DFE	0,1524	0,0456	0,192	3,3402
7c-DFE	0,1342	0,0402	0,173	3,3402
7d-DFE	0,1338	0,0401	0,1726	3,3402
7e-DFE	0,1395	0,0418	0,1776	3,3402
7f-DFE	0,1367	0,0409	0,1751	3,3402
7g-DFE	0,1357	0,0406	0,1741	3,3402
7h-DFE	0,1354	0,0405	0,174	3,3402
7i-DFE	0,1458	0,0437	0,1837	3,3402
7j-DFE	0,1336	0,04	0,1723	3,3402
7a-LSTM	0,0093	0,0028	0,019	3,3402
7b-LSTM	0,0084	0,0025	0,0181	3,3402
7c-LSTM	0,0074	0,0022	0,0143	3,3402
7d-LSTM	0,0089	0,0027	0,0188	3,3402
7e-LSTM	0,0105	0,0031	0,0241	3,3402
7f-LSTM	0,0079	0,0024	0,0161	3,3402
7g-LSTM	0,05	0,015	0,0753	3,3402
7h-LSTM	0,0127	0,0038	0,025	3,3402
7i-LSTM	0,0137	0,0041	0,0283	3,3402
7j-LSTM	0,0106	0,0032	0,0214	3,3402

Fonte: Autor

Tabela A.15 – Hiper parâmetros das simulações do modelo 8

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
8a1-LSTM	4000	RMSprop	240	140	200	tanh	linear	0,003
8a2-LSTM	5000	RMSprop	250	150	210	tanh	linear	0,004
8a3-LSTM	5000	RMSprop	220	160	190	tanh	linear	0,006
8a4-LSTM	5000	RMSprop	200	140	170	tanh	linear	0,001
8a5-LSTM	5000	RMSprop	240	140	200	tanh	linear	0,002
8b1-LSTM	4000	RMSprop	200	240	240	tanh	linear	0,003
8b2-LSTM	5000	RMSprop	230	250	250	tanh	linear	0,002
8b3-LSTM	5000	RMSprop	250	220	210	tanh	linear	0,001
8b4-LSTM	5000	RMSprop	210	180	170	tanh	linear	0,005
8b5-LSTM	5000	RMSprop	200	240	240	tanh	linear	0,009
8c1-LSTM	4000	RMSprop	100	130	120	tanh	linear	0,01
8c2-LSTM	5000	RMSprop	120	150	140	tanh	linear	0,001
8c3-LSTM	5000	RMSprop	150	180	170	tanh	linear	0,06
8c4-LSTM	5000	RMSprop	180	210	200	tanh	linear	0,02
8c5-LSTM	5000	Adam	200	240	230	tanh	linear	0,01

Fonte: Autor

Tabela A.16 – Métricas das simulações do modelo 8

ID	MAE	MAPE	RMSE	VMED
8a1-LSTM	0,0515	0,0093	0,0732	5,5098
8a2-LSTM	0,0509	0,0092	0,0736	5,5098
8a3-LSTM	0,129	0,0234	0,1576	5,5098
8a4-LSTM	0,0728	0,0132	0,0963	5,5098
8a5-LSTM	0,0707	0,0128	0,0932	5,5098
8b1-LSTM	0,0256	0,0042	0,0474	6,1026
8b2-LSTM	0,0227	0,0037	0,0433	6,1026
8b3-LSTM	0,0604	0,0099	0,0946	6,1026
8b4-LSTM	0,0479	0,0078	0,0737	6,1026
8b5-LSTM	0,0398	0,0065	0,0635	6,1026
8c1-LSTM	0,0233	0,0067	0,0425	3,4938
8c2-LSTM	0,0628	0,018	0,0913	3,4938
8c3-LSTM	0,167	0,0478	0,2023	3,4938
8c4-LSTM	0,0618	0,0177	0,0874	3,4938
8c5-LSTM	0,167	0,0478	0,2021	3,4938

Fonte: Autor

]

Tabela A.17 – Hiper parâmetros das simulações do modelo 9

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
9a1-DFF	30000	Adam	250	110	140	relu	linear	0,1
9a2-DFF	35000	Adam	260	120	150	relu	linear	0,01
9a3-DFF	35000	Adam	240	140	170	relu	linear	0,001
9a4-DFF	35000	Adam	230	130	150	relu	linear	0,002
9a5-DFF	40000	SGD	200	100	120	relu	linear	0,001
9b1-DFF	30000	Adam	200	140	110	relu	linear	0,01
9b2-DFF	35000	Adam	220	160	130	relu	linear	0,001
9b3-DFF	40000	Adam	250	190	160	relu	linear	0,002
9b4-DFF	40000	SGD	210	150	120	relu	linear	0,001
9b5-DFF	40000	Adam	240	180	170	relu	linear	0,009
9c1-DFF	30000	Adam	150	120	200	relu	linear	0,001
9c2-DFF	35000	Adam	180	150	230	relu	linear	0,003
9c3-DFF	35000	Adam	210	170	250	relu	linear	0,09
9c4-DFF	40000	Adam	220	180	250	relu	linear	0,007
9c5-DFF	40000	SGD	150	120	200	relu	linear	0,001

Fonte: Autor

Tabela A.18 – Métricas das simulações do modelo 9

ID	MAE	MAPE	RMSE	VMED
9a1-DFF	0,1629	0,0296	0,1955	5,5098
9a2-DFF	0,1542	0,028	0,1896	5,5098
9a3-DFF	0,1524	0,0277	0,1883	5,5098
9a4-DFF	0,1526	0,0277	0,1886	5,5098
9a5-DFF	0,1599	0,029	0,1941	5,5098
9b1-DFF	0,1204	0,0197	0,1671	6,1026
9b2-DFF	0,1201	0,0197	0,166	6,1026
9b3-DFF	0,1202	0,0197	0,1663	6,1026
9b4-DFF	0,1223	0,02	0,1683	6,1026
9b5-DFF	0,1204	0,0197	0,167	6,1026
9c1-DFF	0,1415	0,0405	0,1794	3,4938
9c2-DFF	0,1475	0,0422	0,1813	3,4938
9c3-DFF	0,167	0,0478	0,202	3,4938
9c4-DFF	0,149	0,0426	0,1825	3,4938
9c5-DFF	0,1603	0,0459	0,1936	3,4938

Fonte: Autor

Tabela A.19 – Hiper parâmetros das simulações do modelo 10

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
10a-DFF	10000	Adam	80	70		relu	linear	0,1
10b-DFF	10000	Adam	90	80		relu	linear	0,1
10c-DFF	10000	Adam	100	90		relu	linear	0,1
10d-DFF	10000	Adam	90	80		relu	linear	0,2
10e-DFF	10000	Adam	90	80		relu	linear	0,3
10f-DFF	10000	Adam	90	80		relu	linear	0,4
10g-DFF	10000	Adam	90	80		relu	linear	0,3
10h-DFF	10000	SGD	90	80		relu	relu	0,3
10i-DFF	10000	Adam	90	80		linear	linear	0,3
10j-DFF	10000	Adam	90	80		linear	linear	0,5
10a-LSTM	2000	RMSprop	100	80		tanh	linear	0,06
10b-LSTM	2000	RMSprop	100	80		tanh	linear	0,001
10c-LSTM	2000	RMSprop	110	90		tanh	linear	0,001
10d-LSTM	2000	RMSprop	120	100		tanh	linear	0,001
10e-LSTM	3000	RMSprop	110	90		tanh	linear	0,001
10f-LSTM	3000	RMSprop	110	90		tanh	linear	0,01
10g-LSTM	3000	Adam	110	90		tanh	linear	0,001
10h-LSTM	3000	RMSprop	110	90		tanh	linear	0,002
10i-LSTM	3000	RMSprop	110	90		tanh	linear	0,003
10j-LSTM	4000	RMSprop	110	90		tanh	linear	0,001

Fonte: Autor

Tabela A.20 – Métricas das simulações do modelo 10

ID	MAE	MAPE	RMSE	VMED
10a-DFF	0,0063	0,0023	0,0067	2,7714
10b-DFF	0,0058	0,0021	0,0062	2,7714
10c-DFF	0,0075	0,0027	0,0065	2,7714
10d-DFF	0,0029	0,001	0,003	2,7714
10e-DFF	0,0021	0,0008	0,0035	2,7714
10f-DFF	0,0027	0,001	0,0047	2,7714
10g-DFF	0,002	0,0007	0,0061	2,7714
10h-DFF	0,0024	0,0009	0,0027	2,7714
10i-DFF	0,0181	0,0065	0,0184	2,7714
10j-DFF	0,0192	0,0069	0,0208	2,7714
10a-LSTM	0,1215	0,0438	0,0487	2,7714
10b-LSTM	0,0081	0,0029	0,0143	2,7714
10c-LSTM	0,0071	0,0026	0,0053	2,7714
10d-LSTM	0,0074	0,0027	0,0065	2,7714
10e-LSTM	0,0076	0,0027	0,0099	2,7714
10f-LSTM	0,0334	0,0121	0,0737	2,7714
10g-LSTM	0,0578	0,0209	0,0679	2,7714
10h-LSTM	0,0071	0,0026	0,0075	2,7714
10i-LSTM	0,0066	0,0024	0,0055	2,7714
10j-LSTM	0,0043	0,0016	0,0057	2,7714

Fonte: Autor

Tabela A.21 – Hiper parâmetros das simulações do modelo 11

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
11a1-LSTM	4000	RMSprop	230	220	220	tanh	linear	0,003
11a2-LSTM	5000	RMSprop	250	240	240	tanh	linear	0,006
11a3-LSTM	5000	RMSprop	240	230	230	tanh	linear	0,002
11a4-LSTM	5000	RMSprop	200	190	180	tanh	linear	0,001
11a5-LSTM	5000	RMSprop	190	180	170	tanh	linear	0,09
11b1-LSTM	4000	RMSprop	240	230	250	tanh	linear	0,002
11b2-LSTM	5000	RMSprop	250	240	250	tanh	linear	0,001
11b3-LSTM	5000	RMSprop	210	200	210	tanh	linear	0,003
11b4-LSTM	5000	RMSprop	190	180	190	tanh	linear	0,006
11b5-LSTM	5000	RMSprop	170	160	170	tanh	linear	0,009
11c1-LSTM	4000	RMSprop	180	220	150	tanh	linear	0,003
11c2-LSTM	5000	RMSprop	200	240	170	tanh	linear	0,002
11c3-LSTM	5000	RMSprop	220	250	190	tanh	linear	0,004
11c4-LSTM	5000	RMSprop	150	180	170	tanh	linear	0,009
11c5-LSTM	5000	RMSprop	160	190	180	tanh	linear	0,001

Fonte: Autor

Tabela A.22 – Métricas das simulações do modelo 11

ID	MAE	MAPE	RMSE	VMED
11a1-LSTM	0,0734	0,0088	0,0954	8,3502
11a2-LSTM	0,1057	0,0127	0,1324	8,3502
11a3-LSTM	0,0751	0,009	0,0974	8,3502
11a4-LSTM	0,0769	0,0092	0,0993	8,3502
11a5-LSTM	0,1542	0,0185	0,1868	8,3502
11b1-LSTM	0,0916	0,0111	0,1178	8,245
11b2-LSTM	0,096	0,0116	0,1216	8,245
11b3-LSTM	0,0957	0,0116	0,1217	8,245
11b4-LSTM	0,1218	0,0148	0,153	8,245
11b5-LSTM	0,0926	0,0112	0,1184	8,245
11c1-LSTM	0,059	0,007	0,081	8,4342
11c2-LSTM	0,0735	0,0087	0,0942	8,4342
11c3-LSTM	0,0617	0,0073	0,0833	8,4342
11c4-LSTM	0,1047	0,0124	0,1321	8,4342
11c5-LSTM	0,0748	0,0089	0,0949	8,4342

Fonte: Autor

Tabela A.23 – Hiper parâmetros das simulações do modelo 12

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
12a1-DFE	30000	Adam	240	110	250	relu	linear	0,01
12a2-DFE	35000	Adam	230	100	240	relu	linear	0,001
12a3-DFE	40000	Adam	210	120	220	relu	linear	0,009
12a4-DFE	40000	Adam	190	100	200	relu	linear	0,02
12a5-DFE	40000	Adam	170	140	180	relu	linear	0,09
12b1-DFE	30000	Adam	130	240	110	relu	linear	0,01
12b2-DFE	40000	Adam	150	250	140	relu	linear	0,001
12b3-DFE	40000	Adam	200	230	180	relu	linear	0,005
12b4-DFE	40000	Adam	220	250	200	relu	linear	0,009
12b5-DFE	40000	SGD	150	250	140	relu	linear	0,001
12c1-DFE	30000	Adam	230	110	230	relu	linear	0,01
12c2-DFE	40000	Adam	240	120	240	relu	linear	0,001
12c3-DFE	40000	Adam	250	130	250	relu	linear	0,005
12c4-DFE	40000	Adam	250	130	250	relu	linear	0,009
12c5-DFE	40000	Adam	250	130	250	relu	relu	0,005

Fonte: Autor

Tabela A.24 – Métricas das simulações do modelo 12

ID	MAE	MAPE	RMSE	VMED
12a1-DFE	0,1024	0,0123	0,1295	8,3502
12a2-DFE	0,1079	0,0129	0,1361	8,3502
12a3-DFE	0,1057	0,0127	0,1334	8,3502
12a4-DFE	0,1065	0,0128	0,1343	8,3502
12a5-DFE	0,1542	0,0185	0,1868	8,3502
12b1-DFE	0,1249	0,0151	0,1578	8,245
12b2-DFE	0,1235	0,015	0,1562	8,245
12b3-DFE	0,1245	0,0151	0,1574	8,245
12b4-DFE	0,1252	0,0152	0,1583	8,245
12b5-DFE	0,1292	0,0157	0,1622	8,245
12c1-DFE	0,104	0,0123	0,132	8,4342
12c2-DFE	0,1115	0,0132	0,1408	8,4342
12c3-DFE	0,1035	0,0123	0,1314	8,4342
12c4-DFE	0,1038	0,0123	0,1316	8,4342
12c5-DFE	0,1036	0,0123	0,1315	8,4342

Fonte: Autor

Tabela A.25 – Hiper parâmetros das simulações do modelo 13

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
13a-DFE	30000	Adam	130	160	170	relu	linear	0,001
13b-DFE	40000	Adam	150	180	190	relu	linear	0,003
13c-DFE	40000	Adam	180	210	220	relu	linear	0,09
13d-DFE	40000	Adam	200	230	240	relu	linear	0,0009
13e-DFE	40000	SGD	210	240	250	relu	linear	0,001
13f-DFE	40000	Adam	210	240	250	relu	linear	0,001
13g-DFE	50000	Adam	230	250	250	relu	linear	0,001
13h-DFE	40000	Adam	210	240	250	linear	linear	0,001
13i-DFE	40000	Adam	210	240	250	relu	relu	0,001
13j-DFE	40000	Adam	250	250	250	relu	linear	0,001
13a-LSTM	4000	RMSprop	100	150	140	tanh	linear	0,002
13b-LSTM	5000	RMSprop	150	200	190	tanh	linear	0,003
13c-LSTM	5000	RMSprop	160	210	200	tanh	linear	0,001
13d-LSTM	5000	RMSprop	170	220	210	tanh	linear	0,004
13e-LSTM	5000	RMSprop	180	230	220	tanh	linear	0,003
13f-LSTM	5000	Adam	150	200	190	tanh	linear	0,003
13g-LSTM	5000	RMSprop	150	200	190	relu	linear	0,003
13h-LSTM	5000	RMSprop	150	200	190	tanh	tanh	0,003
13i-LSTM	5000	RMSprop	200	250	240	tanh	linear	0,003
13j-LSTM	6000	SGD	200	250	240	tanh	linear	0,003

Fonte: Autor

Tabela A.26 – Métricas das simulações do modelo 13

ID	MAE	MAPE	RMSE	VMED
13a-DFF	0,113	0,0217	0,1433	5,2154
13b-DFF	0,4772	0,0915	0,5092	5,2154
13c-DFF	0,4772	0,0915	0,5092	5,2154
13d-DFF	0,1147	0,022	0,1452	5,2154
13e-DFF	0,1204	0,0231	0,1507	5,2154
13f-DFF	0,1114	0,0214	0,1414	5,2154
13g-DFF	0,114	0,0219	0,1444	5,2154
13h-DFF	0,1207	0,0231	0,1512	5,2154
13i-DFF	0,1119	0,0215	0,1419	5,2154
13j-DFF	0,1113	0,0213	0,1411	5,2154
13a-LSTM	0,008	0,0015	0,0142	5,2154
13b-LSTM	0,0058	0,0011	0,0091	5,2154
13c-LSTM	0,0941	0,018	0,1194	5,2154
13d-LSTM	0,0151	0,0029	0,0301	5,2154
13e-LSTM	0,006	0,0012	0,0103	5,2154
13f-LSTM	0,0921	0,0177	0,118	5,2154
13g-LSTM	0,0872	0,0167	0,1133	5,2154
13h-LSTM	0,0446	0,0086	0,0697	5,2154
13i-LSTM	0,0053	0,001	0,0082	5,2154
13j-LSTM	0,1035	0,0198	0,1311	5,2154

Fonte: Autor

Tabela A.27 – Hiper parâmetros das simulações do modelo 14

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
14a1-LSTM	4000	RMSprop	110	140	190	tanh	linear	0,003
14a2-LSTM	5000	RMSprop	130	170	220	tanh	linear	0,005
14a3-LSTM	5000	RMSprop	150	190	240	tanh	linear	0,001
14a4-LSTM	5000	RMSprop	180	220	250	tanh	linear	0,003
14a5-LSTM	5000	RMSprop	110	140	190	tanh	linear	0,002
14b1-LSTM	4000	RMSprop	200	180	160	tanh	linear	0,003
14b2-LSTM	5000	RMSprop	220	200	180	tanh	linear	0,001
14b3-LSTM	5000	RMSprop	230	210	190	tanh	linear	0,005
14b4-LSTM	5000	RMSprop	240	220	200	tanh	linear	0,002
14b5-LSTM	6000	RMSprop	250	230	210	tanh	linear	0,002
14c1-LSTM	4000	RMSprop	190	180	200	tanh	linear	0,001
14c2-LSTM	5000	RMSprop	200	190	210	tanh	linear	0,002
14c3-LSTM	5000	RMSprop	220	210	230	tanh	linear	0,003
14c4-LSTM	5000	RMSprop	230	220	240	tanh	linear	0,009
14c5-LSTM	6000	RMSprop	230	220	240	tanh	linear	0,004

Fonte: Autor

Tabela A.28 – Métricas das simulações do modelo 14

ID	MAE	MAPE	RMSE	VMED
14a1-LSTM	0,095	0,0196	0,1228	4,844
14a2-LSTM	0,1081	0,0223	0,1357	4,844
14a3-LSTM	0,1019	0,021	0,1289	4,844
14a4-LSTM	0,0978	0,0202	0,1256	4,844
14a5-LSTM	0,1	0,0206	0,1274	4,844
14b1-LSTM	0,0634	0,0139	0,0921	4,5685
14b2-LSTM	0,1022	0,0224	0,1292	4,5685
14b3-LSTM	0,1727	0,0378	0,2144	4,5685
14b4-LSTM	0,096	0,021	0,123	4,5685
14b5-LSTM	0,0933	0,0204	0,1209	4,5685
14c1-LSTM	0,0957	0,0187	0,1212	5,1151
14c2-LSTM	0,0929	0,0182	0,1194	5,1151
14c3-LSTM	0,0907	0,0177	0,1174	5,1151
14c4-LSTM	0,1525	0,0298	0,11844	5,1151
14c5-LSTM	0,1838	0,0359	0,2279	5,1151

Fonte: Autor

Tabela A.29 – Hiper parâmetros das simulações do modelo 15

ID	EP	OT	NINT1	NINT2	NINT3	FAI	FAS	TAP
15a1-DFE	30000	Adam	110	220	240	relu	linear	0,003
15a2-DFE	40000	Adam	130	240	250	relu	linear	0,001
15a3-DFE	40000	Adam	150	250	250	relu	linear	0,005
15a4-DFE	40000	Adam	100	200	220	relu	linear	0,004
15a5-DFE	40000	Adam	160	250	250	relu	linear	0,003
15b1-DFE	30000	Adam	220	200	170	relu	linear	0,003
15b2-DFE	40000	Adam	240	220	190	relu	linear	0,001
15b3-DFE	40000	Adam	250	230	200	relu	linear	0,004
15b4-DFE	40000	Adam	250	230	200	relu	linear	0,002
15b5-DFE	40000	Adam	250	240	220	relu	linear	0,003
15c1-DFE	30000	Adam	150	180	150	relu	linear	0,01
15c2-DFE	40000	Adam	200	230	200	relu	linear	0,001
15c3-DFE	40000	Adam	220	250	220	relu	linear	0,03
15c4-DFE	40000	Adam	230	250	230	relu	linear	0,07
15c5-DFE	40000	Adam	240	250	240	relu	linear	0,01

Fonte: Autor

Tabela A.30 – Métricas das simulações do modelo 15

ID	MAE	MAPE	RMSE	VMED
15a1-DFE	0,1235	0,0255	0,156	4,844
15a2-DFE	0,1238	0,0256	0,1563	4,844
15a3-DFE	0,1257	0,0259	0,1586	4,844
15a4-DFE	0,1264	0,0261	0,1595	4,844
15a5-DFE	0,1269	0,0262	0,1598	4,844
15b1-DFE	0,1152	0,0252	0,1455	4,5685
15b2-DFE	0,1164	0,0255	0,147	4,5685
15b3-DFE	0,1161	0,0254	0,1467	4,5685
15b4-DFE	0,1174	0,0257	0,1479	4,5685
15b5-DFE	0,1169	0,0256	0,1474	4,5685
15c1-DFE	0,1147	0,0224	0,1448	5,1151
15c2-DFE	0,1157	0,0226	0,1453	5,1151
15c3-DFE	0,119	0,0233	0,1498	5,1151
15c4-DFE	0,1525	0,0298	0,1844	5,1151
15c5-DFE	0,1144	0,0224	0,1444	5,1151

Fonte: Autor