



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Oceanografia

Eduarda Pinto Borba

**Previsão da maré meteorológica com rede neural artificial aplicada à
estimativa do nível do mar na Baía de Guanabara – RJ**

Rio de Janeiro

2025

Eduarda Pinto Borba

Previsão da maré meteorológica com rede neural artificial aplicada à estimativa do nível do mar na Baía de Guanabara – RJ

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Oceanografia, da Universidade do Estado do Rio de Janeiro. Área de concentração: Oceanografia física.

Orientador: Prof. Dr. Alessandro Mendonça Filippo

Coorientador: Prof. Dr. Alessandro Lopes Aguiar

Rio de Janeiro

2025

CATALOGAÇÃO NA FONTE
UERJ/REDE SIRIUS/CTCC

B726 Borba, Eduarda Pinto.
Previsão da maré meteorológica com rede neural artificial aplicada à
estimativa do nível do mar na Baía de Guanabara – RJ / Eduarda Pinto
Borba.– 2025.
84 f. : il.

Orientador: Alessandro Mendonça Filippo.
Coorientador: Alessandro Lopes Aguiar.
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro,
Faculdade de Oceanografia.

1. Oceanografia física – Teses. 2. Maré – Teses. 3. Nível do mar –
Guanabara, Baía de (RJ) - Teses. 4. Redes neurais (computação) – Teses. I.
Filippo, Alessandro Mendonça. II. Aguiar, Alessandro Lopes. Universidade
do Estado do Rio de Janeiro. Faculdade de Oceanografia. III. Título.

CDU: 551.16(815.3)

Bibliotecária Responsável: Priscila Freitas Araujo/ CRB-7: 7322

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta
dissertação, desde que citada a fonte.

Assinatura

Data

Eduarda Pinto Borba

Previsão da maré meteorológica com rede neural artificial aplicada à estimativa do nível do mar na Baía de Guanabara – RJ

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Oceanografia, da Universidade do Estado do Rio de Janeiro. Área de concentração: Oceanografia física.

Aprovada em 27 de agosto de 2025.

Orientador: Prof. Dr. Alessandro Mendonça Filippo
Faculdade de Oceanografia - UERJ

Coorientador: Prof. Dr. Alessandro Lopes Aguiar
Faculdade de Oceanografia - UERJ

Banca examinadora:

Prof. Dr. Alexandre Macedo Fernandes
Faculdade de Oceanografia - UERJ

Prof. Dr. André Soares Monat
Escola Superior de Desenho Industrial - UERJ

Prof. Dr. Alexandre Luiz Coelho
Marinha do Brasil - DHN

Rio de Janeiro

2025

AGRADECIMENTOS

Agradeço primeiramente à umbanda, aos guias e orixás por tudo.

À minha família e amigos, que sempre estiveram presentes, apoiando e incentivando. Agradeço especialmente ao Didac pelos momentos descontraídos no laboratório e fora da UERJ, que tornaram tudo mais leve.

Agradeço ao meu orientador, Prof. Dr. Alessandro Filippo, pelo apoio constante, paciência e parceria nesta trajetória.

Aos técnicos do LABOFIS, em especial à Elisa Passos, pela paciência, apoio e trocas de conhecimento ao longo do mestrado.

À UERJ e ao PPG-OCN, pela oportunidade de cursar o mestrado e pela disposição em auxiliar sempre que necessário.

À Capes, pela bolsa concedida ao longo do mestrado.

Aos professores que aceitaram o convite para participação na banca de defesa, Alexandre Fernandes e André Monat, pela orientação desde as qualificações e pelas valiosas sugestões e críticas.

Por fim, agradeço a todos que, de alguma forma, contribuíram para que eu chegasse até aqui, tanto profissional quanto pessoalmente. Muito obrigada!

RESUMO

BORBA, Eduarda Pinto. **Previsão da maré meteorológica com rede neural artificial aplicada à estimativa do nível do mar na Baía de Guanabara – RJ**. 2025. 84 f. Dissertação (Mestrado em Oceanografia) – Faculdade de Oceanografia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2025.

O nível do mar (NM) em regiões costeiras é afetado por diversos fatores meteorológicos e oceanográficos especialmente nas regiões sul e sudeste do Brasil. A previsão convencional, baseada apenas na Maré astronômica, desconsidera variações induzidas por forçantes de origem não-astronômica, o que pode gerar desvios significativos em relação ao NM. Neste estudo, propõe-se o uso de rede neural recorrente do tipo *Long Short-Term Memory* (LSTM) para prever a maré meteorológica (MM) na Baía de Guanabara-RJ e estimar o NM a partir da soma das componentes astronômica e meteorológica. Foram utilizados dados de vento e pressão atmosférica provenientes da reanálise ERA5 em quatro pontos do litoral brasileiro, além de dados de NM fornecidos pela Marinha do Brasil. A MM foi obtida pela diferença entre o nível observado e a Maré astronômica prevista, sendo posteriormente filtrada na banda de 3,1 a 31,5 dias. O modelo teve sua arquitetura e hiperparâmetros otimizados por meio do método *Random Search*. A previsão da MM com a rede LSTM apresentou bom desempenho, com coeficiente de correlação (r) de 0,84 e RMSE de 6,5 cm. A reconstrução da série total, com a soma da Maré astronômica à MM prevista pela rede, reduziu o erro em 43% em relação à previsão convencional, com r de 0,97 e RMSE de ~ 8 cm. Os resultados evidenciam o potencial da LSTM para aprimorar previsões costeiras de curto prazo e melhorar a acurácia da previsão em eventos de maiores energias.

Palavras-chave: maré meteorológica; previsão do nível do mar; *long short-term memory*; Baía de Guanabara.

ABSTRACT

BORBA, Eduarda Pinto. **Meteorological tide predict with artificial neural network applied to sea level estimation in Guanabara Bay – RJ**. 2025. 84 f. Dissertação (Mestrado em Oceanografia) – Faculdade de Oceanografia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2025.

Sea level (SL) in coastal regions is affected by several meteorological and oceanographic factors, especially in the southern and southeastern regions of Brazil. Conventional forecasting, based only on the Astronomical Tide, disregards variations induced by forcings of non-astronomical origin, which can generate significant deviations from SL. In this study, we propose the use of a recurrent Long Short-Term Memory (LSTM) neural network to predict the Meteorological Tide (MT) in Guanabara Bay - RJ and to estimate the SL from the sum of the astronomical and meteorological components. Wind and Mean Sea Level Pressure data from the ERA5 reanalysis were used at four points on the Brazilian coast, in addition to sea level data provided by the Brazilian Navy. The MT was obtained by the difference between the observed level and the predicted Astronomical Tide and was subsequently filtered in the 3.1 to 31.5-day band. The model had its architecture and hyperparameters optimized through the Random Search method. The prediction of MT with the LSTM network showed good performance, with a correlation coefficient (r) of 0.84 and RMSE of 6.5 cm. The reconstruction of the entire time series, with the sum of the Astronomical Tide to the MT predicted by the network, reduced the error by 43% compared with conventional forecast, with an r of 0.97 and RMSE of ~8 cm. The results highlight the potential of LSTM to improve short-term coastal forecasts and enhance forecasting accuracy in higher energy events.

Keywords: meteorological tide; sea level prediction; long short-term memory; Guanabara Bay.

LISTA DE FIGURAS

Figura 1 –	Modelo esquemático de uma rede neural com neurônios e pesos sinápticos.....	19
Figura 2 –	Representação de uma rede MLP dividida em camadas.....	20
Figura 3 –	Expansão do loop da rede neural recorrente.....	23
Figura 4 –	Rede Neural Recorrente com problemas do aumento da lacuna.....	24
Figura 5 –	Diagrama da estrutura interna da RNR padrão.....	24
Figura 6 –	Diagrama da estrutura interna da LSTM.....	25
Figura 7 –	Primeira etapa da rede LSTM.....	27
Figura 8 –	Segunda etapa da rede LSTM.....	27
Figura 9 –	Terceira etapa da rede neural LSTM.....	28
Figura 10 –	Última etapa da rede neural LSTM.....	29
Figura 11 –	Comparação dos níveis do mar costeiro simulados e observados na estação de medição de Osaka durante todo o período do estudo: a) escala horária e b) escala mensal.....	30
Figura 12 –	Séries temporais horárias dos níveis do mar costeiros simulados e observados na estação de medição de Osaka em setembro de 2018, bem como a velocidade do vento (WS) e a pressão média do nível do mar (MSLP).....	31
Figura 13 –	Níveis do mar previstos para 1 hora à frente de SVR, MLP, CNN, LSTM e CNN-LSTM.....	33
Figura 14 –	Níveis do mar previstos para 2 horas à frente de SVR, MLP, CNN, LSTM e CNN-LSTM.....	34
Figura 15 –	Gráficos de radar de diferentes modos para previsões de nível do mar de várias etapas para o período dos tufões <i>Khanum</i> e <i>Mangkhut</i> e para o ano de 2017 a 2018.....	35

Figura 16 –	Mapa da região de estudo (Baía de Guanabara – RJ) com representação das isolinhas de profundidade (em metros).....	37
Figura 17 –	Localização da Estação Maregráfica da Ilha Fiscal (EMIF) e dos pontos de extração de dados do ERA-5.....	41
Figura 18 –	Série temporal da maré meteorológica observada, destacando os conjuntos de dados utilizados para treinamento, validação e teste da rede neural.....	47
Figura 19 –	Espectros de energia do nível do mar observado (NM), Maré astronômica (MA) e nível não-astronômico (NnA), com 4 graus de liberdade, para o período de 01/01/2016 a 31/12/2020.....	52
Figura 20 –	Espectro do NnA, com 4 graus de liberdade, para o período de 01/01/2016 a 31/12/2020.....	53
Figura 21 –	Série temporal do nível não-astronômico e da maré meteorológica.....	54
Figura 22 –	Mapa de correlação de Pearson entre a MM e as variáveis meteorológicas selecionadas (pressão atmosférica no ponto P1 e componentes u e v do vento nos pontos P2, P3 e P4), considerando as respectivas defasagens temporais.....	56
Figura 23 –	Mapa de correlação de Pearson entre a MM e as variáveis meteorológicas selecionadas (pressão atmosférica no ponto P1 e tensões do vento Tx e Ty nos pontos P2, P3 e P4), considerando as respectivas defasagens temporais.....	57
Figura 24 –	Comparação entre a maré meteorológica observada e a prevista pela rede LSTM para o ano de 2020.....	63
Figura 25 –	Comparação do nível do mar observado com a maré astronômica prevista e com a previsão incluindo a maré meteorológica para o ano de 2020.....	64
Figura 26 –	Séries temporais do nível do mar observado, da maré astronômica prevista e do nível do mar previsto, incluindo os limites de $\pm 2DP(\pm 66,18 \text{ cm})$ e	

$\pm 3DP(\pm 99,27 \text{ cm})$ 67

Figura 27 – Diagrama de Taylor do nível do mar observado (vermelho), maré astronômica (laranja) e nível do mar previsto..... 68

LISTA DE TABELAS

Tabela 1 – Precisão R dos modelos ARIMA, SVR e LSTM para diferentes cenário em todas as Estações.....	33
Tabela 2 – Resultados experimentais de seis algoritmos em dados de teste em intervalos de várias horas.....	34
Tabela 3 – Localização dos pontos de dados meteorológicos e do nível do mar.....	43
Tabela 4 – Critérios utilizados para o controle de qualidade.....	44
Tabela 5 – Resultados estatísticos de cada variável da rede neural LSTM.....	48
Tabela 6 – Resultados do teste estatístico ADF para os dados meteorológicos do ERA-5 e para a maré meteorológica.....	49
Tabela 7 – Hiperparâmetros avaliados durante a busca com <i>Random Search</i>	52

LISTA DE ABREVIATURAS E SIGLAS

ACAS	Água continental do Atlântico Sul
ADF	<i>Augmented Dickey-Fuller</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ASAS	Anticiclone Subtropical do Atlântico Sul
ATMGAAr	Temperatura média global anual do ar
BG	Baía de Guanabara
BI	Barômetro Invertido
BIAS	Viés
BNDO	Banco Nacional de Dados Oceanográficos
CNN	Rede Neural Convolucional
CPD	Ciclos por dias
DP	Desvio Padrão
E	Leste
EMIF	Estação Maregráfica da Ilha Fiscal
ENSO	<i>El Niño Southern Oscillation</i>
ICE	Intervalo de Confiança Espectral
MA	Maré astronômica
MAE	<i>Mean Absolute Error</i>
MM	maré meteorológica
MLP	<i>Perceptron Multicamada</i>
MSE	<i>Mean Squared Error</i>
LSTM	<i>Long Short-Term Memory</i>
NE	Nordeste
NM	nível do mar
NnA	nível não-astronômico
NR	Nível de redução
NSE	<i>Nash–Sutcliffe model efficiency coefficient</i>

OCCs	Ondas Confinadas Costeiras
OHI	Organização Hidrográfica Internacional
PANMM	Pressão Atmosférica ao Nível Médio do Mar
PCSE	Plataforma Continental Sudeste
r	Coefficiente de Correlação
RMSE	<i>Root mean square error</i>
RNA	Rede Neural Artificial
RNR	Rede Neural Recorrente
RNP	Redes Neurais Profundas
S	Sul
SI	<i>Scatter Index</i>
SVR	<i>Support Vector Regression</i>
SW	Sudoeste
Tanh	Tangente Hiperbólica
TSM	Temperatura da Superfície do Mar
Tx	Tensão de cisalhamento do vento zonal
Ty	Tensão de cisalhamento do vento meridional
U	Componente zonal do vento
V	Componente meridional do vento
ZCAS	Zona de Convergência do Atlântico Sul

SUMÁRIO

	INTRODUÇÃO	12
1	OBJETIVOS	16
1.1	Geral	16
1.2	Específicos	16
2	BASE TEÓRICA	17
2.1	Redes neurais artificiais	17
2.2	Redes neurais recorrentes	24
2.3	Redes <i>long short-term memory</i> (LSTM)	24
3	REVISÃO DA LITERATURA	30
3.1	Redes neurais e estudos aplicados ao nível do mar	30
4	ÁREA DE ESTUDO	38
5	METODOLOGIA	42
5.1	Dados utilizados e análises das séries de dados	42
5.2	Escolha das variáveis de entrada	46
5.3	Teste de Estacionaridade	47
5.4	Treinamento da rede neural	49
5.5	Implementação da rede neural	50
5.6	Métodos de avaliação do desempenho do modelo	52
6	RESULTADOS	54
6.1	Seleção dos dados	54
6.1.1	<u>Comparação das bandas astronômicas e não-Astronômicas do nível do mar</u>	54
6.1.2	<u>Banda meteorológica</u>	55
6.1.3	<u>Variáveis de entrada para a previsão da maré meteorológica com a rede LSTM</u> . 57	
6.1.4	<u>Análise comparativa das variáveis de entrada na previsão da maré meteorológica: U e V vs Tx e Ty</u>	62
6.2	Previsão da maré meteorológica com a rede LSTM	64

6.2.1	Melhores hiperparâmetros	64
6.2.2	Previsão com a rede LSTM.....	65
7	DISCUSSÃO.....	70
8	CONCLUSÕES.....	75
	CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES.....	77
	REFERÊNCIAS.....	79

INTRODUÇÃO

Ao longo do tempo observa-se a variação do Nível do mar (NM), principalmente, pela combinação de três componentes: nível médio do mar, Maré astronômica (MA) e nível residual (Pugh & Woodworth, 2014). Tal oscilação se dá por variados processos astronômicos e meteoceanográficos desencadeados por forçantes ambientais. A compreensão desses processos e forçantes, bem como os estudos relacionados à previsão do NM, são fundamentais para garantir a segurança da navegação, orientar operações portuárias, apoiar o gerenciamento costeiro e subsidiar planos de contingência, como aqueles voltados à prevenção de enchentes, evacuação e proteção de populações vulneráveis.

Em momentos extremos, essas forçantes podem amplificar o rebaixamento, tornando-o perigoso à navegação e embarcações podem encalhar quando navegam utilizando somente a profundidade indicada na carta náutica (Coelho *et al.*, 2016; Teixeira *et al.*, 2023). Por outro lado, podem também provocar sobre-elevação do NM, resultando, por exemplo, em inundações costeiras. Na Baía de Guanabara, Tecchio *et al* (2024) caracterizaram a ocorrência de extremos de nível do mar e identificaram marcada variabilidade sazonal, com sobre-elevações mais frequentes no outono e inverno, enquanto os rebaixamentos predominam no inverno e primavera. Esses autores destacam ainda que tais eventos não são desencadeados por forçantes locais, mas sim pela persistência temporal, intensidade e direção dos ventos ao longo da costa S/SE do Brasil.

A Organização Hidrográfica Internacional (OHI) determina que o NR deve ser um plano tão baixo que só raramente a maré fique abaixo dele, correspondendo aproximadamente a uma das menores baixa-mares possíveis (segurança a navegação) (Franco, 2009). O valor do NR é uma constante que é calculada somente levando em conta as componentes astronômicas. Porém, esse nível mais baixo de água pode variar de acordo com as condições meteorológicas. Esse valor é de supra importância na segurança à navegação, uma vez que para adentrar, por exemplo, em zonas portuárias, o calado dinâmico recomendado varia conforme diferentes fatores ambientais como, por exemplo, a altura do nível do mar (Marinha do Brasil, 2021).

Devido ao nível não-astronômico (NnA) apresentar componentes de natureza não-determinística, é possível obter uma série temporal apenas com as frequências de interesse com transformadas, como a Transformada Inversa de Fourier (Thomson & Emery, 2014), ou com filtros digitais (Thompson, 1983; Filippo, 2003; França, 2013; Franco, 2009). Neste

trabalho, o foco será a maré meteorológica (MM), uma das sub-bandas do NnA (Melo, 2017) ou maré residual (Pugh & Woodworth, 2014). O período desse fenômeno é comumente reconhecido entre 3 e 30 dias (Castro & Lee, 1995; Filippo *et al.*, 2012; Melo, 2017), embora Freitas *et al.* (2021) também tenham identificado energia significativa em períodos mais longos, de até 40 dias.

A MM é causada principalmente por mudanças na pressão atmosférica (efeito do barômetro invertido) e pela ação da força do vento local e remota (Gil; Schumann, 1979; Marone & Camargo, 1994; Castro & Lee, 1995; Campos *et al.*, 2010; Filippo *et al.*, 2012; Melo, 2017; Dottori & Castro, 2018; Siqueira *et al.*, 2021; Sonderman *et al.*, 2023). A força do vento remoto é sentida ao longo das regiões costeiras sujeitas a mudanças na direção do vento devido à formação de sistemas frontais sinóticos atmosféricos, gerando sinais do NM que se propagam ao longo da costa na forma de ondas confinadas costeiras (OCCs) (Gill & Schumann, 1979; Brink, 1991; Stech & Lorenzetti, 1992; Castro & Lee, 1995; Filippo *et al.*, 2012; França, 2013; Melo, 2017; Dottori & Castro, 2018; Freitas *et al.*, 2021). O nível do mar local pode responder tanto as forças locais e remotas, além de influenciado também pela configuração costeira, batimetria e largura da plataforma. Em Fernandes *et al.* (2023), a passagem local de OCCs foi identificada influenciando o NM na Baía de Guanabara (BG) e desempenhando um papel secundário nas intrusões da Água Central do Atlântico Sul (ACAS).

Variações no nível do mar, quando combinadas com condições astronômicas e meteorológicas durante períodos de marés de sizígia, podem intensificar a sobre-elevação e o rebaixamento do NM, aumentando o risco de eventos extremos e representando uma ameaça às comunidades, à infraestrutura costeira e à navegação (Marone & Camargo, 1994; Dutra *et al.*, 2014; Coelho *et al.*, 2016). Em Teixeira *et al.* (2023), durante um evento de ressurgência, com a permanência dos ventos de E-NE sobre a região da BG, foi observado um rebaixamento de 41 cm do NnA. Essa componente, ao se somar à Maré astronômica, resultou em um NM 25,3 cm abaixo do NR na BG, configurando um evento de risco à navegação. Em Fernandes *et al.* (2023), também foi observado a diminuição duradoura do NM, em até 34 cm, também em resposta aos ventos favoráveis (E-NE) ao fenômeno de ressurgência na região da BG. Tais situações evidenciam a vulnerabilidade do planejamento logístico em águas costeiras, que comumente considera apenas a componente astronômica do NM.

Por outro lado, Jordão *et al.* (2023) destacaram as consequências das inundações associadas a eventos não astronômicos para a população no entorno da BG e ressaltaram a importância da previsão da MM. Nos eventos analisados, a água chegou a invadir residências

na Vila Residencial, localizada na Ilha do Fundão, na BG. Diante desse cenário, os autores vêm desenvolvendo um sistema de previsão e alerta de inundações relacionadas a esse fenômeno, sobretudo porque a análise da série histórica evidenciou um aumento expressivo na frequência desses eventos nos últimos anos. Assim, a previsão do NM baseada unicamente na MA, como ocorre nas Tábuas de Marés da Marinha do Brasil, pode resultar em divergências relevantes em relação aos níveis observados, principalmente em regiões com forte influência meteorológica, como as regiões Sul e Sudeste (Melo, 2017; Fuchs *et al.*, 2021).

A previsão do NM é, portanto, crucial para o planejamento e a mitigação de riscos em regiões costeiras. Tradicionalmente, tais previsões são realizadas por meio de modelos baseados em processos, que neste caso são modelos numéricos hidrodinâmicos da circulação oceânica ou costeira (Pereira *et al.*, 2024). Esses modelos resolvem diretamente as equações físicas que regem a circulação marinha e oferecem uma boa representação dos processos físicos, representando uma tecnologia significativa para a compreensão e previsão de fenômenos naturais. As diferenças entre campos simulados e observados, que podem ser grandes, em particular para eventos extremos, são em parte devido a aproximações numéricas, comportamento não linear do sistema físico, processos de pequena escala não resolvidos, parametrizações do modelo e dados insuficientes ou não confiáveis. Entretanto, apesar de sua robustez teórica, esses modelos requerem dados de entrada detalhados, como batimetria precisa de alta resolução, para garantir representações confiáveis do fundo do mar e condições de contorno confiáveis, além de apresentarem alto custo computacional, o que pode limitar sua aplicabilidade em tempo real ou em regiões com infraestrutura reduzida (Pereira *et al.*, 2024).

Redes Neurais Artificiais (RNAs) surgiram como alternativas eficazes para predição de séries temporais em sistemas não lineares, como NM em ambientes costeiros. As RNAs podem identificar padrões complexos nos dados, aprendendo relacionamentos entre variáveis de entrada e saída sem a necessidade de explicação das equações físicas subjacentes (Zhao *et al.*, 2019; You *et al.*, 2019; Sahoo & Bhaskaran, 2019; Kim *et al.*, 2019; Ishida *et al.*, 2020; Balogun & Adebisi, 2021; Wang *et al.*, 2021; Kaufmann, 2024). Uma vez treinadas, essas redes operam com baixo custo computacional e oferecem capacidade preditiva satisfatória mesmo sob restrições de dados ou incertezas em condições de contorno. Entretanto, seu desempenho está diretamente relacionado à qualidade e extensão das séries históricas utilizadas no treinamento, sendo suscetível a superajustes (Géron, 2021).

A Baía de Guanabara, área de estudo deste trabalho, possui grande importância socioeconômica, ambiental e cultural para as comunidades que a cercam. Abriga o Porto do

Rio de Janeiro — um dos principais do país —, além de concentrar diversas atividades econômicas que impulsionam o desenvolvimento regional. As suas águas são palco de intenso tráfego aquaviário, não apenas pelo movimento associado às instalações portuárias, mas também pela constante circulação de embarcações que realizam a travessia entre as margens da baía e pela atividade pesqueira. A operação dessas embarcações é influenciada pelas variações do nível do mar, sejam elas de origem astronômica ou meteorológica. A bacia também inclui municípios e ilhas habitadas, onde atividades tradicionais como a pesca e a aquicultura seguem sendo fontes de sustento para muitas famílias. Do ponto de vista ecológico, a Baía apresenta elevada biodiversidade, com ecossistemas marinhos e estuarinos que desempenham papel fundamental na conservação da fauna e flora locais (Kjerfve et al., 1997; Chaves, 2021).

A Baía de Guanabara, área de estudo deste trabalho, possui grande importância socioeconômica, ambiental e cultural para as comunidades que a cercam. Abriga o Porto do Rio de Janeiro — um dos principais do país — e concentra diversas atividades econômicas que impulsionam o desenvolvimento regional. Suas águas são palco de intenso tráfego aquaviário, não apenas pelo movimento associado às instalações portuárias, mas também pela constante circulação de embarcações que realizam a travessia entre as margens da baía e pela atividade pesqueira. A operação dessas embarcações, assim como a vida cotidiana nas habitações localizadas nas margens e no interior da Baía, é diretamente influenciada pelas variações do nível do mar, sejam elas de origem astronômica ou meteorológica.

Portanto, a previsão acurada do NM, especialmente da componente não-astronômica e dos eventos energéticos a ela associados, é fundamental para apoiar as atividades operacionais, o planejamento e a realocação de atividades socioeconômicas. Tal necessidade se torna ainda mais urgente diante da perspectiva futura de mudanças climáticas que, segundo projeções, poderão provocar a elevação do Nível Médio do Mar (Oppenheimer *et al.*, 2019) e a intensificação dos ciclones extratropicais (Lambert & Fyfe, 2006).

1 OBJETIVOS

1.1 Objetivo geral

Avaliar o potencial da rede neural *Long Short-Term Memory* para a previsão da maré meteorológica na região de estudo, utilizando variáveis meteorológicas locais e remotas como entradas, de modo a quantificar a capacidade do modelo em reproduzir as oscilações não-astronômicas do Nível do mar e a relevância da inclusão desse fenômeno na previsão do Nível do mar.

1.2 Objetivos específicos

- a) Analisar a variabilidade do nível do mar na Baía de Guanabara, com foco na sub-banda da maré não-astronômica denominada de maré meteorológica por Melo (2017);
- b) Avaliar a influência de variáveis meteorológicas, de origem local e remota, sobre a maré meteorológica na região;
- c) Obter a série da Maré astronômica a partir da previsão baseada em constantes harmônicas;
- d) Prever a maré meteorológica utilizando a rede neural *Long Short-Term Memory*;
- e) Determinar o nível do mar na Estação Maregráfica da Ilha Fiscal (EMIF), situada na Baía de Guanabara – RJ, por meio da combinação das componentes astronômica e não-astronômica.

2 BASE TEÓRICA

2.1 Redes neurais artificiais

No contexto da Inteligência Artificial, existe a metodologia chamada Redes Neurais Artificiais (RNAs), que consiste na criação de um modelo computacional inspirado no funcionamento do sistema nervoso biológico. Dessa forma, busca-se representar a relação dos neurônios biológicos, no processo de informações, além de simular o aprendizado por meio de assimilação e memorização de padrões, identificação de tendências e tomada de decisão após o treinamento (Silva *et al.*, 2016). O crescimento no uso das RNAs e sua vasta aplicabilidade podem ser atribuídos à sua capacidade de adaptação por experiência, conforme os padrões de entrada fornecidos. Além disso, outras características que impulsionam a disseminação dessa técnica incluem a habilidade de representar sistemas não lineares, reconhecer e classificar padrões (Géron, 2021).

A origem das redes neurais artificiais se deu pelo modelo matemático baseado no neurônio biológico, através do arranjo dos neurônios, proposto por Warren McCulloch e Walter Pitts em 1943 (McCulloch & Pitts, 1943). Esse modelo apresenta uma ou mais entradas binárias (ativar/desativar) e uma saída binária (Géron, 2021). Posteriormente, em 1957, Frank Rosenblatt implementou uma das arquiteturas mais simples da RNA, a *perceptron* (Géron, 2021). Esse modelo toma como base um neurônio artificial denominado unidade lógica de limiar ou, às vezes, uma unidade de limiar linear (Géron, 2021). Diferentemente do modelo citado anteriormente, as entradas e saídas são números ao invés de valores binários e cada conexão de entrada está associada a um valor de peso. Esse neurônio artificial calcula uma soma ponderada de suas entradas, aplica uma função degrau e gera o resultado (Géron, 2021).

A rede neural modela de modo tal qual o cérebro realiza uma tarefa estabelecida ou uma função de interesse (Haykin, 2009). As redes neurais podem ser definidas, segundo Silva *et al* (2010), como um conjunto de unidades de processamento de informações (neurônios artificiais) que são interligadas por diversos conectores (sinapses artificiais), da mesma forma como ocorre no cérebro humano. Estes neurônios podem extrair informações lineares ou não-lineares dos dados. Na figura 1 pode-se observar o esquema da rede neural na sua essência matemática e a representação dos elementos que constituem a rede, tais como:

- Entradas da rede (x_1, x_2, \dots, x_n)
Informações que vão percorrer a rede até chegar ao neurônio artificial. Essas séries de dados são anteriormente normalizadas para servirem de entrada na rede.
- Pesos sinápticos (w_1, w_2, \dots, w_n)
Valor atribuído a cada informação de entrada de acordo com o grau de influência em relação à funcionalidade do respectivo neurônio. A faixa dos pesos inclui valores negativos e positivos.
- Combinador Linear (Σ)
Agrega os sinais de entrada logo após terem sido ponderadas pelos pesos sinápticos para criar um valor de potencial de ativação.
- Bias (b)
Auxilia ajustando a saída do combinador linear. É uma constante que ajuda o modelo de uma maneira que ele possa se adaptar melhor aos dados fornecidos.
- Potencial de ativação (u)
É o resultado da combinação linear entre os sinais de entrada e os pesos sinápticos somada a um bias.
- Função de ativação ($\varphi(\cdot)$)
A função de ativação é aplicada a entrada total (u). A depender da aplicação da rede e do algoritmo de treinamento empregado, pode ser do tipo degrau, linear, linear retificada (ReLU – *Rectified Linear Unit*), sigmoide ou tangente hiperbólica (Tanh). Dependendo da função de ativação escolhida, o valor de saída será diferente. Com base nesse valor, o neurônio decide se deve passar a informação adiante (ativado) ou não (Goodfellow *et al.*, 2016; Sharma *et al.*, 2020; Géron, 2021; Giaremis *et al.*, 2024).

A função ReLU é uma das mais populares, especialmente em arquiteturas profundas. Ela é utilizada para introduzir a não-linearidade no modelo, o que é muito significativo para que a rede neural aprenda e represente as relações complexas entre as variáveis. É definida como:

$$\text{Relu}(x) = \max(0, x)$$

Ou seja, para qualquer valor de entrada x :

- Se $x > 0$, então $\text{ReLU}(x) = x$.
- Se $x \leq 0$, então $\text{ReLU}(x) = 0$.

Devido a sua operação de comparação (se $x > 0$, retorne x ; caso contrário, retorne 0), é computacionalmente eficiente em comparação com outras funções de ativação, como a sigmóide ou a Tanh). Além de contribuir para uma menor sobrecarga computacional devido a sua característica de ativar apenas uma fração dos neurônios para qualquer amostra de entrada.

A função de ativação linear mantém a relação direta entre entrada e saída ($f(x) = ax$), permitindo a previsão de valores contínuos sem restrições de intervalo, uma característica essencial em tarefas de regressão, como a previsão de séries temporais.

Outra função comumente utilizada é a Tanh, principalmente em camadas ocultas. Ela transforma valores de entrada em uma saída que varia entre -1 e 1. Matematicamente é expressa pela Equação 3.1.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.1)$$

Por fim, destaca-se a função sigmóide que é popularmente aplicada em problemas de classificação binária por transformar a entrada, que pode variar entre $-\infty$ e $+\infty$, em uma saída que varia entre $[0,1]$. Matematicamente é expressa pela Equação 3.2.


$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.2)$$

Além disso, a função de ativação é um artifício essencial na atualização dos valores dos pesos sinápticos através método de *backpropagation*, ou retropropagação.

- Saída da rede (y)

Representa o sinal de saída da rede em relação aos sinais de entrada, após a realização de todos os cálculos.

Figura 1 - Modelo esquemático de uma rede neural com neurônios e pesos sinápticos.



Fonte: HAYKIN, 2009. Adaptada pela autora, 2025.

Em termos matemáticos, o esquema da Figura 1 está representado nas equações 3.3 e 3.4.

$$u_k = \sum_{j=1}^m w_{kj} x_j - b_k \quad (3.3)$$

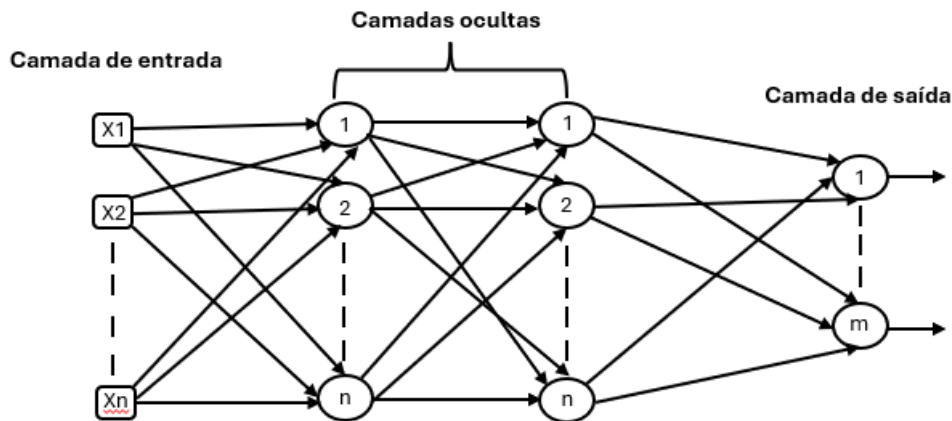
$$y_k = \varphi(u_k) \quad (3.4)$$

Onde: x_j = entradas da rede; w_{kj} = peso associado à j -ésima entrada; u = potencial de ativação; y = saída da rede; φ = função de ativação e b = viés.

A *perpceptron* simples por apresentar uma natureza linear, apresenta inúmeras deficiências como, por exemplo, não resolver problemas que apresentam operações não-lineares, apresentando dificuldades em aprender padrões complexos (Géron, 2021). A *Perceptron* Multicamada (MLP - *Multilayer Perceptrons*) foi desenvolvida para resolver algumas deficiências por meio do empilhamento de diversas camadas de neurônios artificiais.

A Figura 2 apresenta a arquitetura básica deste tipo de rede, podendo apresentar uma ou mais camadas ocultas. Neste tipo de rede, cada neurônio recebe os sinais das camadas anteriores, sem realimentação. As saídas dependem apenas das entradas e das condições de sinapse dos neurônios da rede (Silva, 2010). Cada sequência de camadas pode ser composta por números diferentes de neurônios. De uma forma geral, quanto maior a quantidade desses elementos, menor a “responsabilidade” de cada neurônios e seus respectivos pesos no treinamento (Haykin, 2001).

Figura 2 - Representação de uma rede MLP dividida em camadas.



Fonte: A autora, 2025.

Para superar as dificuldades ao treinar essa rede, foi criado o algoritmo de treinamento de retropropagação (algoritmo de *backpropagation*), que ajusta os pesos da rede a fim de reduzir o erro do modelo. Esse ajuste é feito por meio do cálculo dos gradientes, que indicam a direção e magnitude da atualização dos pesos sinápticos. O gradiente inicial é obtido a partir da diferença entre os valores previstos pela rede e os valores reais da saída, sendo a função de perda mais utilizada o erro quadrático médio (MSE – Mean Square Error) (Haykin, 2001; Géron, 2021).

Em seguida, esse gradiente é propagado para trás pelas camadas, multiplicando-se pelas derivadas das funções de ativação e pelos pesos de cada camada, para calcular o gradiente de todos os parâmetros da rede. O processo continua camada por camada até chegar à camada de entrada, repetindo-se até que algum critério de parada seja atendido (como número de épocas ou convergência do erro) (Géron, 2021). Diferentes métodos de otimização podem ser usados para ajustar os pesos a partir desses gradientes, incluindo algoritmos como SGD, Adam e RMSprop.

O ajuste nos pesos é descrito pela expressão 3.5:

$$W^{m+1} = W^m + \Delta W \quad (3.5)$$

Onde: W^m é a matriz contendo os pesos de todas as entradas de todos os neurônios da rede e ΔW representa a variação desses pesos.

Ao treinar redes neurais profundas (RNP) e redes neurais recorrentes (RNRs) pode ocorrer problemas como, o desaparecimento do gradiente (*Vanishing Gradient Problem*) e a explosão do gradiente (*Exploding Gradient Problem*). O primeiro, à medida que o algoritmo avança para as camadas inferiores ou se propagado para muitos passos temporais, os gradientes ficam cada vez menores, quase zero. Isso impede que os pesos sejam atualizados de forma significativa, tornando o aprendizado muito lento nas camadas iniciais. Já o segundo, ocorre devido ao crescimento contínuo dos gradientes durante a retropropagação, causando atualizações instáveis nos pesos e o algoritmo divergir. Isso pode dificultar a avaliação do desempenho do modelo e ocorrer também a interrupção do treinamento. O número de camadas da rede e a taxa de aprendizagem podem influenciar nos problemas citados (Géron, 2021; Giaremis *et al.*, 2024).

A função Tanh mapeia os valores de entrada para o intervalo entre -1 e 1, o que ajuda a centralizar as ativações em torno de zero e, conseqüentemente, acelera a convergência durante o treinamento. Para entradas próximas de zero, sua derivada é alta, favorecendo um aprendizado mais eficiente. No entanto, em casos em que os valores de entrada são muito grandes ou muito pequenos, a função pode entrar em saturação, fazendo com que os gradientes se aproximem de zero e resultando em um aprendizado lento, especialmente nas camadas iniciais. A função sigmoide apresenta comportamento semelhante, tende à saturação com entradas extremas, o que reduz significativamente o gradiente e compromete a eficiência do aprendizado em redes neurais profundas.

Por outro lado, a função ReLU, embora amplamente utilizada por sua simplicidade e eficiência computacional, apresenta algumas limitações. Um dos principais problemas ocorre quando os pesos são inicializados e/ou atualizados de forma que a soma ponderada das entradas seja constantemente negativa. Nesse caso, a saída da ReLU será zero, impedindo que o neurônio participe do processo de aprendizado.

Quanto à divisão da rede neural, basicamente pode ser feita da seguinte forma: camada de entrada, onde são fornecidas as informações iniciais geralmente normalizadas; camada intermediária ou oculta, possui os neurônios que extraem as características dos dados e onde são realizados a maior parte dos cálculos interno da rede; e a camada de saída, constituída também pelos neurônios e responsável pelo resultado da rede, como mostrado na figura 2 (Silva *et al.*, 2016).

A arquitetura de uma rede neural refere-se à forma como os neurônios estão organizados e conectados entre si. Diferentes arquiteturas apresentam variadas composições estruturais, que influenciam diretamente o desempenho do modelo. O processo de treinamento

consiste em ajustar os parâmetros da rede por meio da aplicação de dados de entrada e comparação das respostas geradas com os valores desejados, buscando minimizar o erro e otimizar a capacidade preditiva do modelo (Silva *et al.*, 2016).

As principais arquiteturas de redes neurais são: rede *feedforward* de camadas simples ou múltiplas: fluxo de informação é unidirecional, não há ciclos, sendo comum a representação em camadas. Neste tipo de rede, cada neurônio recebe os sinais das camadas anteriores, sem realimentação. As saídas dependem apenas das entradas e das condições de sinapse dos neurônios da rede (Silva *et al.*, 2016); redes recorrentes (*Feedback*), as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios, ou seja, as saídas levam em consideração valores das saídas anteriores; e redes reticuladas, a disposição espacial dos neurônios está diretamente relacionada com o processo de ajuste de seus pesos e limiares (Silva *et al.*, 2016).

O objetivo principal do treinamento de uma rede neural é permitir que ela generalize soluções de forma eficaz, ajustando os pesos sinápticos e os limiares dos neurônios por meio de um processo iterativo e ordenado. Esse treinamento pode ser realizado de forma supervisionada ou não supervisionada. No treinamento supervisionado, os valores de saída desejados são previamente conhecidos, e a rede ajusta seus parâmetros com base na comparação entre a saída prevista e o valor real, minimizando o erro por meio de algoritmos de otimização. Dessa forma, a rede aprende a produzir respostas cada vez mais precisas frente a novos dados.

Por outro lado, o aprendizado não-supervisionado é utilizado em situações nas quais não há uma saída desejada previamente definida. Nessa abordagem, a própria rede se auto-organiza com base nas características dos dados de entrada, identificando subconjuntos com similaridades. O algoritmo de aprendizagem ajusta os pesos sinápticos de forma autônoma, com base nas similaridades detectadas entre os dados, sendo particularmente útil em tarefas de classificação, agrupamento e ordenação (Silva *et al.*, 2016; Géron, 2021).

Na etapa de configuração de uma rede neural, a seleção adequada dos hiperparâmetros é fundamental para a obtenção de um modelo com bom desempenho. Por serem definidos externamente ao processo de treinamento, os hiperparâmetros devem ser especificados pelo pesquisador responsável, sendo essenciais para orientar o ajuste dos parâmetros internos do modelo, como os pesos sinápticos. A escolha desses elementos impacta diretamente a capacidade de generalização da rede e, portanto, influencia a qualidade dos resultados. No entanto, essa seleção representa um desafio, pois exige a realização de diversos testes e experimentações para identificar a combinação que minimize o erro da previsão. Entre os


principais hiperparâmetros destacam-se o *batch size*, o otimizador, o número de neurônios por camada, a taxa de aprendizado (*learning rate*), entre outros (Géron, 2021).

2.2 Redes neurais recorrentes

As redes neurais recorrentes fazem uso de informações sequenciais, o que as diferem da rede neural tradicional onde as informações de entrada e de saída são independentes entre si. Essas redes são uma classe de redes neurais nas quais as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios, formando uma estrutura com loops.

Essa característica de realimentação permite que as informações persistam ao longo do tempo, possibilitando que as RNRs sejam compreendidas como múltiplas cópias da mesma rede, cada uma transmitindo mensagens para suas sucessoras. A Figura 3 mostra com maior detalhe esse loop que ocorre nas RNRs. Entretanto, se limita a um número de etapas anteriores. Essa capacidade torna as RNRs especialmente adequadas para o processamento dinâmico dos dados, sendo amplamente utilizadas em aplicações como previsão de séries temporais de longo prazo, otimização e identificação de sistemas, reconhecimento de fala, legendas de imagens, entre outros (Géron, 2021).

Figura 3 - Expansão do loop da rede neural recorrente.



Fonte: *Data Science Academy*, 2022.

Para garantir a precisão desejada desse modelo, adota-se o uso do estado oculto, que armazena informações da classificação anterior da série temporal. A cada nova etapa, esse estado é atualizado por meio da combinação com os dados recém-recebidos, originando um novo estado oculto e, em seguida, uma nova saída. Esse ciclo se repete, com cada estado sendo utilizado como base para a próxima atualização.


2.3 Redes *long short-term memory* (LSTM)

Em arquiteturas do tipo RNR, valores podem ser retidos por períodos variáveis, o que possibilita o tratamento de sequências temporais. No entanto, ao lidar com longas sequências, essas redes enfrentam o desafio do desaparecimento do gradiente. Tal fenômeno compromete o aprendizado das camadas mais antigas ao executar em diversos intervalos de tempo, pois o gradiente se torna muito pequeno – tendendo a desaparecer nas camadas anteriores - para atualizar os pesos de forma eficiente, impossibilitando o treinamento da rede (Hochreiter & Schmidhuber, 1997).

Para contornar essa limitação, foi introduzida a arquitetura LSTM, que incorpora células de memórias capazes de conservar e transmitir informações relevantes ao longo do tempo. Essas células mantêm o fluxo de erro mais estável durante a retropropagação, permitindo que o modelo continue aprendendo mesmo após muitos passos temporais (Hochreiter & Schmidhuber, 1997).

Essa característica é fundamental para identificar relações de longo prazo em dados sequenciais, onde eventos distantes podem estar interligados. Por isso, este tipo de arquitetura é altamente recomendada para classificar, processar e prever séries temporais, especialmente quando os intervalos entre eventos significativos são irregulares ou de duração indefinida. Portanto, uma das vantagens da LSTM na prática é a insensibilidade relativa ao comprimento da lacuna sobre as demais RNRs tradicionais, que à medida que a lacuna cresce se tornam incapazes de aprender a conectar as informações (Figura 4), ou seja, foram projetadas para evitar o problema de dependência de longo prazo.

Figura 4 - Rede Neural Recorrente com problemas do aumento da lacuna.




Fonte: Colah's blog, 2015.

A estrutura da LSTM é semelhante à das RNRs, mantendo a ideia de uma cadeia temporal, mas apresenta uma arquitetura interna mais complexa. Cada célula da LSTM possui quatro componentes internos que controlam o fluxo de informações, além de blocos de


memória dedicados. Enquanto as RNRs convencionais têm uma estrutura mais simples, com apenas um elemento interno (Figura 5), as LSTM utilizam portões (*gates*) para manipular o estado da célula. Esses portões permitem adicionar ou remover informações da memória da célula (Figura 6), garantindo que a rede consiga lembrar valores ao longo de intervalos temporais arbitrários.

Figura 5 - Diagrama da estrutura interna da RNR padrão.



Fonte: Colah's blog, 2015.

Figura 6 - Diagrama da estrutura interna da LSTM.



Fonte: Colah's blog, 2015.

A rede LSTM tem três portões para controlar o estado da célula, são eles:

Forget Gate: Decide quais informações do estado anterior $C_{(t-1)}$ devem ser mantidas ou descartadas, filtrando com um valor de função sigmoide entre 0 e 1. Se para um determinado estado de célula a saída for 0, a informação é esquecida e para a saída 1, a informação é retida para uso futuro.

Input Gate: regula a incorporação de novas informações combinando uma sigmoide que seleciona quais dados armazenar e uma função Tanh que gera os candidatos a serem adicionados ao estado da célula.

Output Gate: determina quais partes do estado atualizado C_t serão expostas como saída h_t , combinando uma função sigmoide e tanh para modular as informações transmitidas para a próxima etapa.

Nas LSTM, os portões atuam como filtros adaptativos que controlam o fluxo de informações dentro da célula. Cada portão recebe sinais de entrada e decide, com base em sua ativação, se deve bloquear, transmitir ou atenuar essas informações. Essa decisão é mediada por conjuntos próprios de pesos, ajustados durante o aprendizado por meio da retropropagação através do tempo (*Backpropagation Through Time* – BPTT), que calcula os gradientes de erro considerando as dependências temporais existentes entre os instantes da sequência (Hochreiter & Schmidhuber, 1997; Goodfellow *et al.*, 2016, Géron, 2021).

Durante o BPTT, a rede é “desdobrada” no tempo, permitindo que o erro seja propagado entre os instantes sucessivos e não apenas entre camadas, como em uma rede *feedforward*. Dentro desse processo, o estado interno (C_t) atua como um canal de memória de longo prazo, enquanto o portão de esquecimento (f_t) regula quais informações devem ser preservadas ou descartadas, garantindo a coerência temporal da memória (Hochreiter & Schmidhuber, 1997; Goodfellow *et al.*, 2016).

Esse mecanismo cria um caminho quase linear para a passagem do gradiente, reduzindo os problemas de desaparecimento e explosão do gradiente, comuns em redes recorrentes simples. Assim, a LSTM mantém estabilidade no aprendizado e consegue representar relações de longo prazo de forma eficiente, aprendendo de maneira seletiva quando atualizar, preservar ou descartar informações relevantes ao longo do tempo (Hochreiter & Schmidhuber, 1997; Goodfellow *et al.*, 2016).


Com o objetivo de capturar padrões temporais mais complexos, as redes LSTM podem ser organizadas em múltiplas camadas sucessivas, conhecidas como LSTM empilhadas. Nessa arquitetura, a camada superior fornece uma saída em sequência, e não um único valor, para a camada imediatamente abaixo. Cada camada é composta por unidades de memória capazes de reter informações temporais por longos intervalos e processar as dependências entre instantes sucessivos. Nas LSTM empilhadas, cada passo de tempo da entrada gera um passo de saída correspondente, permitindo que cada camada represente detalhadamente a dinâmica temporal da série e capture padrões em diferentes escalas de tempo (Graves *et al.*, 2013; Pascanu *et al.*, 2014). A ideia de empilhar camadas LSTM foi introduzida por Graves *et al.* (2013) em aplicações de reconhecimento de fala, demonstrando que a profundidade da rede era mais importante do que o número de células de memória em cada camada para a performance do modelo.

Após o processamento temporal pelas LSTM, adicionam-se geralmente camadas densas, responsáveis pela etapa final de mapeamento entre os estados ocultos e a variável-alvo. Nessas camadas, todos os neurônios estão interligados, realizando uma combinação linear dos valores de entrada, seguida de uma função de ativação de saída a ser escolhida (Goodfellow *et al.*, 2016; Géron, 2021). Elas são normalmente utilizadas como camada final em tarefas de regressão ou classificação, convertendo as representações internas da rede em valores de saída. Quando há camadas densas intermediárias, funções como ReLU ou tanh podem introduzir não-linearidade e aumentar a flexibilidade da rede.

A combinação entre camadas LSTM empilhadas e camadas densas confere poder preditivo às redes aplicadas a séries temporais ambientais. Enquanto as LSTM capturam a dinâmica temporal e as dependências entre as variáveis, as camadas densas realizam a síntese final, convertendo as representações aprendidas em previsões quantitativas.

Para ilustrar o funcionamento de uma célula LSTM, a Figura 7 mostra o primeiro passo do ciclo de processamento de uma célula LSTM em cada instante de tempo, que consiste em definir quais informações do estado da célula anterior (C_{t-1}) serão descartadas ou mantidas pelo portão de esquecimento (f_t). Esse portão aplica uma função sigmoide sobre a combinação da entrada atual x_t e do estado oculto anterior h_{t-1} , produzindo um vetor com valores entre 0 (exclui informações) e 1 (mantém informações). Esses valores atuam como filtros, controlando a proporção de cada componente da memória de longo prazo que será mantida ou descartada. A Equação 3.4 traduz o que acontece nesse primeiro passo.

Figura 7 - Primeira etapa da rede LSTM.




$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.4)$$

Fonte: Colah's blog, 2015.

Onde: σ = função de ativação sigmoide; W_f = matriz de peso do portão de esquecimento; h_{t-1} = saída do estado oculto anterior; x_t = entrada do tempo atual; b_f = viés do portão de esquecimento.

Na etapa seguinte (Figura 8), o objetivo é incorporar e atualizar informações provenientes da nova entrada (x_t) no estado da célula. Esse processo ocorre em duas partes principais: inicialmente, uma camada sigmoide avalia quais elementos da nova informação devem ser armazenados, produzindo valores entre 0 e 1 que indicam o grau de retenção de cada componente. Em seguida, a \tanh transforma a nova entrada em um vetor de possíveis valores candidatos, entre -1 e 1 , refletindo o grau de importância relativa de cada informação. A multiplicação desses dois vetores define os conteúdos efetivamente incorporados à célula. As Equações 3.5 e 3.6 resumem o que ocorre nesta etapa.

Figura 8 - Segunda etapa da rede LSTM.



Fonte: Colah's blog, 2015.

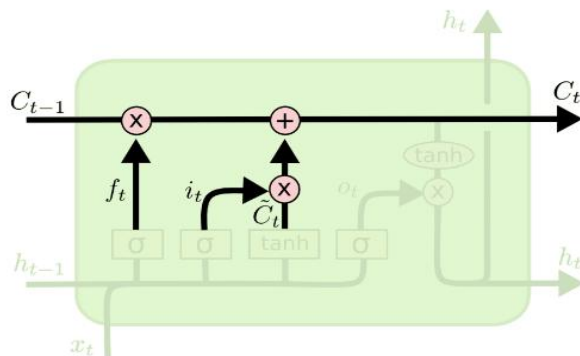
$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.5)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.6)$$

Onde: \tilde{C}_t = vetor candidato; W_i = matriz de peso do portão de entrada; b_i = viés do portão de entrada; W_c = matriz de peso do vetor candidato; b_c = viés do vetor candidato.

Posteriormente, essa nova informação é combinada ao estado de célula anterior, (C_{t-1}), resultando na memória atualizada do sistema, C_t (Figura 9). A Equação 3.7 resume o que ocorre nessa etapa.

Figura 9 - Terceira etapa da rede neural LSTM.




Fonte: Colah's blog, 2015.

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (3.7)$$

Onde: C_{t-1} = estado da célula antigo; f_t = portão de esquecimento; i_t = portão de entrada; \tilde{C}_t = vetor candidato.

Por fim (Figura 10), os valores de saída (h_t) é produzida com base no estado interno da célula, porém de forma regulada. Inicialmente, uma camada sigmoide (o_t) determina quais informações do estado da célula devem ser transmitidas para a saída, funcionando como um filtro seletivo. Em seguida, o estado da célula atualizado (C_t) é transformado por meio da função \tanh , que comprime seus valores para o intervalo entre -1 e 1. O resultado dessa transformação é então multiplicado pelo vetor o_t , gerando uma saída modulada que reflete tanto o conteúdo interno da célula quanto os critérios definidos pela porta de saída. As Equações 3.8 e 3.9 traduzem essa etapa.

Figura 10 - Última etapa da rede neural LSTM.



Fonte: Colah's blog, 2015.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (3.8)$$

$$h_t = o_t \times \tanh(C_t) \quad (3.9)$$

Aqui, as matrizes de peso e o viés da porta de saída são denotados por W_o e b_o , respectivamente.

A estrutura descrita acima é uma LSTM padrão, há outras versões diferentes ainda que com pequenas diferenças entre elas.

3 REVISÃO DA LITERATURA

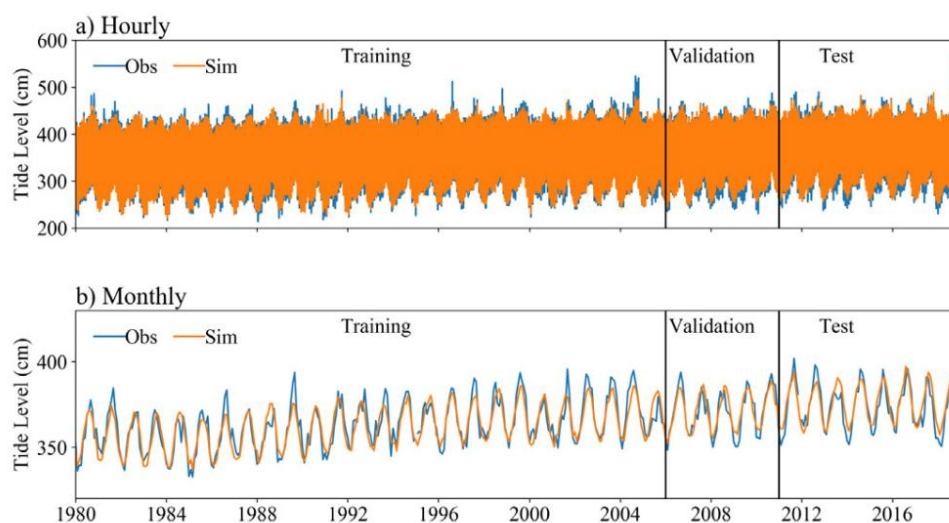
3.1 Redes neurais e estudos aplicados ao nível do mar

Ishida *et al* (2020) desenvolveram um modelo de estimativa do NM costeiro em uma escala horária usando a rede neural LSTM para as estações maregráfica de Osaka no Japão

com período de dados de 1980 a 2018 (Figura 11). Para tal foram utilizadas 9 variáveis locais como: temperatura média global anual do ar (ATMGAAr), velocidade e direção do vento, pressão atmosférica ao nível médio do mar, temperatura do ar e componentes astronômicas. Foram analisados quatro casos contendo essas variáveis, porém três com diferentes comprimentos de entrada da ATMGAAr (20, 50, 80 anos) e um sem a adição dessa variável.

Primeiramente, verificou-se que a ATMGAAr permitiu ao modelo capturar o efeito do aumento do nível do mar em longo prazo. Além disso, a inclusão dessa variável melhorou a precisão do modelo: a raiz do erro quadrático *médio* (RMSE - Root Mean Square Error) diminuiu gradualmente à medida que se utilizou um período maior da temperatura média global anual do ar como entrada, enquanto o coeficiente de eficiência de Nash-Sutcliffe (NSE - *Nash-Sutcliffe Efficiency Coefficient*) permaneceu alto em todos os períodos, apresentando aumento adicional com a utilização de durações mais longas.

Figura 11 - Comparação dos níveis do mar costeiro simulados e observados na estação de medição de Osaka durante todo o período do estudo: a) escala horária e b) escala mensal.




Fonte: Ishida *et al.*, 2020.

Os resultados demonstraram o desempenho satisfatório da rede LSTM na previsão do nível do mar. A precisão do modelo, avaliada por métricas como RMSE e NSE, variou de ~12 a 9 cm e de ~0,85 a 0,94, respectivamente, entre os conjuntos de treinamento, validação e teste das quatro etapas. Para capturar as oscilações mensais, o modelo foi treinado com apenas 240 h de dados combinados com a anomalia anual da temperatura global do ar, conseguindo reproduzir a sazonalidade (Figura 11b). Nessa análise, os valores de NSE foram 0,829, 0,777 e 0,720 para treino, validação e teste, respectivamente.

Durante um evento de tufão, o modelo subestimou os valores do NM (Figura 12), possivelmente devido à utilização de variáveis atmosféricas de apenas uma grade do ERA5, limitando a representação da dinâmica da tempestade.

Figura 12 - Séries temporais horárias dos níveis do mar costeiros simulados e observados na estação de medição de Osaka em setembro de 2018, bem como a velocidade do vento (WS) e a pressão média do nível do mar (MSLP).



Fonte: Ishida *et al.*, 2020.

Balogun & Adebisi (2021) compararam o desempenho dos modelos de Média Móvel Integrada Autorregressiva (ARIMA - *AutoRegressive Integrated Moving Average*), Regressão por Vetores de Suporte (SVR - *Support Vector Regression*) e a rede LSTM na previsão do nível do mar em diferentes Estações Maregráficas ao longo da costa oeste da Península da Malásia utilizando dados mensais de variáveis oceânicas e atmosféricas entre 1993 e 2019, avaliando o efeito do uso de variáveis oceânicas (OV) - Temperatura da Superfície do Mar, Salinidade da Superfície do Mar e Densidade da Superfície do Mar -, atmosféricas (AV) - Pressão Atmosférica da superfície, velocidade do vento, cobertura total de nuvens, precipitação - e a combinação de ambas (OAV). O modelo ARIMA utilizou somente o Nível do mar como entrada.

Conforme apresentado na Tabela 1, para o modelo ARIMA, os coeficientes de correlação variaram de 0,573 a 0,882, sem variáveis externas. No caso do SVR, os resultados mostraram ganhos mais expressivos ao se incluir as variáveis atmosféricas. O coeficiente médio de correlação passou de 0,597 (OV) para 0,720 (AV), representando um aumento

relativo médio de 16,47%. Quando ambas as variáveis foram combinadas (OAV), observou-se um pequeno acréscimo adicional ($R = 0,748$).

Já a rede LSTM apresentou o melhor desempenho geral. Utilizando apenas variáveis oceânicas, o coeficiente médio foi de 0,643, aumentando para 0,810 com variáveis atmosféricas, o que representou um ganho médio de 20,14%. A combinação de variáveis oceânicas e atmosféricas (OAV) resultou em um desempenho ainda superior ($R = 0,853$), embora o acréscimo relativo tenha sido menos expressivo (5,41%).

De modo geral, os resultados mostram que as variáveis atmosféricas têm maior relevância do que o uso exclusivo de variáveis oceânicas em todos os modelos testados. Entre as abordagens avaliadas, a LSTM se destacou por apresentar maior robustez e precisão. A única exceção ocorreu na Estação de Langkawi, onde o modelo ARIMA obteve melhor desempenho, possivelmente em função da influência dominante da maré no local. Isso indica que a eficácia dos modelos de previsão não é uniforme em todas as regiões, estando diretamente relacionada aos processos físicos predominantes que controlam a variabilidade do nível do mar em cada local.

Tabela 1 - Precisão R dos modelos ARIMA, SVR e LSTM para diferentes cenários em todas as estações.

Station	ARIMA	SVR				LSTM					
	No input	OV	AV	OAV	% Increase of AV relative to OV	% Increase of OAV relative to AV	OV	AV	OAV	% Increase of AV relative to OV	% Increase of OAV relative to AV
Langkawi	0.882	0.591	0.749	0.769	21.095	2.601	0.637	0.839	0.879	24.076	4.768
Pinang	0.605	0.549	0.726	0.742	24.380	2.156	0.595	0.816	0.852	27.083	4.412
Lumut	0.683	0.626	0.679	0.718	7.806	5.432	0.672	0.769	0.828	12.614	7.672
Port Kelang	0.835	0.699	0.659	0.712	-6.070	7.444	0.745	0.749	0.822	0.534	9.746
Tanjung Keling	0.703	0.619	0.706	0.737	12.323	4.206	0.665	0.796	0.847	16.457	6.407
Kukup	0.573	0.521	0.743	0.769	29.879	3.381	0.567	0.833	0.839	31.933	0.720
Johor Bahru	0.692	0.575	0.776	0.792	25.902	2.020	0.621	0.866	0.902	28.291	4.157
Mean of R	0.710	0.597	0.720	0.748	16.474	3.891	0.643	0.810	0.853	20.141	5.412

*OV, Ocean variables; AV, Atmospheric Variables; OAV, Ocean Atmospheric variables.

Legenda: OV: variáveis oceânicas, AV: variáveis atmosféricas e OAV: variáveis oceânicas e atmosféricas.

Fonte: Balogun & Adebisi, 2021.

Wang et al (2021) avaliaram a previsão de curto prazo da *Storm Surge* no norte da Ilha de Hainan, China, utilizando modelos de aprendizado de máquina, incluindo SVR, MLP, Redes Neurais Convolucionais (CNN - *Convolutional Neural Networks*) e LSTM, testados individualmente e em arquiteturas híbridas (CNN-LSTM e LSTM-CNN). Os modelos utilizaram como entrada *Surge Level*, obtida subtraindo-se a Maré astronômica do nível do mar observado, e as componentes do vento (U10 e V10). A saída correspondeu à previsão da elevação do nível do mar causada por tempestades em múltiplos horizontes futuros (1, 2, 4 e 6 horas). Essa abordagem permitiu avaliar a capacidade dos modelos em fornecer alertas

imediatos e estimativas antecipadas durante eventos extremos. Foram utilizados 11 anos de dados horários, mas o treinamento concentrou-se apenas nos períodos próximos à passagem de tufões, selecionados estatisticamente para reduzir a quantidade de dados e focar em situações extremas, mantendo a qualidade da amostra.

A Tabela 2 apresenta a comparação do desempenho dos modelos, mostrando que os híbridos (LSTM-CNN e CNN-LSTM) obtiveram os melhores resultados nas métricas estatísticas avaliadas. A combinação CNN-LSTM apresentou desempenho superior em todas as etapas de previsão, superando individualmente CNN e LSTM em aproximadamente 4 a 6%. Observa-se, ainda, que a acurácia tende a diminuir à medida que o horizonte de previsão se alonga, refletindo a maior complexidade de prever períodos mais longos.

Ao comparar CNN e LSTM, nota-se que, nas três últimas etapas, o RMSE da LSTM foi 1,1%, 1,7% e 2,1% inferior ao da CNN, enquanto, na primeira etapa, o RMSE da CNN foi 2,5% menor que o da LSTM. Em média, os modelos híbridos apresentaram RMSE inferior aos modelos individuais, evidenciando a vantagem de integrar CNN e LSTM para capturar simultaneamente padrões espaciais e dependências temporais.

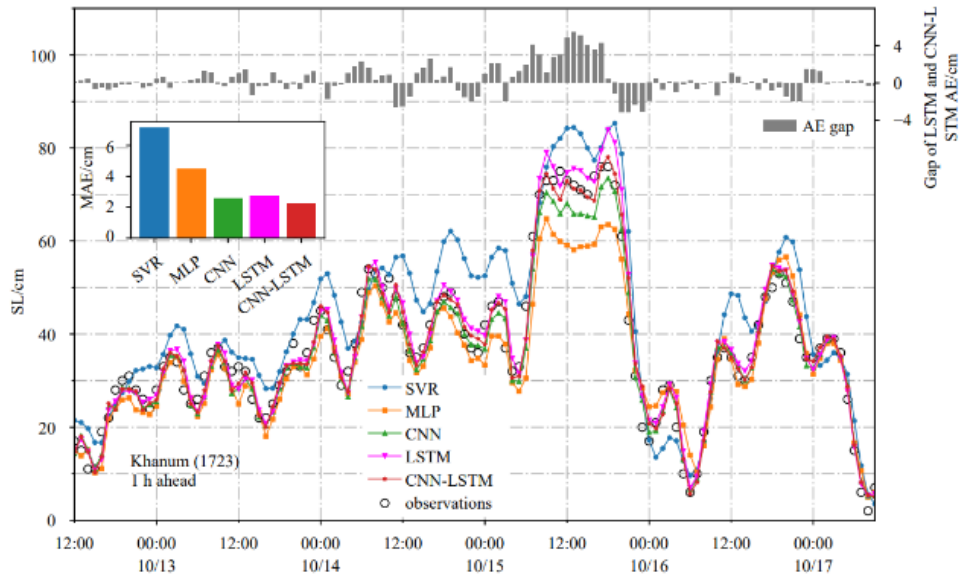
Tabela 2 - Resultados experimentais de seis algoritmos em dados de teste em intervalos de várias horas.

Steps	Index	SVR	MLP	CNN	LSTM	LSTM-CNN	CNN-LSTM
1 h	CC	0.850 5	0.954 3	0.965 5	0.962 9	0.965 8	0.966 1
	MAE/cm	5.895 8	3.208 3	2.695 6	2.795 7	2.668 2	2.630 3
	RMSE/cm	7.544 2	4.212 4	3.531 1	3.622 0	3.478 4	3.463 1
2 h	CC	0.771 6	0.883 0	0.900 2	0.902 9	0.904 6	0.908 6
	MAE/cm	6.869 2	4.821 1	4.502 1	4.455 6	4.383 2	4.267 6
	RMSE/cm	8.868 5	6.291 9	5.832 4	5.767 6	5.722 3	5.612 5
4 h	CC	0.671 5	0.733 4	0.780 7	0.789 2	0.794 2	0.799 1
	MAE/cm	7.644 9	6.831 0	6.407 1	6.368 3	6.191 9	6.091 8
	RMSE/cm	10.047 3	9.021 9	8.335 1	8.196 2	8.063 4	7.982 1
6 h	CC	0.460 8	0.658 8	0.705 6	0.718 3	0.720 4	0.736 1
	MAE/cm	9.507 3	7.687 7	7.118 4	6.935 3	6.921 1	6.738 0
	RMSE/cm	12.060 8	9.813 2	9.132 7	8.945 3	8.914 7	8.709 5

Fonte: Wang *et al.*, 2021.

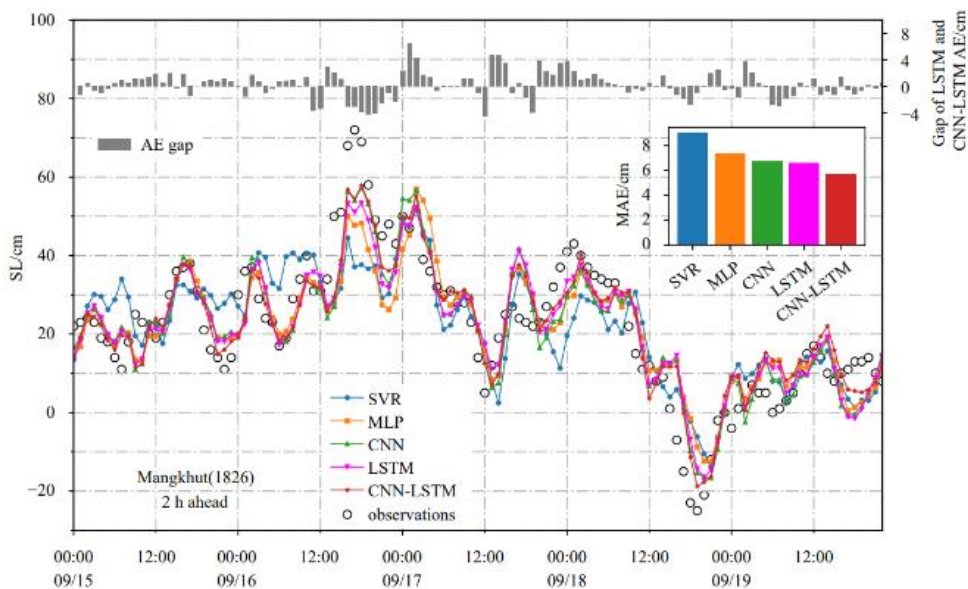
Além disso, esse estudo mostrou que a melhora na qualidade da precisão se concentra principalmente nos valores extremos positivos e negativos do NM, onde a tarefa de previsão é mais desafiadora e significativa, por meio de dois episódios de tufões, *Khanum* e *Mangkhut* (Figuras 13 e 14).

Figura 13 - Níveis do mar previstos para 1 hora à frente de SVR, MLP, CNN, LSTM e CNN-LSTM.



Fonte: Wang *et al.*, 2021.

Figura 14 - Níveis do mar previstos para 2 horas à frente de SVR, MLP, CNN, LSTM e CNN-LSTM.



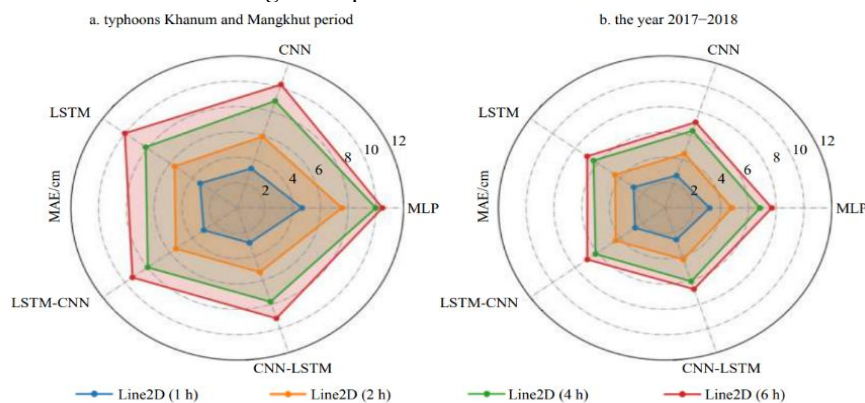
Fonte: Wang *et al.*, 2021.

A Figura 15 mostra dois diagramas de radar comparando o erro absoluto médio (MAE – *Mean Absolute Error*) de diferentes arquiteturas aplicadas à previsão do NM. Os diagramas mostram que o desempenho dos modelos de aprendizado de máquina na previsão do NM depende tanto da arquitetura quanto do horizonte de previsão.

As redes recorrentes (LSTM e variações híbridas) apresentaram menor MAE em comparação às arquiteturas MLP e CNN, especialmente em horizontes curtos (1–2h). No entanto, à medida que o horizonte de previsão aumenta (até 6 h), todos os modelos

apresentaram degradação de desempenho, com crescimento progressivo do erro. Essa tendência se acentua no período de ocorrência dos tufões *Khanum* e *Mangkhut*, quando os erros se elevam de forma mais pronunciada, sugerindo que eventos extremos impõem maior desafio às redes neurais. Já no período anual de 2017–2018, o aumento do erro foi mais gradual, evidenciando maior estabilidade em condições típicas.

Figura 15 - Gráficos de radar de diferentes modos para previsões de nível do mar de várias etapas para o período dos tufões *Khanum* e *Mangkhut* e para o ano de 2017 a 2018.



Fonte: Wang *et al.*, 2021.

Já mais próxima da área de estudo, Kaufmann (2024) teve como objetivo principal avaliar os impactos das mudanças climáticas nas estimativas de eventos extremos da MM do nível do mar na região do Porto de Imbetiba, Macaé – RJ. Esse fenômeno foi extraído a partir de um filtro passa-baixa com corte em 72 horas. Para isso, a autora empregou técnicas de inteligência artificial, utilizando redes neurais artificiais para projeções de longo prazo da MM, considerando tanto forçantes meteorológicas quanto oceanográficas, bem como os efeitos projetados das mudanças climáticas.

Foram utilizados 10 anos de dados históricos e 11 variáveis preditoras, incluindo componentes u e v do vento, tensão do vento na superfície do mar (T_x e T_y), componentes das ondas, temperatura do ar e pressão atmosférica ao nível médio do mar, com diferentes defasagens temporais e espaciais em quatro pontos oriundos do ERA-5. Na primeira fase do trabalho, os preditores foram definidos com base na climatologia presente, e as redes MLP e LSTM foram treinadas com dados do ERA5 organizados em conjuntos de treino, validação e teste. A LSTM apresentou desempenho robusto na previsão da maré meteorológica, com coeficientes de correlação entre 0,96 e 0,99, baixo RMSE (0,01–0,03 m) e viés próximo de zero. Resultados semelhantes foram obtidos para a MLP, ligeiramente inferiores aos da LSTM, sem diferenças estatisticamente significativas, evidenciando a capacidade da LSTM

em capturar relações não-lineares entre variáveis meteorológicas, oceanográficas e a maré meteorológica, explorando dependências temporais de forma consistente.

Nas etapas seguintes, o modelo calibrado foi aplicado a projeções futuras usando cenários climáticos RCP4.5 e RCP8.5, regionalizados a partir de modelos globais (HadGEM2-ES e MPI-ESM-MR) pelo modelo regional RegCM4 (*Regional Climate Model*, versão 4). Os dados atmosféricos regionalizados foram utilizados como entrada no modelo de ondas WAVEWATCH III (WW3), gerando informações sobre altura, direção e período das ondas. Tanto as variáveis atmosféricas quanto as ondas geradas pelo WW3 foram então utilizadas como preditores das redes neurais, permitindo que MLP e LSTM realizassem projeções de longo prazo da maré meteorológica.

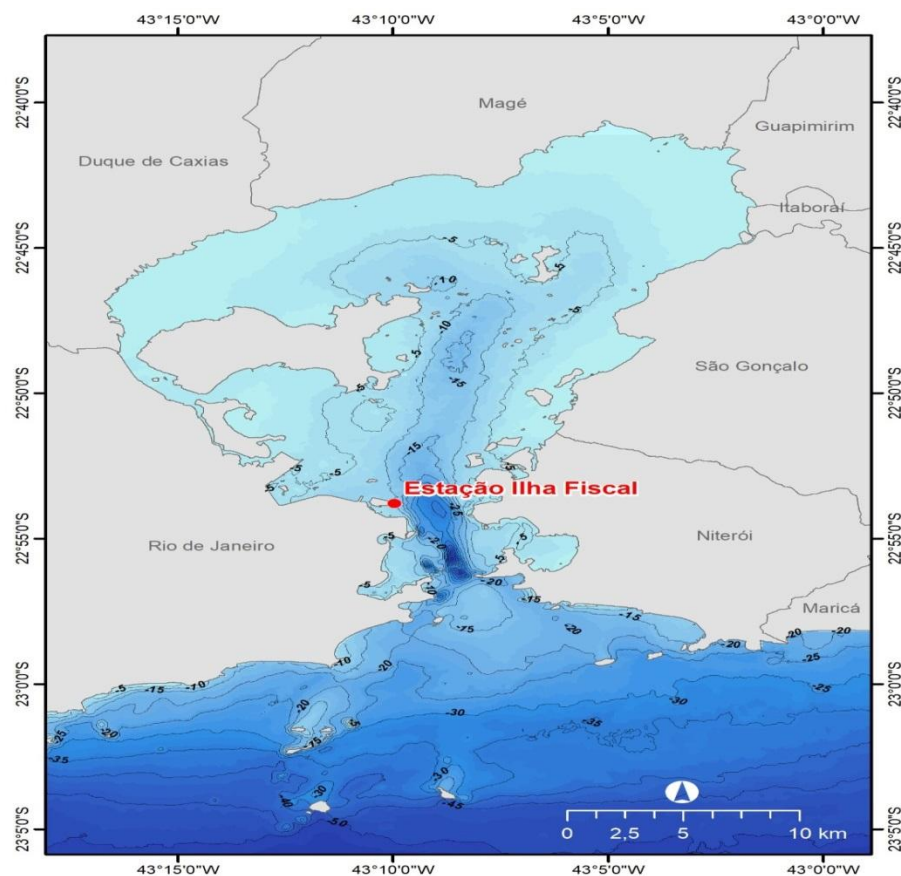
A análise de extremos foi realizada utilizando a Teoria das Excedências (POT) associada à Distribuição Pareto Generalizada (GPD), que considera todos os valores acima de um limiar, permitindo analisar mais pontos extremos e estimar com maior precisão frequência e magnitude dos eventos futuros com base no comportamento observado na série de dados. Primeiramente, os extremos foram estimados a partir da série histórica da MM (2006–2015) e, em seguida, comparados com os extremos obtidos a partir das séries projetadas pelas redes (2006–2060).

O período de retorno de 100 anos foi adotado como referência para projetos de infraestrutura costeira, permitindo avaliar o impacto das mudanças climáticas na estimativa desse valor. Observou-se que a LSTM tende a projetar valores de extremos maiores quando aplicada aos dados regionalizados, enquanto ambas as redes indicam aumento nos extremos projetados. Essa diferença sugere que a LSTM é mais sensível às não linearidades presentes nas projeções de longo prazo, embora, devido à natureza das projeções climáticas, não seja possível afirmar com total certeza a superioridade do modelo. A análise de sensibilidade revelou que variáveis relacionadas ao vento e à direção das ondas respondem por até 70% da variabilidade do modelo, destacando a importância de ampliar a base de dados e reduzir incertezas para melhorar a precisão das projeções futuras.

4 ÁREA DE ESTUDO

A Baía de Guanabara, situada nas latitudes de 22° 41' e 22° 58' S e longitudes de 43° 02' e 43° 18' W, é um ambiente estuarino de grande importância socioeconômica e ecológica para a cidade do Rio de Janeiro e sua região metropolitana (figura 16). Além de possuir diversos municípios localizados ao longo de suas margens e rios que desaguam em suas águas, abriga aeroportos, o Porto do Rio de Janeiro, diversas indústrias, refinarias de Petróleo, bases navais e estaleiros (Kjerfve *et al.*, 1997). A bacia também inclui diversos municípios e ilhas habitadas, onde atividades tradicionais como a pesca e a aquicultura continuam sendo fontes essenciais de sustento para muitas famílias. Do ponto de vista ecológico, a BG apresenta elevada biodiversidade, com ecossistemas marinhos e estuarinos que desempenham papel fundamental na conservação da fauna e flora locais (Kjerfve *et al.*, 1997; Chaves, 2021).

Figura 16 – Mapa da região de estudo (Baía de Guanabara – RJ) com representação das isolinhas de profundidade (em metros).



Fonte: A autora, 2025.

A BG é considerada uma baía costeira rasa, que ocupa uma área total de 384 km² e profundidade média de 5,7 m apresentando algumas características tipicamente estuarinas. (Kjerfve *et al.*, 1997; Castro *et al.*, 2005). Esta é orientada norte-sul, estendendo-se, aproximadamente, por 30 km e 28 km de oeste para leste. Sua entrada mede 1,6 km de largura (Kjerfve *et al.*, 1997). O canal de navegação principal possui uma profundidade média de cerca de 20 m, com valores máximos chegando a 50 m próximo da entrada da baía.

Localizada na Plataforma Continental Sudeste (PCSE), que corresponde a área entre a região do Cabo de São Tomé -RJ até o Cabo de Santa Marta -SC, a região apresenta orientação zonal da linha de costa predominante na direção SW-NE (Castro; Lee, 1995; Coelho, 2010). Na PCSE os sistemas atmosféricos que possuem maior influência na dinâmica da região são o Anticiclone Subtropical do Atlântico Sul (ASAS) e os Sistemas Frontais Polares, que podem ser frios, quentes ou estacionários. Este último sendo a perturbação meteorológica mais influente na região (Castro & Lee, 1995).

O ASAS: é um sistema meteorológico de macroescala semi-estacionário que ocorre o ano todo, sofrendo variações sazonais. Durante a estação do verão esse sistema está mais deslocado para o continente africano (menores valores de pressão atmosférica para a área de estudo) e durante o inverno seu centro se encontra mais próximo do continente sul-americano (maiores valores de pressão atmosférica). Esse deslocamento influencia remotamente o padrão de ventos na PCSE, que são compostos por ventos com direção predominantemente de NE-E. Esse sistema pode ser eventualmente desestabilizado por outras perturbações ondulatórias de escalas temporais e espaciais distintas como os Ciclones Extratropicais, vórtices desprendidos, eventos de *El Niño* (*El Niño Southern Oscillation* - ENSO) (Filippo *et al.*, 2012) e Zona de Convergência do Atlântico Sul (ZCAS), que eleva a frequência e magnitude dos eventos extremos de chuva (Cavalcanti & Kousky, 2009; Dereczynski *et al.*, 2022).

As Frentes frias são massas de ar frias e úmidas de baixa pressão que se originam nas regiões polares e se deslocam, geralmente, em direção às baixas latitudes. Os sistemas frontais se propagam para nordeste no Oceânico Atlântico Sul e dão origem a ventos intensos de S-SW à medida que a frente se desloca. Anteriormente a passagem dessas frentes, o vento inicia um movimento de rotação anti-horária passando a ser de noroeste. Durante a passagem da frente os ventos predominantes são de SW e possuem maior intensidade. (Stech; Lorenzetti, 1992; Cavalcanti; Kousky, 2009; Dereczynski *et al.*, 2022). A frequência desses sistemas e a intensidade do vento são maiores durante os meses de outono e inverno (Kjerfve *et al.*, 1997; Cavalcanti & Kousky, 2009; Dereczynski *et al.*, 2022). Esses sistemas ocorrem ao longo de

todo o ano e têm período de ocorrência em torno de 5 à 10 dias. As altas migratórias que se deslocam junto às frentes frias também influenciam a região com eventos de rebaixamento do NM (Borba *et al.*, 2022).

Segundo Pimentel *et al* (2014) o padrão do vento na estação do aeroporto Santos Dumont, próximo à entrada da baía, em sua totalidade é norte-sul. Quanto ao ciclo diário, nos períodos da tarde e da noite há uma maior contribuição para os ventos de quadrante sul. Já os ventos da madrugada e da manhã para os ventos de quadrante norte. Na estação do aeroporto do Galeão, localizada mais no interior da baía, o padrão do vento é mais distribuído entre as direções, com predominância de sudeste e leste. Com relação ao ciclo diário, nos períodos da tarde e noite as direções predominantes são de sudeste, principalmente, no período da tarde, e leste. Por outro lado, nos períodos da madrugada e manhã os ventos são mais distribuídos, porém as direções leste e norte se destacam com maior frequência.

Em relação à importância da força remota da tensão do vento na dinâmica da PCSE, estudos demonstram que as OCCs, responsáveis por modular a altura da superfície do mar, apresentam forte correlação com ventos de quadrante sul registrados em períodos anteriores à resposta observada no NM (Gill & Schumann, 1979; Brink, 1991; Stech & Lorenzetti, 1992; Castro & Lee, 1995; Filippo *et al.*, 2012; Melo, 2017; Dottori & Castro, 2018; Freitas *et al.*, 2021). A região de geração dessas ondas estende-se desde a Patagônia até a plataforma sul do Brasil, caracterizando-se pela formação frequente de frentes frias e sistemas ciclônicos (Cavalcanti & Kousky, 2009; Reboita *et al.*, 2010; Melo, 2017; Freitas *et al.*, 2021). Essa região pode ser dividida em duas subáreas distintas: ao sul e ao norte de 45°S, sendo esta última a que apresenta maior energia e maior coerência com o sinal dessas ondas que se propagam em direção à plataforma continental brasileira (Freitas *et al.*, 2021).

As OCCs são ondas de baixa frequência que se propagam ao longo das margens continentais, mantendo-se próximas à costa — à direita no hemisfério norte e à esquerda no hemisfério sul — com períodos que podem variar de alguns dias a várias semanas (Castro & Lee, 1995; Filippo *et al.*, 2012; França, 2013; Melo, 2017; Freitas *et al.*, 2021). Essas ondas têm apresentando amplitude máxima junto à margem continental e atenuação exponencial em direção ao oceano aberto, sendo guiadas pela topografia da plataforma. Podem assumir modos distintos: o barotrópico, no qual a resposta é quase uniforme na coluna d'água e está mais diretamente associado ao forçamento do vento (Dottori & Castro, 2009); e os modos baroclínicos, modulados pela estratificação, com propagação mais lenta e estrutura vertical complexa, o que pode permitir modulações e amplificação da onda em camadas específicas (Brink, 1991; Huthnance, 1978 apud Freitas *et al.*, 2021). Dottori & Castro (2009)

demonstraram que a resposta subinercial ao vento na região central da Plataforma sul do Brasil é predominantemente barotrópica.

Na margem brasileira, a propagação dessas ondas ocorre predominantemente em direção ao equador, acompanhando a linha de costa. Entretanto, sua energia sofre significativa atenuação ao norte de 22°S, devido à variação na largura e profundidade da plataforma continental e à estratificação da coluna d'água. Dessa forma, as OCCs desempenham papel significativo na dinâmica de mesoescala e na variabilidade das correntes ao longo da plataforma continental, provocando não apenas alterações no nível do mar, mas também flutuações nas correntes longitudinais à linha de costa.

Na PCSE, Castro & Lee (1995) descrevem a convergência de sinais de maré em direção à região central da plataforma, resultado da propagação de duas ondas da componente harmônica semidiurna M_2 : uma originada em Cabo Frio, com direção sudoeste, e outra proveniente do sul da plataforma, propagando-se para nordeste. Essa convergência está associada à presença de dois pontos anfidrômicos no Oceano Atlântico Sul (Brown, 1989; Castro & Lee, 1995). De acordo com o critério de Courtier (1932), que é o critério utilizado pela Marinha do Brasil (MB) para classificar as marés e calcular o NR, a maré na região é classificada como semidiurna com desigualdades diurnas (Coelho *et al.*, 2015). A maré desempenha papel significativo na variabilidade do NM na BG, principalmente devido às componentes semidiurnas, além do efeito das componentes de águas rasas resultantes do atrito com o fundo e por outros efeitos não-lineares locais. Além disso, a maré na BG é uma co-oscilação com a região oceânica, não sendo gerada por forças locais, mas sim pela propagação da maré conforme Castro & Lee (1995).

5 METODOLOGIA

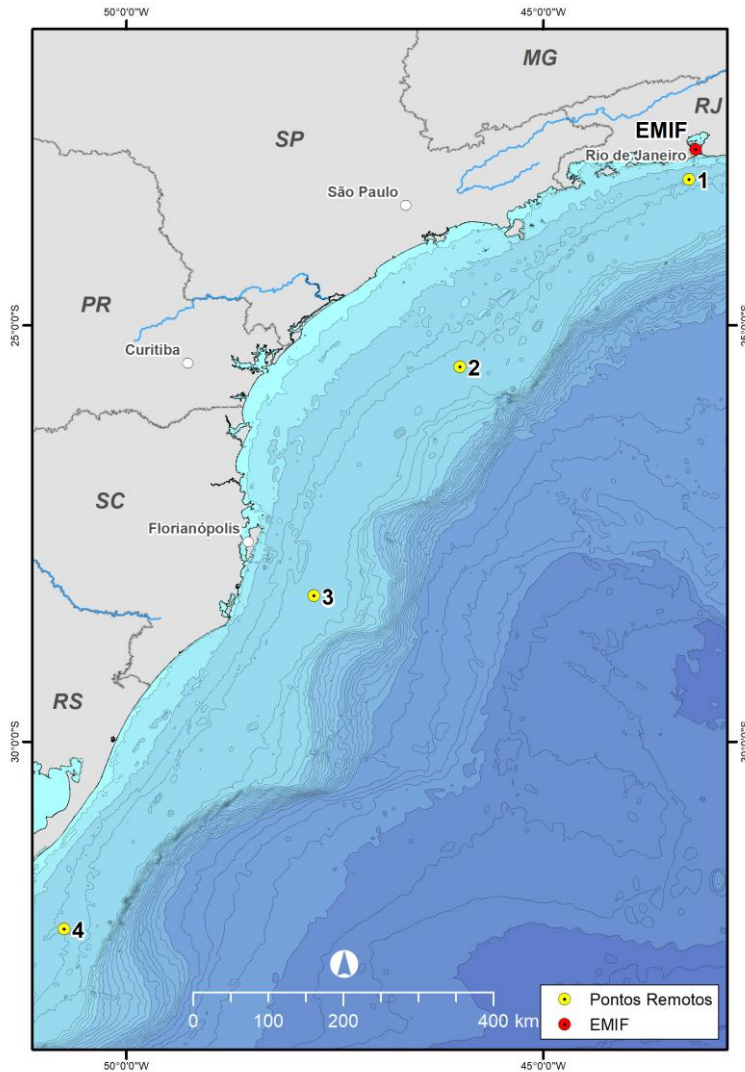
5.1 Dados utilizados e análises das séries de dados

Inicialmente, foi selecionado um período de dados de nível do mar disponibilizados pelo Banco Nacional de Dados Oceanográficos (BNDO/CHM). As informações foram obtidas por meio de um marégrafo localizado na Estação Ilha Fiscal, com taxa de amostragem de 5 minutos. Observou-se que o ano de 2021 apresentava uma lacuna no mês de junho, enquanto os dados de 2023 estavam disponíveis apenas até o mês de julho. Essas limitações de disponibilidade influenciaram diretamente a definição do período adotado para o estudo, de forma a garantir séries temporais contínuas e consistentes para a análise.

Os dados meteorológicos, Componentes zonal (U) e meridional (V) do vento e Pressão Atmosférica ao Nível Médio do Mar (PANMM), foram obtidos da base das simulações de reanálise do *European Center for Medium-Range Weather Forecast - Copernicus Climate Change Service (ECMWF)*, ERA-5. Esses dados se encontram no formato *NetCdf* com resolução temporal horária, para o período de 01/01/2016 – 31/12/2020 com $0,25^\circ \times 0,25^\circ$ de resolução horizontal (cerca de 27km).

A Figura 18 destaca o ponto de dados utilizado no modelo de previsão, que inclui a estação maregráfica, três pontos da grade ERA5 mais ao sul da BG para melhor representar a variabilidade espacial do campo eólico, buscando capturar a influência de ventos remotos, e um ponto mais próximo da BG para refletir o efeito do BI. As coordenadas geográficas desses pontos são mostradas na Tabela 3.

Figura 17 - Localização da Estação Maregráfica da Ilha Fiscal (EMIF) e dos pontos de extração de dados do ERA-5.



Fonte: A autora, 2025.

Tabela 3 - Localização dos pontos de dados meteorológicos e do nível do mar.

Location	Lat	Lon
EMIF	22.89° S	43.17° W
1	23.25° S	43.25° W
2	25.50° S	46.00° W
3	28.25° S	47.75° W
4	32.25° S	50.75° W

Fonte: A autora, 2025.

A seleção do período de dados considerou o período concomitante entre as variáveis de entrada e saída e os anos com menor ocorrência de dados ausentes, critério essencial para o bom desempenho da rede neural. Diante disso, foi definido o período de 2016 a 2020.

Anteriormente à adoção dos dados do ERA5, foi realizada uma análise preliminar com os dados da boia SIMCOSTA RJ-4. Verificou-se que os anos de 2017 e 2018 apresentaram a menor porcentagem de dados ausentes e maior continuidade temporal em relação ao total de dados disponíveis dessa boia. No entanto, após diversas análises comparativas entre os dados da boia e os de reanálise, optou-se pela utilização do ERA5, por este representar de maneira mais direta a influência das forçantes atmosféricas, sobretudo aquelas de origem remota, sobre o nível do mar na região da Ilha Fiscal. Além disso, o curto período selecionado dos dados da boia também foi um fator limitante que contribuiu para essa decisão.

Essa análise comparativa corrobora o que foi apontado por Melo (2017), ao indicar que variáveis meteorológicas provenientes de locais remotos exercem maior influência sobre a maré meteorológica do que os dados locais. Essa influência se mostra especialmente relevante quando essas variáveis são utilizadas como entradas para redes neurais na tarefa de previsão. Ainda assim, não se descarta a importância de análises e testes com períodos mais longos de dados locais, visando avaliar com maior robustez sua contribuição com entrada na rede para previsão da MM.

Posterior a decisão da seleção do período de análise foi feito o pré-processamento destes dados, que consiste em realizar um controle de qualidade dos dados tomando como base Bushnell & Worthington (2021) a fim de remover possíveis *outliers*, lacunas, dados consecutivos semelhantes, alturas abruptas, entre outros.

Foram implementados cinco testes listados na Tabela 4: quatro descritos no manual — Faixa Bruta (Teste 4), Spike (Teste 6), Taxa de Variação (Teste 7) e Linha Plana (Teste 8).

Tabela 4 - Critérios utilizados para o controle de qualidade.

TESTE	RESUMO
Faixa bruta (Teste 4)	Dados coletados em períodos em que os valores de nível estão fora dos limites de +2 metros e -2 metros são desconsiderados.
<i>Spike</i> (Teste 6)	Dados (n_1) que excedam a média entre seus vizinhos adjacentes $((n_2 + n_0)/2)$ são desconsiderados ($n_1 - ((n_2 + n_0)/2) > 0$).
Taxa de Variação (Teste 7)	Dados em que a subtração com seu antecessor ($n_1 - n_0$) exceda 0,25 vezes o desvio padrão (STD) de uma amostragem de 25 horas posteriores são desconsiderados ($n_1 - n_0 > 0,25 * STD [n_1 : n_{25}]$).
Linha Plana (Teste 8)	Acima de 5 horas de dados consecutivos iguais são desconsiderados.

Fonte: A autora, 2025.

Em seguida, realizou-se a análise harmônica utilizando o pacote U-TIDE (Codiga, 2011), a partir da qual foram obtidas as constantes harmônicas e, por conseguinte, gerado a série da Maré astronômica. Posteriormente, o NnA foi obtido conforme Equação 6.1 (Melo, 2017; Pugh, 1987).

$$NnA(t) = NM(t) - MA(t) \quad (6.1)$$

Adicionalmente, foram realizadas análises espectrais com a finalidade de avaliar tanto as principais frequências do nível do mar observado e da Maré astronômica, quanto investigar o nível não-astronômico e separar a banda de interesse tomando como base o trabalho de Melo (2017). Tais bandas são: banda sazonal (período de 30 dias a 1 ano), maré meteorológica (período de 3 dias a 30 dias) e maré de vento (período de 2 horas a 3 dias). Para a execução das análises espectrais foi empregado a função *Pwelch*. Essa ferramenta estima a densidade espectral de potência de um sinal. Esse método realiza sobreposições nas divisões realizadas na série, calcula a Transformada de Fourier em cada segmento, obtém um espectro para cada um deles e estes são combinados calculando a média, com a finalidade de não haver perdas de informações e suavizar o espectro (Rosa, 2024). Com isso, a estimativa torna-se mais confiável, ajuda na redução do ruído e se adaptam a variações nas características do sinal ao longo do tempo. Desse modo, foi possível identificar as frequências mais significativas nos níveis do mar observado, astronômico e não-astronômico.

Entretanto, as frequências correspondentes às bandas não astronômicas, identificadas por MELO (2017), podem apresentar variações em função da localidade analisada. Para reduzir essa incerteza, foi aplicado o intervalo de confiança espectral (ICE), o que permitiu uma determinação mais precisa dos limites que definem essas bandas (Emery & Thomson, 2001):

$$\frac{(n-1)s^2}{X_{\alpha/2, v}^2} < \sigma^2 < \frac{(n-1)s^2}{X_{1-\alpha/2, v}^2} \quad (6.2)$$

Onde: n é o número de amostras, s^2 é a variância populacional, σ^2 é a variância amostral, X^2 é uma função assimétrica (os limites superiores e inferiores da amostra são assimétricos), α é a significância estatística desejada (no presente estudo esse valor foi de 99%) e v são os graus de liberdade da distribuição do qui-quadrado. As operações $\alpha/2$ e

$1 - \alpha/2$ representam os valores extremos do intervalo de confiança. No presente estudo as amostras citadas são as densidades espectrais calculadas para os níveis do mar medido, astronômico e não-astronômico. Assim, a Equação 6.2 aparece da seguinte forma (MELO, 2017):

$$\frac{\tilde{P}_{xx}}{X_v^2(\alpha/2)} < P_{xx} < \frac{\tilde{P}_{xx}}{X_v^2(1 - \alpha/2)} \quad (6.3)$$

Sendo P_{xx} o intervalo de confiança da densidade espectral, \tilde{P}_{xx} o estimador e X_v^2 é a função qui-quadrada com v graus de liberdade. Essa técnica possibilitou a determinação do limite de frequência entre as bandas não-astronômicas com maior precisão.

Em seguida, foi empregado o filtro digital *Butterworth* passa-banda, amplamente utilizado na comunidade científica (Roberts; Roberts, 1978; Filippo, 2003; Filippo *et al.*, 2012; Coogan *et al.*, 2019; Kjerfve *et al.*, 2021; Fernandes *et al.*, 2023), com as frequências de corte determinadas através da avaliação espectral. No presente estudo esta técnica foi utilizada para obter a curva da sub-banda meteorológica, onde apenas as frequências que estejam no intervalo determinado serão mantidas.

5.2 Escolha das variáveis de entrada

As variáveis de entrada foram selecionadas com base nos mecanismos físicos associados à geração da maré meteorológica, considerando as principais forçantes atmosféricas identificadas na literatura (Gill & Schumann, 1979; Brink, 1991; Stech & Lorenzetti, 1992; Castro & Lee, 1995; Parise *et al.*, 2009; Filippo *et al.*, 2012; Melo, 2017; Vedana *et al.*, 2021). Considerando que o vento remoto tende a exercer maior influência do que o vento local, foi aplicada a análise de correlação cruzada para identificar os atrasos temporais entre essas variáveis e a MM.

Essa técnica permite medir o grau de similaridade entre duas séries temporais conforme uma delas é deslocada no tempo, sendo especialmente útil para estimar defasagens

relevantes na dinâmica do sistema. Valores positivos de defasagem indicam que a variável explicativa ocorre antes da resposta na maré, enquanto valores negativos indicam o contrário.

Com os lags definidos com base na máxima correlação cruzada, foi realizada em seguida a análise de correlação de *Pearson* entre as variáveis. Essa etapa teve como objetivo identificar a força e a direção das associações entre as variáveis, fornecendo um diagnóstico preliminar da estrutura de dependência entre os dados. O coeficiente de correlação linear varia entre -1 e 1, sendo utilizado neste trabalho como critério complementar para a identificação das variáveis mais relevantes a serem utilizadas como entrada da rede.

O coeficiente de correlação de *Pearson* entre duas variáveis x e y é dado pela Equação 6.4:

$$r(x, y) = \frac{\sum(x - \bar{x})(y - \bar{y})}{\sqrt{\sum(x - \bar{x})^2 \sum(y - \bar{y})^2}} \quad (6.4)$$

Neste estudo, foram selecionadas as variáveis com correlação entre moderada e forte a partir da referência de valores proposta por Cohen (1988):

- $0,5 \leq |r| \leq 1,0$: Forte correlação linear.
- $0,3 \leq |r| < 0,5$: Correlação linear moderada;
- $0,0 \leq |r| < 0,3$: Correlação linear fraca ou ausência de correlação.

5.3 Teste de Estacionaridade

Foi aplicado o teste de estacionaridade em cada variável de entrada definida para verificar se constituem uma série estacionária. Primeiramente, foram calculadas a média e variância de cada série temporal, onde a série é dividida em duas partes e os valores dessas métricas de cada parte serão comparadas, se forem próximos ou constantes ao longo do tempo, a série é estacionária. Por outro lado, se a série temporal original não for estacionária, pode-se aplicar uma decomposição aditiva para obter uma série residual estacionária, que servirá como entrada para a rede neural.

Por fim, foi realizado o teste estatístico de *Augmented Dickey-Fuller* (ADF) (Dickey & Fuller, 1979), Dickey-Fuller Aumentado, em português. O teste ADF é uma estatística utilizada para averiguar se a série temporal é estacionária, ou seja, se tem a presença ou não de raiz unitário no conjunto de dados. Esse teste avalia a hipótese nula de que uma série temporal possuir uma raiz unitária (não estacionária). A hipótese alternativa, que rejeita a hipótese nula, é que a série temporal não tem uma raiz unitária, ou seja, estacionária. A interpretação do teste se dá pelo cálculo do *p-value*. Desse modo, valor menor ou igual a 0,05 significa que a série é estacionária.

Na tabela 5 encontram-se os valores de média e variância obtidos na divisão de cada série temporal em duas partes. Nota-se que ambas as séries possuem valores próximos dessas métricas nas duas divisões, sendo, portanto, consideradas estacionárias. Além disso foi feito o teste estatístico de ADF para confirmar tal possibilidade.

Tabela 5 - Resultados estatísticos de cada variável da rede neural LSTM.

		Componente U		Componente V		Pressão (hpa)		Maré meteorológica(cm)	
Pontos	Partes da série	Variância	Média	Variância	Média	Variância (hpa ²)	Média (hpa)	Variância (cm ²)	Média (cm)
EMIF	1º	-	-	-	-	-	-	140,2	-0,05
	2º	-	-	-	-	-	-	134,9	0,02
1	1º	-	-	-	-	25,29	1.015	-	-
	2º	-	-	-	-	20,99	1.016	-	-
2	1º	14,11	-2,68	17,70	-0,30	-	-	-	-
	2º	13,58	-2,79	18,26	-0,08	-	-	-	-
3	1º	15,22	-0,87	37,73	-1,26	-	-	-	-
	2º	14,88	-1,02	38,72	-1,13	-	-	-	-
4	1º	32,05	-1,09	29,14	-0,50	-	-	-	-
	2º	30,54	-1,20	29,84	-0,40	-	-	-	-

Fonte: A autora, 2025.

A partir da Tabela 6 é possível verificar que todas as variáveis de entrada apresentam um valor de *p-value* abaixo de 0,05 do teste ADF, indicando que as séries são estacionárias. Além disso, quanto mais negativo for o valor da estatística, maior é a probabilidade que a série seja estacionária (Brownlee, 2020).

Tabela 6 - Resultado do teste estatístico ADF para os dados meteorológicos do ERA-5 e para a maré meteorológica.

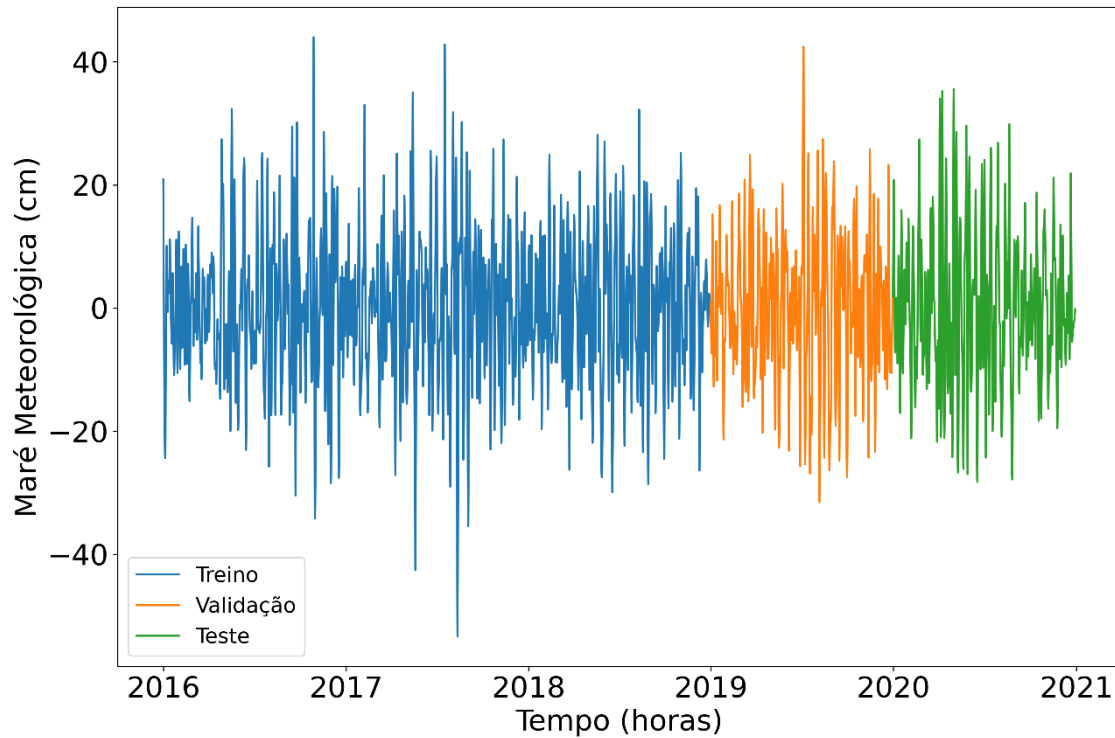
Pontos	Séries	<i>p-value</i>	Estatística do teste
EMIF	Maré meteorológica	0	-44.19
1	Pressão	0	-12.69
2	U	0	-22.57
	V	0	-26.99
3	U	0	-21.26
	V	0	-25.60
4	U	0	-20.88
	V	0	-26.19

Fonte: A autora, 2025.

5.4 Treinamento da rede neural

Os dados horários observados das variáveis foram divididos em três conjuntos: treinamento (60%), validação (20%) e teste (20%). A separação foi realizada utilizando a função *train_test_split* da biblioteca *Scikit-Learn*. A Figura 18 ilustra a divisão da série da MM.

Figura 18 - Série temporal da maré meteorológica observada, destacando os conjuntos de dados utilizados para treinamento, validação e teste da rede neural.



Fonte: A autora, 2025.

5.5 Implementação da rede neural

Os scripts da rede neural foram implementados em linguagem *Python*, com o auxílio de bibliotecas voltadas ao aprendizado de máquina. A arquitetura LSTM foi desenvolvida utilizando o *framework Keras*, integrado ao pacote *TensorFlow*.

Esse pacote permite configurar diversos parâmetros essenciais para a construção de redes LSTM, dentre os quais destacam-se:

- a) **Número de entradas (*features*):** representa a quantidade de variáveis independentes fornecidas ao modelo em cada instante de tempo. Cada entrada corresponde a uma dimensão dos dados utilizados para prever os valores futuros, refletindo as características que influenciam o fenômeno em estudo.
- b) **Número de camadas:** indica o número total de camadas presentes na arquitetura da rede. No caso de redes LSTM, é possível empilhar múltiplas camadas LSTM ou combiná-las com camadas densas (*Dense Layers*), o que pode aumentar a capacidade de representação do modelo e facilitar a detecção de padrões temporais mais complexos. Contudo, o aumento da profundidade da rede pode elevar o risco de sobreajuste (*overfitting*) e o custo computacional.

c) **Número de unidades LSTM:** corresponde à quantidade de neurônios em cada camada LSTM. Essas unidades atuam como células de memória responsáveis por armazenar e processar informações ao longo da sequência temporal. Um maior número de unidades pode melhorar a capacidade da rede de capturar dependências de longo prazo, embora também implique em um número maior de parâmetros, o que pode resultar em maior tempo de treinamento e maior propensão ao *overfitting*.

d) **Dropout:** é uma técnica de regularização empregada para reduzir o *overfitting*. Durante o treinamento, uma fração das unidades é desativada aleatoriamente, conforme definido pelo parâmetro dropout. Essa abordagem pode ser aplicada tanto nas camadas LSTM quanto nas camadas densas, promovendo uma generalização mais eficaz do modelo.

e) **Funções de ativação:** determinam como a saída de cada neurônio é calculada a partir de sua entrada. São responsáveis por introduzir não linearidades no modelo, o que permite que a rede aprenda padrões complexos e represente relações não lineares entre as variáveis. Cada função possui características específicas que impactam o desempenho e a estabilidade do treinamento.

Com o objetivo de aumentar a confiabilidade e a estabilidade no desempenho do modelo, foram adotadas algumas técnicas específicas. Entre elas, destaca-se a normalização dos dados de entrada, que visa evitar que variáveis com escalas maiores exerçam influência desproporcional sobre a atualização dos pesos durante o treinamento. Além disso, contribui para acelerar o processo de convergência da rede e reduzir o custo computacional associado ao ajuste dos parâmetros.

Outra técnica adotada foi a otimização dos hiperparâmetros por meio do método *RandomSearch*, implementado com o auxílio do *Keras Tuner*. Esse procedimento consiste na amostragem aleatória de combinações de hiperparâmetros dentro de um espaço definido, com o objetivo de identificar configurações que maximizem o desempenho do modelo. A busca é guiada pela avaliação dos resultados em um conjunto de validação, permitindo selecionar os valores que resultam em maior acurácia preditiva para a rede LSTM (Géron, 2021).

Os hiperparâmetros são configurações definidas previamente ao treinamento e que controlam o funcionamento e o desempenho do modelo. Diferentemente dos parâmetros internos, como os pesos sinápticos, que são ajustados durante o processo de aprendizagem, os hiperparâmetros devem ser estabelecidos antes da fase de treinamento. A escolha adequada desses valores pode impactar significativamente a precisão, a capacidade de generalização e a

estabilidade do modelo. Um conjunto bem ajustado de hiperparâmetros permite que o modelo se aproxime de um comportamento ideal para o problema em questão, reduzindo o erro de predição e promovendo o equilíbrio entre viés e variância. Para isso, diferentes combinações são testadas com o objetivo de identificar a configuração que ofereça o melhor desempenho.

A manipulação manual de cada combinação de hiperparâmetros para otimizar a performance do modelo pode se tornar monótona e demorada. Além disso, ao definir aleatoriamente os valores, pode vir a ocorrer o fenômeno de *overfitting*. Este é observado quando o modelo apresenta uma acurácia significativamente maior no conjunto de treinamento em comparação com o conjunto de teste, ou seja, o modelo se ajusta em excesso aos dados de treinamento, prejudicando sua capacidade de generalização para novos dados (teste). Esse fenômeno é um problema comum em modelos de aprendizado de máquina e pode levar a previsões imprecisas em novos conjuntos de dados. Desse modo, é fundamental identificá-lo para garantir a eficácia do modelo.

Os critérios utilizados para a seleção dos hiperparâmetros do modelo, estão apresentados na Tabela 7.

Tabela 7 - Hiperparâmetros avaliados durante a busca com *Random Search*.

Hiperparâmetro	Opções Avaliadas
Unidades de Entrada	32 a 512 (step = 32)
Número de camadas	1 a 4
Unidades por camada oculta	32 a 512 (step = 32)
Função de ativação	ReLu, Sigmoid, Linear
Taxa de <i>Dropout</i>	0.0 a 0.4 (step = 0.1)
<i>Batch Size</i>	32, 64, 128

Fonte: A autora, 2025.

5.6 Métodos de avaliação do desempenho do modelo

Os resultados obtidos com a rede LSTM serão avaliados em comparação aos resultados reais observados com as seguintes métricas estatísticas: Coeficiente de Correlação

(r), Viés (*bias*), índice de dispersão (*Scatter Index* - SI) e RMSE. As Equações 6.5 a 6.8 representam matematicamente tais métricas.

O bias e o SI são medidas estatísticas usadas para avaliar a qualidade e a confiabilidade dos resultados experimentais. O bias quantifica os erros sistemáticos ou desvios em relação ao valor verdadeiro, enquanto o índice de dispersão mede a variabilidade aleatória ou imprevisível nos dados. O bias pode ser calculado tomando a média das diferenças entre os valores medidos e os valores verdadeiros ou um padrão de referência. O índice de dispersão quantifica a dispersão ou a distribuição dos pontos de dados em torno do valor médio. O método de cálculo mais comum é o desvio padrão. Já o coeficiente de correlação avalia o grau de associação linear entre os valores previstos e observados, indicando o quanto as variações de um acompanham as do outro.

O RMSE fornece uma indicação de quão bem o modelo prevê os valores reais. Um RMSE mais baixo indica melhor precisão preditiva. O RMSE é calculado tomando a raiz quadrada da média das diferenças ao quadrado entre os valores observados e previstos.

$$r = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}) (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (6.5)$$

$$BIAS = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (6.6)$$

$$SI = \sqrt{\frac{\sum_{i=1}^n [(\hat{y}_i - \bar{\hat{y}}) - (y_i - \bar{y})]^2}{\sum_{i=1}^n y_i^2}} \quad (6.7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (6.8)$$

Onde: n = número total de amostras; i = instante de tempo; y = valor observado; \hat{y} = valor previsto.

6 RESULTADOS

6.1 Seleção dos dados


Os resultados obtidos após a aplicação dos testes de qualidade nos dados de NM evidenciaram alguns *outliers*, porém após uma análise complementar por meio das cartas sinóticas correspondentes aos respectivos períodos, concluiu-se que esses valores extremos estavam associados à atuação de sistemas atmosféricos na região. Diante disso, os dados foram mantidos na série por representarem variações do fenômeno.

6.1.1 Comparação das bandas astronômicas e não-Astronômicas do nível do mar

Os limites da MM foram definidos por meio da análise espectral empregando a função *Pwelch* tomando como base o trabalho de Melo (2017). A aplicação do intervalo de confiança espectral possibilitou uma maior acurácia na determinação desses limites (Emery & Thomson, 2001).

A Figura 19 apresenta o comparativo entre as análises espectrais, com 4 graus de liberdade (para não haver perda de informação nas bandas dos níveis não-astronômicos), dos dados de NM, MA e NnA. Observa-se na figura que a banda não-Astronômica possui uma energia mais significativa entre 0 e 0,35 ciclos por dia (cpd). O maior valor de densidade de energia dessa banda foi de, aproximadamente, $2.980 \text{ cm}^2 \cdot \text{dia}^{-1}$, na frequência de 0,024 cpd. Por outro lado, na banda astronômica, é possível observar que as componentes semidiurnas da maré possuem a maior energia do NM observado. A componente lunar semidiurna principal (M2) é a mais energética, ultrapassando $300.000 \text{ cm}^2 \cdot \text{dia}^{-1}$ de densidade de energia e posteriormente a componente S2 com, aproximadamente, $110.000 \text{ cm}^2 \cdot \text{dia}^{-1}$. Em relação as, componentes diurnas, a componente mais energética foi a O1, aproximadamente, $30.000 \text{ cm}^2 \cdot \text{dia}^{-1}$, seguido da componente K1 e Q1, respectivamente.

Figura 19 - Espectros de energia do nível do mar observado (NM), maré astronômica (MA) e nível não-astronômico (NnA), com 4 graus de liberdade, para o período de 01/01/2016 a 31/12/2020.



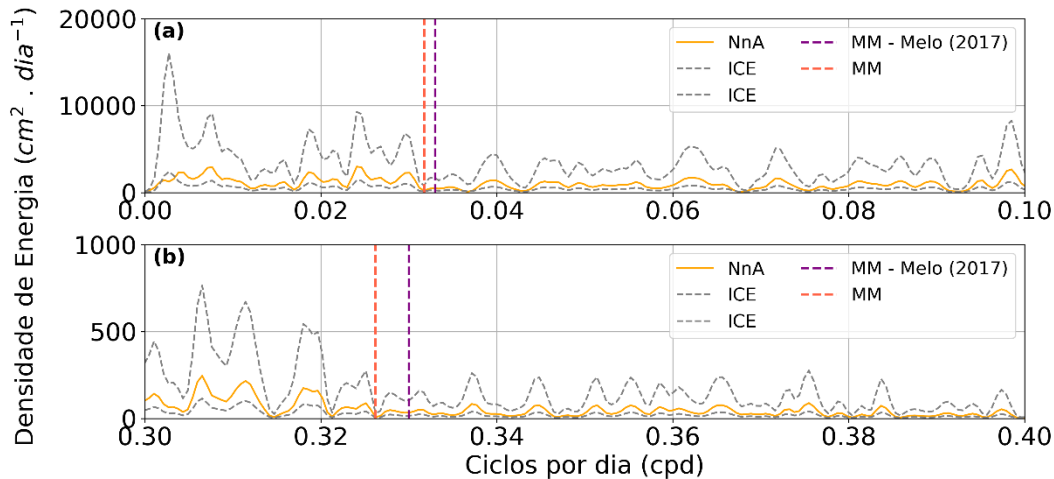
Legenda: linhas tracejadas correspondem as frequências das componentes harmônicas da maré. MU2 = constituinte variacional, N2 = elíptica semidiurna lunar, M2 = lunar semidiurna principal, S2 = solar semidiurna principal, K2 = luni-solar semidiurna declinacional, Q1 = lunar diurna elíptica maior, O1= lunar diurna principal, NO1 = Lunar elíptica menor, P1= solar diurna principal e K1= luni-solar diurna declinacional. Fonte: (*Harmonic Constituents, NOAA*).

Fonte: A autora, 2025.

6.1.2 Banda meteorológica

A figura 20 apresenta o espectro do NnA, com 4 graus de liberdade, para o período de 01/01/2016 a 31/12/2020. A linha tracejada em cinza representa o intervalo de confiança espectral (ICE), enquanto as demais representam os limites da banda meteorológica proposta por Melo (2017) e indicado pelo presente estudo. Na figura 27 foi possível observar que a maior parte da energia do NnA se concentra nas bandas sazonal e meteorológica. Os limites de frequência indicadas da banda meteorológica foram as que se encontram exatamente em um ponto onde o ICE tende a 0, foram eles: 0,031758 cpd (31,5 dias) e 0,32622 cpd (3,06 dias) dessa banda. O uso desses novos limites não resultou em perda significativa de energia.

Figura 20 - Espectro do NnA, com 4 graus de liberdade, para o período de 01/01/2016 a 31/12/2020.



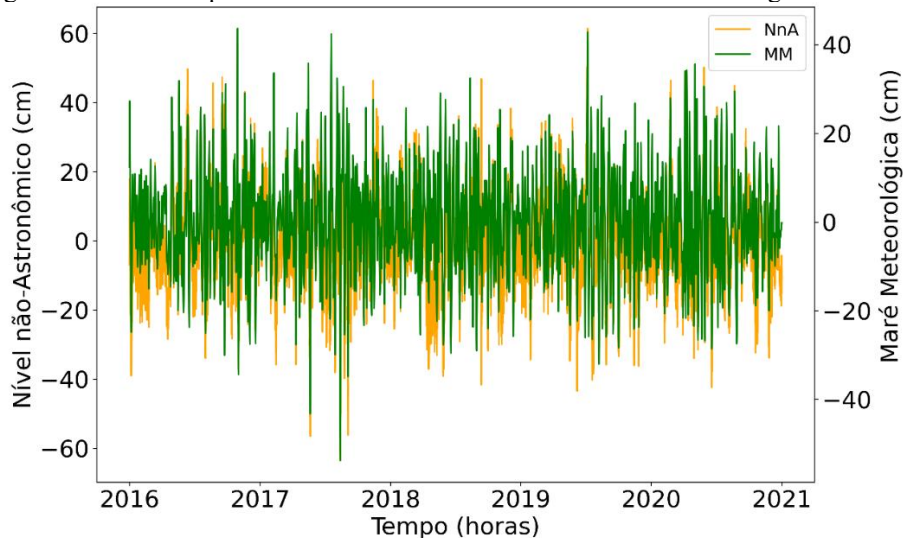
Legenda: As linhas tracejadas correspondem ao intervalo de confiança espectral (ICE), limites da frequências da sub-banda meteorológica proposto por MELO (2017) (MM – MELO (2017)), limites da frequências da sub-banda meteorológica proposto no presente estudo (MM) e a linha sólida corresponde ao NnA.

Fonte: A autora, 2025.

Após a definição dos limites de frequência, o passo seguinte foi aplicar o filtro *Butterworth* passa-banda no NnA para obter a MM e calcular a variância do NnA e da MM com o intuito de avaliar a energia dessa sub-banda. A MM representou, aproximadamente, 68.32% da energia total do NnA e apresentou uma correlação de 86%. Esses valores estão de acordo com o verificado no estudo de Melo (2017), que encontrou 66% da energia da MM no NnA, evidenciando a predominância da MM sobre as demais bandas, principalmente em altas latitudes. Entretanto, as outras duas sub-bandas definidas por Melo (2017), apesar de apresentarem menor energia (31,68% do NnA), não podem ser desprezadas em previsões do nível do mar (NM).

O nível do mar na estação da Ilha Fiscal exhibe flutuações significativas, variando de 113 cm a -120 cm. A partir da aplicação da técnica descrita, a série de alturas de MM oscilou entre 44 cm e - 53 cm. A Figura 21 apresenta a série temporal da MM após aplicação do filtro citado.

Figura 21 - Série temporal do nível não-astronômico e da maré meteorológica



Fonte: A autora, 2025.

6.1.3. Variáveis de entrada para a previsão da maré meteorológica com a rede LSTM

Para a previsão da MM, a seleção das variáveis de entrada foi inicialmente orientada por fundamentos físicos e pela aplicação de análises estatísticas, como correlação cruzada e correlação de Pearson. Em seguida, diferentes conjuntos de variáveis identificados como promissores foram submetidos a testes preliminares durante a fase de busca de hiperparâmetros, de modo a comparar o desempenho obtido e apoiar a definição final das variáveis de entrada.

Na geração da MM, os principais mecanismos de forçamentos reconhecido são, do ponto de vista físico, o vento e a pressão atmosférica. O vento exerce uma força de cisalhamento sobre a superfície da água, gerando deslocamento horizontal da massa líquida e contribuindo para variações locais e regionais do nível do mar. Já a pressão atmosférica atua diretamente sobre a coluna de água, causando variações do nível pelo efeito conhecido como BI (a cada aumento de 1mbar, o nível do mar tende a diminuir localmente 1 cm).

Como o vento pode variar significativamente em escalas espaciais, a utilização de múltiplos pontos permite representar de forma mais precisa a estrutura espacial do vento que afeta localmente a MM. Estudos citados anteriormente, indicam que esse fenômeno é frequentemente induzido por ventos persistentes de origem remota, principalmente do quadrante sul em relação à área analisada. Esses ventos atuam sobre grandes extensões

oceânicas, gerando oscilações de baixa frequência que impactam a dinâmica costeira. Considerando essa influência, foram selecionados três pontos ao sul da BG afim de captar adequadamente esses efeitos do vento.

Por outro lado, a pressão atmosférica, por ser um campo geralmente mais homogêneo em escala regional e ter menor variabilidade espacial do que o vento, pode ser representada adequadamente por um único ponto próximo à região de estudo. Assim, a pressão no ponto mais próximo da BG é utilizada como referência para capturar o efeito do barômetro invertido.

Foi realizada uma análise de correlação cruzada entre as variáveis consideradas significativas, com o objetivo de identificar a defasagem temporal em que cada uma apresenta maior correlação com a MM. Em seguida, aplicou-se a correlação de Pearson para quantificar o grau de influência dessas variáveis na previsão. As variáveis analisadas foram: PANMM no ponto P1; componentes u e v do vento nos pontos P2, P3 e P4; e as tensões de cisalhamento do vento na superfície do mar, T_x e T_y , nos mesmos pontos. Essa seleção buscou representar tanto os efeitos locais quanto os remotos sobre a MM, considerando diferentes defasagens temporais. As Figuras 22 e 23 apresentam os resultados das correlações entre as variáveis meteorológicas e a MM, considerando suas respectivas defasagens temporais.

As tensões de cisalhamento do vento foram calculadas a partir das Equações 7.1 e 7.2, conforme Kutsuwada (1998).

$$T_x = \rho_{ar} \times C_D |W| \times u \quad (7.1)$$


$$T_y = \rho_{ar} \times C_D |W| \times v \quad (7.2)$$

Onde: ρ_{ar} = densidade do ar ($1,22\text{kg/m}^3$); W = velocidade do vento em m/s; e C_D = coeficiente de arrasto.

O C_D foi obtido pela equação 7.3, descrita em Large & Yeager (2004):

$$C_D = 10^{-3} \left(\frac{2,7}{W} + 0,142 + \frac{W}{13,09} \right) \quad (7.3)$$

Figura 22 - Mapa de correlação de Pearson entre a MM e as variáveis meteorológicas selecionadas (pressão atmosférica no ponto P1 e componentes u e v do vento nos pontos P2, P3 e P4), considerando as respectivas defasagens temporais.



Legenda: MM: maré meteorológica; P(-30h)_P1: Pressão ao nível médio do mar 30 horas anteriores; U(-13h)_P2: Componente U do vento 30 horas anteriores; V(-13h)_P2: Componente V do vento 13 horas anteriores; U(-39h)_P3: Componente U do vento 39 horas anteriores; V(-22h)_P3: Componente V do vento 22 horas anteriores; U(-47h)_P4: Componente U do vento 47 horas anteriores; V(-34h)_P4: Componente V do vento 34 horas anteriores.

Fonte: A autora, 2025.

Figura 23 - Mapa de correlação de Pearson entre a MM e as variáveis meteorológicas selecionadas (pressão atmosférica no ponto P1 e tensões do vento Tx e Ty nos pontos P2, P3 e P4), considerando as respectivas defasagens temporais.



Legenda: MM - maré meteorológica; P(-30h)_P1: Pressão ao nível médio do mar 30 horas anteriores; Tensão zonal do vento 28 horas anteriores; Ty(-15h)_P2: Tensão meridional do vento 14 horas anteriores; Tx(-35h)_P3: Tensão zonal do vento 35 horas anteriores; Ty(-23h)_P3: Tensão meridional do vento 23 horas anteriores; Tx(-45h)_P4: Tensão zonal do vento 45 horas anteriores; Ty(-35h)_P4: Tensão meridional do vento 35 horas anteriores.

Fonte: A autora, 2025.

A partir da Figura 22, observa-se que a maior correlação da componente v ocorreu no P4, enquanto a da componente u foi registrada no P2. De modo geral, as maiores correlações nos dois mapas foram associadas às componentes u e v do vento, embora as diferenças em relação às tensões de cisalhamento tenham sido pequenas. As correlações mais expressivas estiveram ligadas às componentes meridionais, evidenciando que a direção norte-sul do vento exerce uma influência significativa sobre a MM na região. Esse padrão também foi identificado por Parise *et al* (2009), Siqueira *et al* (2021) e Vedana *et al* (2021), que identificaram maior impacto do vento meridional nas oscilações do NM ao longo da costa sul e sudeste do Brasil.

Esse comportamento sugere a formação de pistas de vento ao longo desse eixo, favorecendo o acúmulo de água na região costeira. Tal padrão é consistente com o regime atmosférico predominante no sudeste do Brasil, sobretudo durante a atuação de sistemas frontais e ciclones extratropicais que se deslocam de sul para norte, geralmente originados em

regiões polares e nas zonas de ciclogênese ao sul da América do Sul (Cavalcanti & Kousky, 2009; Campos *et al.*, 2010; Reboita *et al.*, 2010).

Na Figura 23, a maior correlação no P4 pode estar associada à intensidade dos ventos, uma vez que a tensão de cisalhamento depende do quadrado da velocidade do vento. Em regiões com ventos mais intensos — especialmente durante a passagem de frentes frias — tendem a transferir mais energia para a superfície oceânica, contribuindo para o forçamento da MM.

Com base na análise de correlação, foram identificadas associações relevantes entre variáveis meteorológicas e a MM. No entanto, além da análise estatística, considerou-se também a relevância física das variáveis na geração da MM. As tensões T_x e T_y embora apresentem correlações numéricas ligeiramente inferiores, representam diretamente o esforço do vento sobre a superfície do mar. Esse esforço é responsável por transferir momento para a camada superficial do oceano, favorecendo a geração de oscilações no nível do mar.

Dessa forma, foram conduzidos experimentos preliminares durante a fase de busca por hiperparâmetros, testando diferentes combinações de variáveis de entrada — incluindo as componentes u e v do vento e suas respectivas tensões T_x e T_y , provenientes de três pontos distintos — além da PANMM do ponto P1, mantida fixa em todos os testes. O objetivo foi avaliar, de forma comparativa, o desempenho de cada conjunto na previsão da MM, levando em conta tanto sua representatividade física quanto sua capacidade preditiva. A avaliação foi realizada com base em métricas como o RMSE, bias, r e SI, calculadas para os conjuntos de treinamento, validação e teste.

Nos testes iniciais, foram avaliadas diferentes combinações de variáveis de entrada provenientes de pontos meteorológicos ao longo da costa. Inicialmente, foi utilizado apenas um ponto de vento mais próximo à região de interesse. Em seguida, com a adição de um segundo ponto, localizado mais ao sul, observou-se uma melhora nas métricas estatísticas do modelo. Por fim, a inclusão de um terceiro ponto ainda mais ao sul, na altura de Rio Grande – RS, resultou em um desempenho ainda mais expressivo. Esse comportamento indicou que a variabilidade espacial do campo de vento ao longo da costa exerce influência significativa na previsão da MM.

6.1.4 Análise comparativa das variáveis de entrada na previsão da maré meteorológica: U e V vs Tx e Ty

A Tabela 9 apresenta os resultados dos testes realizados com diferentes conjuntos de variáveis de entrada, utilizando diversas configurações de hiperparâmetros, como janela temporal, tamanho do batch, número de épocas, número máximo de tentativas, função de ativação e taxa de aprendizado.

O objetivo desses testes iniciais foi comparar, de forma exploratória, o desempenho dos modelos ao utilizar as componentes do vento em relação às tensões de cisalhamento na previsão da MM, incluindo em ambos os casos a PANMM.

Tabela 8 - Resultados da comparação entre diferentes conjuntos de variáveis de entrada.

Resultados				
Testes	Variáveis Entrada	Treino	Validação	Teste
1	Tx, Ty (2,3,4); P(1)	r: 0.8522 RMSE: 5.9916 Bias: -0.2599 SI: 0.5234	r: 0.8588 RMSE: 6.7514 Bias: -0.0639 SI: 0.5234	r: 0.7663 RMSE: 7.0770 Bias: -0.4289 SI: 0.6658
2	U, V (2,3,4); P(1)	r: 0.8130 RMSE: 6.6742 Bias: -0.2846 SI: 0.5831	r: 0.8519 RMSE: 6.9090 Bias: -0.2042 SI: 0.5246	r: 0.7996 RMSE: 6.4387 Bias: -0.1159 SI: 0.6068
3	U, V (2,3,4); P(1)	r: 0.8105 RMSE: 6.7083 Bias: -0.1810 SI: 0.5864	r: 0.8500 RMSE: 6.9571 Bias: -0.1306 SI: 0.5284	r: 0.8066 RMSE: 6.3167 Bias: 0.0695 SI: 0.5953
4	Tx, Ty (2,3,4); P(1)	r: 0.8322 RMSE: 6.3741 Bias: 0.2219 SI: 0.5570	r: 0.8554 RMSE: 6.8269 Bias: 0.3039 SI: 0.5181	r: 0.7832 RMSE: 6.7415 Bias: 0.3679 SI: 0.6344
5	U, V (2,3,4); P(1)	r: 0.8416 RMSE: 6.4303 Bias: -0.9243 SI: 0.5438	r: 0.8398 RMSE: 6.4619 Bias: -1.1682 SI: 0.5440	r: 0.8495 RMSE: 6.4413 Bias: -1.3395 SI: 0.5300
6	Tx, Ty (2,3,4); P(1)	r: 0.8428 RMSE: 6.4147 Bias: 1.2135 SI: 0.5383	r: 0.8357 RMSE: 6.5207 Bias: 1.0574 SI: 0.5508	r: 0.8354 RMSE: 6.5970 Bias: 0.9110 SI: 0.5496

Fonte: A autora, 2025.

De forma geral, os modelos com entrada baseada nas componentes do vento demonstraram desempenho competitivo e, em alguns casos, superior ao das tensões. O Teste 5, por exemplo, apresentou o melhor desempenho entre todos os testes, com $r = 0,8495$ no conjunto de teste, $RMSE = 6.4413$ e SI de 0.5300 . Em comparação, o Teste 6, que utilizou as tensões com a mesma configuração, obteve $r = 0.8354$, $RMSE = 6.5970$ e $SI = 0.5496$, valores levemente inferiores aos obtidos com u e v .

Nos demais experimentos, o comportamento manteve-se semelhante. Tanto o Teste 1 quanto o Teste 2, por exemplo, conduzidos com a mesma configuração, indicaram desempenho superior ao utilizar as componentes em comparação às tensões, com resultados no conjunto de teste de $r = 0,7996$ vs. $0,7663$, $RMSE = 6,4387$ vs. $7,0770$ e $SI = 0,6068$ vs. $0,6658$. Apesar disso, o desempenho obtido com as tensões também foi satisfatório, apresentando valores relativamente próximos em termos de correlação e erro.

Fisicamente, as tensões de cisalhamento do vento representam a força exercida pela atmosfera sobre a superfície do oceano, estando diretamente relacionadas ao transporte de massa e energia entre os dois sistemas. Dessa forma, a inclusão das tensões se justifica como uma forma de captar mais diretamente o efeito dinâmico do vento na MM. No entanto, como essas tensões são derivadas das componentes u e v por meio de equações empíricas, sua utilização pode introduzir incertezas adicionais ou gerar redundância de informação quando empregadas em conjunto com as próprias componentes como variáveis de entrada no modelo.

Além dos bons resultados obtidos com as componentes do vento, a escolha por utilizá-las como variáveis de entrada se deu também a aspectos práticos. As componentes são variáveis brutas, amplamente disponíveis em bases meteorológicas operacionais, o que favorece a reprodutibilidade do experimento e a aplicação do modelo em tempo real. Em contrapartida, as tensões de cisalhamento exigem parametrizações adicionais e o uso de equações empíricas para serem calculadas, o que eleva a complexidade do pré-processamento e pode limitar sua aplicabilidade operacional. Dessa forma, a utilização de u e v torna o modelo mais direto, simples e adaptável a diferentes fontes de dados meteorológicos.

6.2. Previsão da maré meteorológica com a rede LSTM

6.2.1 Melhores hiperparâmetros

A seleção dos melhores hiperparâmetros da rede LSTM foi realizada por meio do método *Random Search*, utilizando a biblioteca *Keras Tuner*. Foram definidos intervalos de busca para os principais hiperparâmetros da arquitetura da rede, conforme apresentado na Tabela 9, e o treinamento foi conduzido utilizando o otimizador Adam. A arquitetura de rede proposta é composta por dois tipos de camadas: a camada LSTM e a camada densa totalmente conectada. A camada LSTM é utilizada para modelar a relação da série temporal. A camada totalmente conectada é utilizada para mapear a saída da camada LSTM para uma previsão final.

A busca foi configurada com múltiplas tentativas, e cada conjunto de hiperparâmetros foi avaliado mais de uma vez para reduzir o impacto de variações aleatórias na inicialização dos pesos e no treinamento. Cada execução foi treinada por até 100 épocas — ou seja, o modelo pôde percorrer todo o conjunto de dados até 100 vezes —, com *EarlyStopping* aplicado para prevenir *overfitting* e *ReduceLRonPlateau* para ajustar dinamicamente a taxa de aprendizado. Diferentes valores de *batch_size* também foram testados durante a otimização.

Os hiperparâmetros que resultaram no melhor desempenho estão apresentados na Tabela 10.

Tabela 9 – Melhores Hiperparâmetros obtidos na otimização com *Random Search*.

Hiperparâmetro	Valor Selecionado
Unidades de Entrada	160
Número de camadas	2
Unidades por camada oculta	32
Função de ativação	Linear
Taxa de <i>Dropout</i>	0.2
<i>Batch Size</i>	32

Fonte: A autora, 2025.

6.2.2 Previsão com a rede LSTM

Após a definição dos melhores hiperparâmetros por meio do *Random Search*, o modelo LSTM foi treinado e avaliado nos conjuntos de treinamento, validação e teste (Tabela 11). Devido ao caráter estocástico da rede LSTM, que envolve inicialização aleatória de pesos e embaralhamento dos dados, o treinamento foi executado 30 vezes. Com isso, busca-se avaliar o modelo de forma mais robusta, considerando a variabilidade inerente ao processo de aprendizado (Brownlee, 2019). O resultado das métricas estatísticas apresentadas na Tabela 11 correspondem à média dessas 30 execuções. Estratégia semelhante foi adotada por Ishida *et al* (2020), Wang *et al* (2021) e Marangoni (2021) para garantir estabilidade nos resultados.

O desempenho preditivo da rede foi analisado por meio das métricas estatísticas, considerando a série da MM real e prevista. De modo geral, os resultados indicaram boa capacidade de aprendizado no treinamento e generalização satisfatória nos dados de teste, embora com variações na precisão conforme o período analisado.

Tabela 10 - Desempenho do modelo LSTM nas etapas de treino, validação e teste.

Etapas	r	RMSE (cm)	Bias (cm)	SI
Treino	0,8583	6,0175	-0,2074	0,6603
Validação	0,8464	6,2614	-0,0231	0,6693
Teste	0,8381	6,5053	-0,1214	0,6924

Fonte: A autora, 2025.

Os coeficientes de correlação, variando de $\sim 0,86$ a $0,84$ ao longo das etapas de avaliação, indicam uma forte associação linear positiva, evidenciando a capacidade da rede LSTM em identificar e reproduzir os padrões da MM. O RMSE, entre 6 cm e 6,5 cm, aponta para um nível de precisão satisfatório nas previsões. O bias, inferior a 1 cm, revela ausência de erro sistemático relevante, embora os valores ligeiramente negativos (entre -0,21 cm e -0,02 cm) indiquem uma discreta tendência à subestimação por parte do modelo. Por fim, o SI, variando entre 0,66 e 0,7, reflete um nível moderado de variabilidade nas estimativas, o que pode ser compatível com a complexidade e a natureza não-linear dos processos envolvidos.


A análise dos resultados obtidos com o modelo LSTM evidencia uma forte correlação entre as variáveis meteorológicas de entrada e a MM prevista. Durante a etapa de validação — em que o modelo é exposto a dados não utilizados no treinamento — o desempenho

permaneceu elevado, com $r \sim 0,85$. Esses resultados indicam que o modelo foi capaz de reconhecer e replicar padrões relevantes, mesmo diante de informações inéditas. A consistência dos coeficientes de correlação entre as diferentes fases sugere que a rede neural não apenas aprendeu as relações presentes nos dados de treino, mas também generalizou bem para novos cenários, sem apresentar indícios de sobreajuste.

Na fase final de teste, composto por dados totalmente independentes do treinamento e da validação, observou-se uma leve redução no coeficiente de correlação, que atingiu $\sim 0,84$. Essa pequena diminuição pode ser atribuída a fatores como a variabilidade intrínseca dos eventos de MM e a complexidade envolvida na representação de todos os processos que influenciam sua dinâmica. Apesar disso, esse coeficiente ainda denota uma forte correlação linear positiva entre os valores previstos pela rede e os observados no conjunto de teste. De modo geral, a consistência dos elevados coeficientes de correlação nas etapas de validação e teste reforça a robustez do modelo e sua capacidade de generalização.

A Figura 24 apresenta os resultados da previsão da MM para a EMIF. Observa-se que o modelo consegue reproduzir de forma satisfatória o comportamento observado, a partir das informações de vento e pressão atmosférica das horas anteriores. Embora apresente boa capacidade de representação geral, alguns eventos tendem a ser subestimados. Ainda assim, o desempenho do modelo permanece expressivo.

Figura 24 - Comparação entre a maré meteorológica observada e a prevista pela rede LSTM para o ano de 2020.




Fonte: A autora, 2025.

Para a avaliação final do modelo, a MM prevista pela rede neural foi somada à MA obtida por meio da previsão harmônica, resultando na estimativa do NM total previsto. Essa

série composta foi então comparada com os dados observados, que refletem naturalmente a combinação entre a componente astronômica e a componente não-astronômica do NM. Nesse contexto, a MM prevista representa a estimativa do NnA.

A Figura 25 mostra que o NM previsto reproduz de forma satisfatória o sinal observado ao longo do tempo. A correlação de $\sim 0,97$ e o RMSE de ~ 8 cm indicam que a MM estimada pela rede LSTM contribuiu de forma consistente para a reconstrução do sinal total, capturando variações importantes da banda não-astronômica. Considerando apenas a MA, a correlação é de $\sim 0,90$ e o RMSE de ~ 14 cm, evidenciando que a inclusão da MM reduz significativamente o erro e aumenta a precisão da previsão.

Figura 25 - Comparação do nível do mar observado com a Maré astronômica prevista (a) e com a previsão incluindo a maré meteorológica (b) para o ano de 2020.

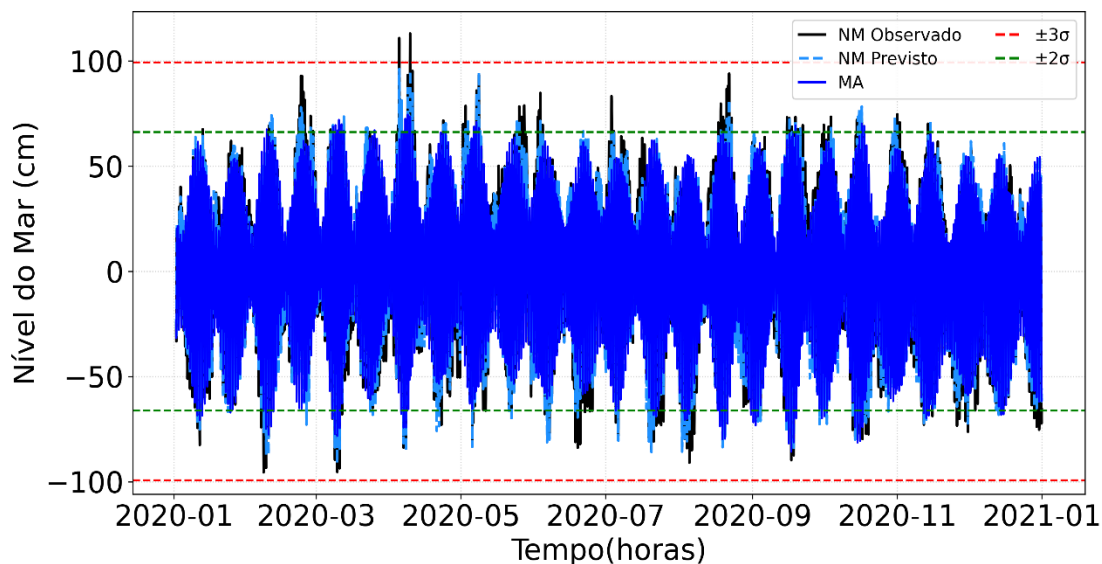


Fonte: A autora, 2025.

A Figura 26 apresenta a variação do NM observado, a MA e o NM previsto ao longo de 2020, destacando os valores extremos associados aos limites de ± 2 DP e ± 3 DP. A análise dos eventos que ultrapassaram ± 2 DP revelou uma quase equivalência entre picos positivos e negativos, com 161 e 163 registros, respectivamente. Por outro lado, acima de ± 3 DP foram observadas apenas ocorrências de picos positivos, embora alguns valores negativos tenham se aproximado do limite inferior. Esses resultados indicam uma alternância entre eventos

extremos positivos e negativos, com ligeira predominância dos positivos em 3 DP durante o período analisado.

Figura 26 - Séries temporais do nível do mar observado, da Maré astronômica prevista e do nível do mar previsto, incluindo os limites de $\pm 2DP$ ($\pm 66,18$ cm) e $\pm 3DP$ ($\pm 99,27$ cm).



Fonte: A autora, 2025.

Foi realizada uma análise detalhada dos dois principais eventos extremos identificados no período — um positivo e outro negativo. O evento positivo ocorreu em 9 de abril de 2020, quando o NM atingiu 113 cm, enquanto a MA registrou 73 cm e o NM previsto 95 cm. Nesse mesmo evento, a maré meteorológica observada foi de 35 cm, e o valor previsto pela rede neural alcançou 22 cm.

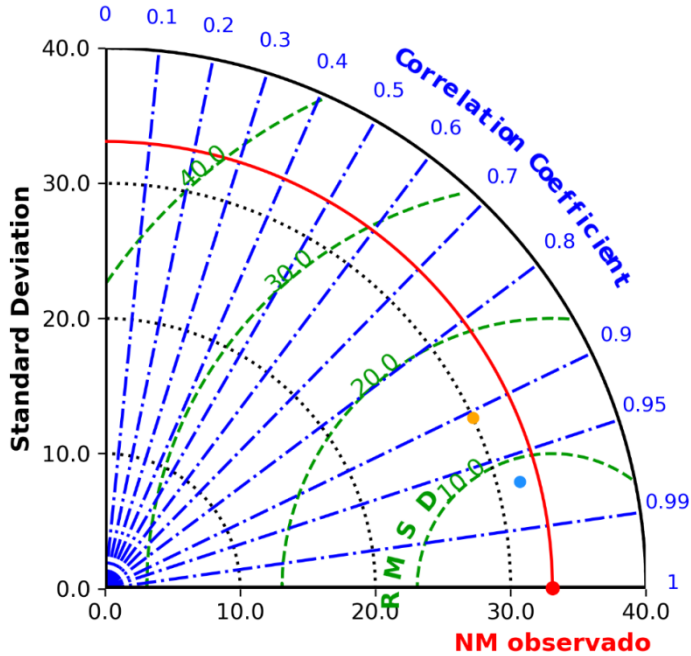
O evento negativo, por sua vez, ocorreu em 7 de fevereiro de 2020, quando o NM chegou a -95 cm, a MA apresentou -66 cm, e o nível previsto -76 cm. Nessa ocasião, a MM observada foi de -21 cm, enquanto o modelo previu -11 cm.

Esses resultados demonstram que o modelo foi capaz de reproduzir adequadamente a tendência e a direção dos eventos extremos, embora subestime parcialmente suas amplitudes, especialmente durante as condições mais intensas. Ainda assim, a coerência entre os sinais observados e previstos evidencia a capacidade da rede neural em capturar a resposta da MM e, conseqüentemente do NM, a forçantes meteorológicas na área de estudo.

O Diagrama de Taylor (Figura 27) mostra que a previsão obtida pelo modelo LSTM (círculo azul) apresenta coeficiente de correlação de 0,97 e Raiz do desvio Quadrático Médio (RMSD) menor que 10 cm em relação ao nível observado, superando a previsão tradicional utilizada. Observa-se também que o desvio-padrão do nível previsto pelo modelo é muito

próximo ao do nível observado, indicando que a variabilidade temporal foi reproduzida adequadamente, sem superestimar ou suavizar excessivamente as oscilações.

Figura 27 - Diagrama de Taylor do nível do mar observado (vermelho), Maré astronômica (laranja) e nível do mar previsto (azul).



Fonte: A autora, 2025.

Esses resultados demonstram que, embora a MA represente a parcela predominante da variabilidade do NM, os efeitos meteorológicos exercem influência significativa. Além disso, reforçam o papel da MM como componente relevante da variabilidade de baixa frequência do NM. O modelo apresenta apenas uma leve tendência à subestimação, porém com diferenças menores considerando apenas a MA. Dessa modo, a inclusão da MM aprimora a reconstrução do sinal total e se mostra essencial para aplicações que demandam maior compreensão dos impactos do NM em regiões costeiras.

7 DISCUSSÃO

As componentes u e v do vento possuem a capacidade de representar padrões de circulação oceânica e os movimentos associados ao transporte de Ekman, diretamente influenciados pela tensão do vento. A PANMM foi incluída devido ao efeito do BI. Além de o mapa de correlação indicar maiores associações entre o vento e a MM, nos experimentos em que a pressão foi removida dos dados de entrada os resultados permaneceram razoáveis, com apenas uma leve redução na performance, sugerindo que sua presença é benéfica, mas não essencial. Em contraste, a retirada das componentes e/ou derivadas do vento resultou em queda expressiva na qualidade da previsão, evidenciando seu papel dominante na modelagem do fenômeno. Esse resultado está em consonância com Gill & Schumann (1974) e Truccolo *et al* (2021), que apontam que, em regiões costeiras, o efeito da tensão do vento sobre as variações do NM é de uma a duas ordens de magnitude maior que o efeito da pressão atmosférica. Ainda assim, a inclusão do efeito do BI se mostrou válida para a previsão da MM na área de estudo.

A análise dos experimentos comparativos, nos quais o modelo foi treinado com diferentes combinações de pontos meteorológicos ao longo da costa, mostrou que a ampliação da cobertura espacial das variáveis de entrada resultou em ganhos progressivos de desempenho. A inclusão de pontos situados mais ao sul, especialmente o localizado na altura de Rio Grande (RS), promoveu melhorias significativas nas métricas estatísticas. Esse comportamento reflete a formação de pistas de vento ao longo desse eixo costeiro, favorecendo o acúmulo de água junto à costa e contribuindo para as variações da MM na Baía de Guanabara. Tal padrão está em consonância com o regime atmosférico predominante no sudeste do Brasil, caracterizado pela atuação recorrente de sistemas frontais e ciclones extratropicais que se deslocam de sul para norte, geralmente originados em regiões polares e em zonas de ciclogênese ao sul da América do Sul (Gill & Schumann, 1974; Cavalcanti & Kousky, 2009; Campos *et al.*, 2010; Reboita *et al.*, 2010).

De modo semelhante, Tecchio *et al* (2024) observaram que os eventos extremos do NM estão fortemente associados à progressão temporal, persistência e intensidade dos ventos de nordeste (NE) — relacionados ao rebaixamento do NM — e de sudoeste (SW) — associados à sobre-elevação do NM — ao longo de toda a costa Sul-Sudeste do Brasil, destacando a importância da pista de vento na geração das anomalias costeiras. Os autores também analisaram as ocorrências de eventos que ultrapassaram os limites de ± 2 DP e ± 3 DP,

verificando um maior número de extremos positivos em ± 2 DP e de negativos em ± 3 DP na BG, a partir de uma série de 31 anos de dados. No presente estudo, considerando apenas o ano de 2020, houve uma leve predominância de extremos negativos em ± 2 DP e de positivos em ± 3 DP. Essa diferença pode estar relacionada à variabilidade interanual das condições atmosféricas, especialmente à frequência e intensidade de eventos meteorológicos e climáticos, que modulam a resposta do NM na região.

Os ventos provenientes de latitudes mais ao sul, associados a sistemas atmosféricos sinóticos, constituem o principal mecanismo de forçamento das ondas subinerciais que se propagam ao longo da PCSE (Stech & Lorenzetti, 1992; Castro & Lee, 1995; Dottori & Castro, 2009; Dottori & Castro, 2018). Em consonância com esse mecanismo, Filippo *et al* (2012) identificaram elevada energia e forte coerência em períodos entre 3,5 e 28 dias, a partir de registros de altura da superfície do mar obtidos durante um ano em quatro estações costeiras situadas entre 43°S e 22°S. Melo (2017) observou a semelhança da MM, filtrada no intervalo de 3 a 30 dias, com dados de NM coletados ao longo de um ano em cinco pontos distribuídos ao longo da costa da América do Sul, situadas entre 47°S e 22°S. Esses achados reforçam a importância de considerar forçantes atmosféricas distribuídas espacialmente ao longo da costa em modelos de previsão, especialmente em áreas onde esses fenômenos modulam significativamente a variabilidade do NM. No local de estudo, a propagação dessas ondas pode atuar modulando a magnitude e a fase das respostas locais, reforçando ou enfraquecendo os processos locais atuantes.

Estudos anteriores demonstram que redes LSTM apresentam excelente desempenho na previsão do NM em diversas regiões e condições, mostrando sua versatilidade como ferramenta de modelagem de fenômenos oceanográficos, atmosféricos e astronômicos. Balogun & Adebisi (2021) utilizaram dados mensais de variáveis oceânicas e atmosféricas ao longo de 26 anos de sete Estações Maregráficas na costa oeste da Malásia para prever o NM e obtiveram entre 0,56 e 0,9 ao usar conjuntos de variáveis atmosféricas, oceânicas e ambas combinadas com rede LSTM. Os autores utilizaram as mesmas variáveis consideradas neste estudo, acrescentando a temperatura do ar, cobertura de nuvens e taxa de evaporação. Ao usarem apenas as variáveis meteorológicas, obtiveram correlações entre 0,75 e 0,87. Os resultados não são uniformes em todas as Estações, estando diretamente relacionados aos processos físicos predominantes que controlam a variabilidade do NM em cada local.

De forma similar, Wang *et al* (2021) mostraram que a LSTM, aplicada à previsão do *Surge Level* — neste trabalho denominado NnA — no norte da Ilha de Hainan (China) utilizando quatro modelos individuais e duas combinações, com horizonte de previsão de 1 a

6 horas e 11 anos de dados, alcançou correlações entre 0,71 e 0,96 e RMSE de 3,6 a 8,9 cm, demonstrando capacidade de lidar com eventos extremos, como tufões, quando combinada com outras arquiteturas de redes neurais (CNN-LSTM e LSTM-CNN). Foi utilizando as componentes zonal e meridional do vento em superfície e dados do SL em tempos anteriores.

Ishida *et al* (2020) evidenciaram a capacidade da LSTM em aprender tendências interanuais e de longo prazo, aprimorando a previsão do NM ao incluir variáveis complementares, como a temperatura média global anual. Os autores desenvolveram um modelo LSTM para estimativa do NM em Osaka (Japão), utilizando 38 anos de dados e variáveis atmosféricas com entradas. Além das variáveis consideradas neste estudo, incorporaram a temperatura do ar e parâmetros astronômicos (azimute e altitude do Sol e da Lua), bem como a temperatura média global anual.

Localmente, Kaufmann (2024) aplicou redes LSTM à previsão da maré meteorológica na região de Macaé (RJ), obtendo resultados robustos ($r = 0,96$; RMSE = 3 cm; SI = 0,22) a partir de uma série temporal de 10 anos. O principal objetivo da autora foi avaliar os impactos das mudanças climáticas nas estimativas de eventos extremos da maré meteorológica na área do Porto de Imbetiba. Para isso, desenvolveu preliminarmente um modelo LSTM para prever o fenômeno, utilizando 10 anos de dados e 11 variáveis meteoceanográficas. A separação dessa componente foi realizada por meio de um filtro passa-baixa com frequência de corte de 72 horas. Enquanto Kaufmann buscou reproduzir a componente não-astronômica do NM, neste trabalho o foco recaiu especificamente sobre a maré meteorológica, obtida por filtragem em banda.

Em relação aos impactos das mudanças climáticas, os resultados indicaram que os episódios extremos desse fenômeno tendem a aumentar nas projeções de longo prazo, com variações entre tipo de modelos climáticos e redes neurais. A LSTM mostrou-se eficaz em capturar o comportamento sazonal da MM e projetou um aumento mais expressivo de eventos extremos (70%) em relação à MLP (28%) para 2006–2060, evidenciando seu potencial para cenários de mudanças climáticas, mas também indicando tendência à superestimação.

Neste trabalho, a correlação obtida foi de aproximadamente 0,97 para o NM previsto (MA + MM) e de 0,84 para a previsão da MM por meio da rede LSTM. A abordagem concentrou-se na previsão da sub-banda meteorológica, utilizando como entradas apenas as componentes zonal e meridional do vento e a pressão atmosférica em quatro pontos ao longo da costa. Diferentemente dos estudos anteriores, que empregaram séries históricas mais longas e conjuntos de entrada mais diversificados, este estudo baseou-se em um banco de

dados mais curto e enxuto, sem a incorporação de variáveis astronômicas, oceanográficas ou globais.

Ainda assim, o modelo proposto apresentou desempenho expressivo, alcançando resultados comparáveis aos obtidos nos trabalhos anteriores, o que reforça a eficácia da abordagem adotada. É importante destacar, contudo, que há diferenças relevantes nas arquiteturas das redes e nos hiperparâmetros utilizados em cada estudo. Além disso, a variabilidade intrínseca de cada conjunto de dados também influencia o desempenho dos modelos, especialmente considerando que as condições meteoceanográficas variam entre as regiões analisadas.

Contudo, assim como observado em outros estudos que empregaram exclusivamente uma única arquitetura de rede, este trabalho também apresentou tendência à subestimação dos valores mais energéticos, sobretudo durante eventos de maior intensidade. Ishida *et al* (2020), por exemplo, relataram que, durante a passagem de um tufão, a rede LSTM estimou um NM de 487 cm, enquanto o observado foi de 574 cm. No presente estudo, considerando o período mais energético da série — um evento de ressaca (Zee, 2020) —, o nível observado atingiu aproximadamente 111 cm, ao passo que o previsto pelo modelo foi de cerca de 95 cm. Já a previsão baseada apenas na MA indicou cerca de 62 cm. Esses resultados reforçam a importância de incorporar as forçantes que representam as componentes não-astronômicas na previsão do NM, bem como de reconhecer o desafio associado à previsão de eventos extremos, os quais possuem grande relevância para aplicações operacionais. Nesse contexto, Wang *et al* (2021) demonstraram que a combinação de modelos — especificamente CNN e LSTM — proporcionou ganhos de 4% a 6% em relação ao uso isolado de cada uma, especialmente na previsão de extremos positivos e negativos. Durante dois tufões severos, a precisão das previsões aumentou em mais de 10% em todos os horizontes de previsão, evidenciando o potencial das abordagens híbridas para melhor capturar eventos mais energéticos.

Outro aspecto relevante refere-se aos eventos climáticos significativos, como *El Niño* e *La Niña*. No estudo de Machado *et al* (2019), observou-se que o *El Niño* classificado como muito forte pelo NOAA, ocorrido entre 2015 e 2016, impactou significativamente as condições atmosféricas no Sul e Sudeste do Brasil, favorecendo maior instabilidade, aumento na frequência de frentes frias e formação de ciclones extratropicais. Esses sistemas contribuíram para a ocorrência de ressacas, especialmente no litoral dessas regiões. Apesar desses efeitos, a distribuição sazonal dos eventos extremos manteve seu padrão típico – com maior número de ressacas nos meses de outono e inverno (Cavalcanti & Kousky, 2009;

Campos *et al.*, 2010). Já Marinho *et al* (2024) observaram uma diminuição na frequência de ciclones extratropicais e de sistemas frontais intensos durante o período de *La Niña*, em comparação ao *El Niño*, nas mesmas regiões.

8 CONCLUSÕES

Esta dissertação apresentou uma abordagem baseada em uma rede neural LSTM para a previsão da maré meteorológica na Baía de Guanabara, utilizando dados de nível do mar da Estação Maregráfica da Ilha Fiscal. A partir da decomposição do NM e da filtragem da componente não-astronômica na banda de 3,1 a 31,5 dias, foi possível isolar a MM. Ao combinar a previsão da MM obtida pela rede LSTM com a previsão da Maré astronômica, estimou-se o nível do mar observado. Em síntese, os resultados obtidos contribuem para aprimorar a precisão das previsões na região estudada. A rede demonstrou capacidade de capturar dependências de longo prazo, mostrando-se eficaz na modelagem e previsão da MM.

Os testes realizados com diferentes composições de entrada, janelas temporais e estratégias de otimização evidenciaram a sensibilidade do modelo a essas escolhas. Entre as combinações testadas, a que apresentou o melhor desempenho incluiu as componentes u e v do vento nos pontos P2, P3 e P4, juntamente com a PANMM no ponto P1, todas obtidas a partir da reanálise ERA-5. Esses resultados evidenciam que o vento desempenha um papel central na previsão da MM, superando a relevância da PANMM, tradicionalmente associada ao efeito do barômetro invertido. Além disso, indicam que a inclusão das características da pista de vento é fundamental para aprimorar a capacidade preditiva da rede neural e aumentar a precisão do modelo.

Um aspecto importante a ser destacado refere-se ao custo computacional. Enquanto os modelos numéricos tradicionais exigem longos períodos de processamento e o uso de infraestrutura computacional robusta, as redes neurais se destacam pela velocidade de execução e pelo menor consumo de recursos computacionais. Essa característica torna as redes neurais uma alternativa particularmente atraente para aplicações operacionais que demandam rapidez na geração de previsões, sem comprometer a qualidade dos resultados.

Este trabalho alcançou seu objetivo principal ao avaliar o potencial da rede neural LSTM na previsão da maré meteorológica na região da Baía de Guanabara, utilizando variáveis meteorológicas locais e remotas como entradas. Os resultados obtidos ($r = 0,84$; $RMSE = 6,5$ cm) evidenciaram que o modelo foi capaz de reproduzir de forma satisfatória as oscilações não-astronômicas do nível do mar, reduzindo o erro médio em cerca de 43%. A aplicação da LSTM mostrou-se uma ferramenta promissora para representar a variabilidade associada à MM, ressaltando a importância de sua inclusão na previsão do nível do mar observado, especialmente em regiões costeiras influenciadas por múltiplas forçantes

atmosféricas, e reforçando o potencial das técnicas de inteligência artificial no aprimoramento de sistemas operacionais de monitoramento e previsão costeira.

CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

Com este trabalho, espera-se ampliar o conhecimento sobre as variações do nível do mar na banda meteorológica, em especial quanto à dinâmica de causa e efeito, ao tempo de resposta da MM frente à atuação dos ventos e à influência de variáveis meteorológicas relevantes para a previsão. Além disso, busca-se destacar a importância da caracterização e previsão da MM na região, visando subsidiar processos decisórios de órgãos públicos em situações extremas, bem como apoiar autoridades marítimas diante de eventos de rebaixamento do NM, que impactam diretamente a atualização e a segurança das cartas náuticas.

O aumento do horizonte de previsão da MM pode contribuir significativamente para operações portuárias, reduzindo os impactos de eventos mais energéticos de sobre-elevação e rebaixamento, por meio da adoção de medidas preventivas. Da mesma forma, pode ampliar a capacidade de emitir alertas antecipados para as populações costeiras, mitigando os riscos de ressacas, inundações e alagamentos em áreas urbanas vulneráveis. Essa necessidade se torna ainda mais urgente diante das projeções de mudanças climáticas, que indicam a elevação do nível médio do mar (Oppenheimer *et al.*, 2019) e a intensificação dos ciclones extratropicais (Lambert & Fyfe, 2006).

A incorporação de variáveis adicionais e representativas, capazes de refletir fenômenos climáticos significativos, como *El Niño* e *La Niña*, pode contribuir para uma melhor caracterização da sazonalidade, das variações interanuais e da tendência de elevação do Nível Médio do Mar em longo prazo, ampliando o potencial de generalização dos modelos de rede neural (Machado *et al.*, 2019; Ishida *et al.*, 2020; Kaufmann, 2024; Marinho *et al.*, 2024). Essa integração tende a fortalecer a robustez dos modelos, sobretudo em cenários de maior energia. Paralelamente, estudos recentes (Wang *et al.*, 2021) demonstram que arquiteturas híbridas — como a combinação de LSTM com CNN ou o uso de mecanismos de atenção — apresentam desempenho superior na previsão de eventos extremos, tradicionalmente mais desafiadores.

Por fim, o fortalecimento da capacidade das redes neurais em prever eventos extremos requer a ampliação e diversificação dos conjuntos de dados utilizados no treinamento, incorporando séries históricas mais extensas, projeções climáticas de alta resolução, modelos híbridos e produtos de regionalizações climáticas disponíveis (Ishida *et al.*, 2020; Wang, *et al.*, 2021; Kaufmann, 2024). Embora tais estratégias possam ser adaptadas especificamente

para a previsão da MM, é importante destacar que esta representa apenas uma faixa de frequência dentro do NnA. Assim, a análise de todo o sinal do NnA pode fornecer uma perspectiva mais abrangente da variabilidade do NM. Além disso, recomenda-se expandir a aplicação espacial dos modelos para diferentes trechos da costa brasileira, com ênfase no Sul do país, região frequentemente impactada por oscilações não-astronômicas, de modo a avaliar comparativamente seus efeitos e apoiar ações preventivas frente às mudanças climáticas.

REFERÊNCIAS

- BALOGUN, A.L; ADEBISI, N. Sea level prediction using ARIMA, SVR and LSTM neural network: assessing the impact of ensemble Ocean-Atmospheric processes on models' accuracy. *Geomatics, Natural Hazards and Risk*, v.12, p. 653–674, 2021.
<https://doi.org/10.1080/19475705.2021.1887372>
- BORBA, E; Teixeira, G.L; Filippo, A.M. Impactos da Maré meteorológica no Nível do mar para a Baía de Sepetiba – RJ. *Anais Hidrográficos / Diretoria de Hidrografia e Navegação*, T.79, p. 191- 200, 2022.
- BRINK, K.H. Coastal-trapped waves and wind-driven currents over the Continental Shelf. *Annual Review of Fluid Mechanics*, v.23, p. 389–412, 1991.
- BROWN, E. Waves, Tides and Shallow-Water Processes. Oxford, The Open University, Elsevier, 2.ed, 1989.
- BROWNLEE, J. “Embrace Randomness in Machine Learning”. 2019. < [Embrace Randomness in Machine Learning - MachineLearningMastery.com](https://embrace.randomness.in.machine.learning-machinelearningmastery.com)> (acessado em 07 de abril 2024)
- BROWNLEE, J. “How to Check if Time Series Data is Stationary with Python. Machine Learning Mastery”. 2020. <https://machinelearningmastery.com/time-series-data-stationary-python/> (acessado em 22 de novembro 2023)
- BUSHNELL, M; WORTHINGTON, H. Manual for real-time quality control of water level data: a guide to quality control and quality assurance for water level observations. 2021.
- CAMPOS, R.M; CAMARGO, R; HARARI, J. Caracterização de eventos extremos do nível do mar em Santos e sua cor respondência com as reanálises do modelo do NCEP no sudoeste do Atlântico Sul. *Revista Brasileira de Meteorologia*, v.25, n.2, p. 175-184, 2010.
- CASTRO, B.M; Lee, T.N. Wind-forced sea level variability on the southeast Brazilianshelf. *J Geophys Res*, v.100, n.C8,16,045–16,056, 1995.
- CASTRO, M. S; BONECKER, A. C. T; VALENTIN, J. L. Seasonal variation in fish larvae at the entrance of Guanabara Bay, Brazil. *Brazilian archives of biology and technology*, v.48, n.1, p. 121-128, 2005.
- CAVALCANTI, I.F.A.; KOUSKY, V.E. Frentes Frias Sobre o Brasil, In: CAVALCANTI, I.F.A (org.). *Tempo e Clima no Brasil*. São Paulo: Oficina de Textos, E-book, Cap.9: p. 135-147, 2009.
- CHAVES, D. A Pesca Artesanal como movimento de luta e os impactos socioambientais das modernizações industriais na orla da Baía de Guanabara (RJ). *Mares: Revista De Geografia E Etnociências*, v.3, n.2, p. 119-126, 2022.
- CODIGA, D.L. Unified Tidal Analysis and Prediction Using the UTide Matlab Functions. Technical Report 2011-01. Graduate School of Oceanography, University of Rhode Island, Narragansett, RI, pp. 59, 2011.
- COELHO, A.L. Intrusão da ACAS na Região Costeira Adjacente à Baía de Sepetiba. *Anais Hidrográficos / Diretoria de Hidrografia e Navegação*, T.67, p. 109- 116, 2010.
- COELHO, A.L; ALVES, A.R; TEIXEIRA, G.L. O Efeito da Plataforma Continental Sobre a Maré na Costa Leste da América do Sul. *Anais Hidrográficos / Diretoria de Hidrografia e Navegação*, T.72, p. 105 – 113. 2015.

- COELHO, A.; TEIXEIRA, F.; TEIXEIRA, G. Impacto do Processo de Ressurgência Costeira no Nível de Redução: caso Baía de Sepetiba, Congresso Brasileiro de Oceanografia, Salvador, Bahia, 2016.
- COHEN, J. Statistical power analysis for the behavioral sciences. 2. ed, p.579, 1988. ISBN 0-8058-0283-5
- COOGAN, J; DZWONKOWSKI, B; LEHRTER, J. Effects of coastal upwelling and downwelling on hydrographic variability and dissolved oxygen in Mobile Bay. *Journal of Geophysical Research: Oceans*, v.124, p. 791–806, 2019. <https://doi.org/10.1029/2018JC014592>
- DATA SCIENCE ACADEMY. Deep Learning Book, 2022. Disponível em: <https://www.deeplearningbook.com.br/>
- DENNY’S BLOG. Recurrent Neural Networks Tutorial, Part 1 – Introduction to RNNs. 2017. Disponível em: (dennybritz.com)
- DERECZYNSKI, C; VASCONCELLOS, F; KAISER, J; GALLO, M.; MELO, G; SILVEIRA I; DOTTORI, M. Projeto de Caracterização Regional da Bacia de Santos – PCR – BS: Meteorologia e Oceanografia Física da Bacia de Santos. v. 3, rev.02, 2022.
- DOTTORI, M., CASTRO, B.M. The response of the sao paulo continental shelf, Brazil, to synoptic winds. *Ocean Dynam.* 59, 603–614, 2009. <https://doi.org/10.1007/s10236-009-0209-2>
- DOTTORI, M; CASTRO, B.M. The role of remote wind forcing in the subinertial current variability in the central and northern parts of the South Brazil Bight. *Ocean Dynamics*, v.68, p. 677–688, 2018. <https://doi.org/10.1007/s10236-018-1153-9>
- DOTTORI, M; FILHO, B.M.C. Circulação na plataforma continental. In: HARARI, Joseph (org.), *Noções de Oceanografia*, São Paulo: Instituto Oceanográfico. 2021. E-book, Cap. 10: p.227-235. 2021.
- DUTRA, F.R.L.S; CIRANO, M; BITTENCOURT, A.C.S.P; TANAJURA, C.A.S; LIMA, M. Meteorological Tides and Episodes of Severe Coastal Erosion on the Coast of Salvador, Bahia State, Brazil. *Revista Brasileira de Geofísica*, v.32, n.4, 2014. <http://dx.doi.org/10.22564/rbgf.v32i4.551>
- FERNANDES, A.M; PASSOS, E.N; CALIL, P.H.R; MOSER, G.A.O; DE OLIVEIRA, E.N; ESPÍNDOLA, R.P. Temperature stratification in the Guanabara Bay and its relationship with wind-induced coastal upwelling off Cabo Frio, Brazil. *Estuarine, Coastal and Shelf Science*, v. 291, 108433, 2023. <https://doi.org/10.1016/j.ecss.2023.108433>
- FILIPPO, A.M. *Variabilidade do Nível do mar em Função de Eventos Meteorológicos de Baixa Frequência*. 2003. Dissertação (Mestrado em Geociências), Programa de Pós-graduação em Geociências, Universidade Federal Fluminense, Niterói, Brasil, 85p, 2003.
- FILIPPO, A.M; KJERFVE, B; JÚNIOR, A.R.T.; FERNANDES, A.M. Low-Frequency Variability of sea level along the Mid-Atlantic coast of South America, in 1983. *Revista Brasileira de Geofísica*, v.30, n.1. 2012.
- FRANCO, A. S. *Marés: Fundamentos, Análise e Previsão*. 2.ed. DHN: Niterói. 2009.
- FRANÇA, B. R. L. 2013. Ondas Costeiras Confinadas na Plataforma Continental Sul-Sudeste do Brasil. Dissertação (Mestrado), Programa de Pós-Graduação em Engenharia Oceânica, COPPE, Universidade Federal do Rio de Janeiro, RJ, Brasil, 77p, 2013.
- FUCHS, V; TEIXEIRA, G.L.G; NZUALO, T.N.M. Estimation Of Nautical Chart Datum By The Statistical Method In Micro And Meso Tidal Regime: An Alternative To The Balay Harmonic Method. International Hydrographic Organization (IHO). *The International Hydrographic Review*, v.26, 2021.

- GOODFELLOW, I; BENGIO, Y; COURVILLE, A. Sequence Modeling: Recurrent and Recursive Nets. In: *Deep Learning*. Cambridge: MIT Press. 2016. <http://www.deeplearningbook.org/>
- GOODFELLOW, I; BENGIO, Y; COURVILLE, A. Deep Feedforward Networks. In: *Deep Learning*. Cambridge: MIT Press. 2016. <http://www.deeplearningbook.org/>
- GRAVES, A; MOHAMED, A.r; HINTON, G. Speech Recognition with Deep Recurrent Neural Networks. Cornell University, arXiv. 2013. <https://doi.org/10.48550/arXiv.1303.5778>
- GÉRON, A. *Mãos à Obra: Aprendizado de Máquina com Scikit_Learn, Keras & TensorFlow – 2a Edição Atualizada com TensorFlow2: Conceitos, Ferramentas e Técnicas para a Construção de Sistemas Inteligentes*. Traduzido por Cibelle Ravaglia. Rio de Janeiro: Alta Books. 640p. 2021.
- GIAREMIS, S; Nader, N; DAWSON, C; KAISER, C; NIKIDIS, E; KAISER, H. Storm surge modeling in the AI era: Using LSTM-based machine learning for enhancing forecasting accuracy. *Coastal Engineering*, v.19, 2024.
- GILL, A. E; SCHUMANN, E. H. Topographically Induced Changes in Structure of an Inertial Coastal Jet: Application to the Agulhas Current. *Journal of Physical Oceanography*, v.9, p. 975 – 991, 1979.
- GOODFELLOW, I; BENGIO, Y; COURVILLE, A. *Deep Learning*. MIT Press. 2016. Disponível em: deeplearningbook.org. (acessado em 15 de junho de 2023).
- GRANGER, C. W. J. (1969). Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica*, 37(3), 424. doi:10.2307/1912791
- HAYKIN, S. *Redes Neurais: Princípios e Práticas*. 2.ed, Bookman, Porto Alegre, 2021.
- HAYKIN, S. S. *Neural networks and learning machines*. 3.ed. Upper Saddle River, NJ, Pearson Education, 2009.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, Cambridge, MA, USA, v. 9, n. 8, p. 1735–1780, 1997.
- ISHIDA, K; TSUJIMOTO, G; ERCAN, A; TU, T; KIYAMA, M; AMAGASAKI, M. Hourly-scale coastal sea level modeling in a changing climate using long short-term memory neural network. *Science of The Total Environment*, v.720, 2020. <https://doi.org/10.1016/j.scitotenv.2020.137613>
- JORDÃO, M.D.L; OLIVEIRA, L.S; VINZON, S.B. Análise do histórico de inundação da Vila Residencial por Maré meteorológica. In: XXV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, Aracaju-SE, 2023. Disponível em: ABRHidro - ANAIS - Análise do Histórico de Inundação da Vila Residencial por Maré meteorológica.
- KAEMPF, J; CHAPMAN, P. The Functioning of Coastal Upwelling Systems. *Upwelling Systems of The World*. Cap. 2: p.31-65, 2016.
- KANG, E. Long Short-Term Memory (LSTM): Concept. Medium. 2017. <https://medium.com/@kangeugine/long-short-term-memory-lstm-concept-cb3283934359>
- KAUFMANN, C.L.G. *Redes Neurais para Projeção de Longo Prazo e Estimativa de Extremos da Maré meteorológica no Porto de Imbetiba, Macaé – RJ*. 2024. 141p. Tese de Doutorado (Doutor em Engenharia Oceânica), Programa de Pós graduação em Engenharia Oceânica, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro. 2024.
- KIM, S; PAN, S; MASE, H. Artificial neural network-based storm surge forecast model: Practical application to Sakai Minato, Japan. *Applied Ocean Research*, v.91, 101871, 2019. <https://doi.org/10.1016/j.apor.2019.101871>

- KJERFVE, B; Ribeiro, C.H.A; GILBERTO, T.M.D; FILIPPO, A.M; QUARESMA, V.d.S. Oceanographic characteristics of an impacted coastal bay: Baía de Guanahara, Rio de Janeiro, Brazil. *Continental Shelf Research*, v.17, n.13, p. 1609–1643, 1997. [https://doi.org/10.1016/S0278-4343\(97\)00028-9](https://doi.org/10.1016/S0278-4343(97)00028-9)
- KJERFVE, B; DIAS, G.T.M; FILIPPO, A; GERALDES, M.C. Oceanographic and environmental characteristics of a coupled coastal bay system: Baía de Ilha Grande-Baía de Sepetiba, Rio de Janeiro, Brazil. *Regional Studies in Marine Science*, v.41, 101594, 2021. <https://doi.org/10.1016/j.rsma.2020.101594>
- KUTSUWADA, K. Impact of wind/wind-stress field in the North Pacific constructed by ADEOS/NSCAT data. *J. Oceanography*, v.54, p. 443-456, 1998. <https://doi.org/10.1007/BF02742447>
- LAMBERT, S. J; FYFE, J. C. Changes in winter cyclone frequencies and strengths simulated in enhanced greenhouse warming experiments: results from the models participating in the IPCC diagnostic exercise. *Climate Dynamics*, v.26, p. 713–728, 2006. <https://doi.org/10.1007/s00382-006-0110-3>
- LARGE, W; YEAGER, S. Diurnal to Decadal Global Forcing for Ocean and Sea-Ice Models: The Data Sets and Flux Climatologies.2004. <http://dx.doi.org/10.5065/D6KK98Q6>
- MACHADO, J.P; MIRANDA, G.S.B; GOZZO, L. P; CUSTÓDIO, M.S. Condições Atmosféricas Associadas a Eventos de Ressaca no Litoral Sul e do Sudeste do Brasil durante o El Niño 2015/2016. *Revista Brasileira de Meteorologia*, v.34, n.4, 2019. <https://doi.org/10.1590/0102-7786344067>
- MARANGONI, P. G. M. P. *Previsão de Altura Significativa de Onda Utilizando Redes Neurais Artificiais*. 2021. 102p. Dissertação de Mestrado (Mestre em Engenharia Oceânica), Programa de Pós graduação em Engenharia Oceânica, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro. 2021.
- MARINHA DO BRASIL. NORMAM-33/DPC: Normas da autoridade marítima para implantação e operação de sistemas para determinação de folga dinâmica abaixo da quilha. Rio de Janeiro: Diretoria de Portos e Costas, 2021.
- MARINHO, Y. B; MACHADO, J. P; SARAIVA, J. M. B. Padrões atmosféricos associados a eventos de ressaca no litoral sul do Brasil. *Revista Brasileira De Climatologia*, v.35, n.20, 124–154, 2024. <https://doi.org/10.55761/abclima.v35i20.17743>
- MARONE, E; CAMARGO, R. Marés meteorológicas no litoral do Estado do Paraná: O evento de 18 de agosto de 1993. *Revista Nerítica*, v.8, n.1-2, 1994. <https://doi.org/10.5380/rn.v8i1-2.85081>
- MAZZINI, P. L. F. *Correntes subinerciais na Plataforma Continental interna entre Peruibe e São Sebastião: Observações*. 2009. 131p. Dissertação (Mestrado) – Universidade de São Paulo, São Paulo, BSP, 2009. Disponível em: <http://www.teses.usp.br/teses/disponiveis/21/21132/tde-22092009-154153/>
- MELO, F.E. *Maré meteorológica na Costa Brasileira*. 2017. 328p. Tese (Professor Titular), Escola de Engenharia, Universidade Federal de Rio Grande, Rio Grande. 2017.
- MCCULLOCH, W.S; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, v.5, p. 115–133, 1943. <https://doi.org/10.1007/BF02478259>
- MESQUITA, A. R.d.; FRANCO, A.S; HARARI, J. On Mean Sea-level along the Brazilian Coast. *Geophysical Journal of the Royal Astronomical Society*, v.87, n.1, p. 67-77, 1986. <https://doi.org/10.1111/j.1365-246X.1986.tb04547.x>
- OLAH, C. Understanding LSTM Networks. *Colah's blog*, 2015.
- OPPENHEIMER, M; GLAVOVIC, B.C; J. Sea Level Rise and Implications for Low-Lying Islands, Coasts and Communities. In: *The Ocean and Cryosphere in a Changing Climate*. Special Report of the Intergovernmental Panel on Climate Change.

- Cambridge University Press, Cap.4: p. 321–446, 2022.
<https://doi.org/10.1017/9781009157964.006>
- PARISE, C. K; CALLIARI, L. J; KRUSCHE, N. Extreme storm surges in the south of Brazil: atmospheric conditions and shore erosion. *Brazilian Journal of Oceanography*, v. 57, n.3, 2009.
- PASCANU, R; GULCEHRE, C; CHO, K; BENGIO, Y. How to construct deep recurrent neural networks, arXiv preprint, arXiv:1312.6026. 2014.
<https://doi.org/10.48550/arXiv.1312.6026>
- PASSOS, E.N. Variação Sazonal da Água Central do Atlântico Sul na Plataforma Continental Sudeste Brasileira ao Largo do Estado do Rio De Janeiro. 2015. 132p. Dissertação (Mestrado em Engenharia Civil), Programa de Pós-graduação em Engenharia Civil, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro. 2015.
- PEREIRA, N.E.d.S; VINZÓN, S.B; GALLO, M.N; GABIOUX, M. Meteorological Signal on Hydrodynamics in the Ilha Grande and Sepetiba Bays: Lag Effects and Coastal Currents. *Hydrology*, v.11, n.2, 2024. <https://doi.org/10.3390/hydrology11020015>
- PIMENTEL, L.C.G; MARTON, E; SILVA, M. S. d; JOURDAN, P. Caracterização do regime de vento em superfície na Região Metropolitana do Rio de Janeiro. *Engenharia Sanitária e Ambiental*, v.19, n.2, p. 121-132, 2014. <https://doi.org/10.1590/S1413-41522014000200003>
- PUGH, D. Tides, Surges and Mean Sea-Level. John Wiley, London. 1987
- PUGH, D; WOODWORTH, P. *Sea-Level Science: Understanding Tides, Surges, Tsunamis and Mean Sea-Level Changes*. Cambridge University Press, 2014.
<https://doi.org/10.1017/CBO9781139235778>
- REBOITA, M. S. A; GAN, M. A; ROCHA, R. P; AMBRIZZI, T. Regimes de precipitação na América do Sul: uma revisão bibliográfica. *Revista Brasileira de Meteorologia*, v. 25, n.2, p. 185-204, 2010. <https://doi.org/10.1590/S0102-77862010000200004>
- ROBERTS, J; ROBERTS, T.D. Use of the Butterworth low-pass filter for oceanographic data. *J. Geophys. Res*, v.83, n.C11, 5510–5514, 1978.
<https://doi.org/10.1029/JC083iC11p05510>
- ROSA, P. H.T. 2024. “Notas de uma reunião sobre a função PWELCH”. Março.
- SAHOO, B; BHASKARAN, P.K. Prediction of storm surge and coastal inundation using Artificial Neural Network – A case study for 1999 Odisha Super Cyclone. *Weather and Climate Extremes*, v.23, 100196, 2019.
<https://doi.org/10.1016/j.wace.2019.100196>
- SILVA, I.N.d; SPATTI, D.H; FLAUZINI, R.A. 2016. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Fundamentos teóricos e aspectos práticos. Artliber, 2.ed, 431p, 2016.
- SIQUEIRA, B.V.P.d; PAIVA, A.M. Using neural network to improve sea level prediction along the southeastern Brazilian coast. *Ocean Modelling*, v.168, 101898, 2021.
<https://doi.org/10.1016/j.ocemod.2021.101898>
- SONDERMANN, M; CHOU, S.C; SOUZA, C.R.d. *et al.* Atmospheric Patterns Favourable to Storm Surge Events on the Coast of São Paulo State, Brazil. *Nat. Hazards*, v.117, p. 93–111, 2023. <https://doi.org/10.1007/s11069-023-05851-z>
- STECH, J; LORENZZETTI, J. A. The response of the South Brazil Bight to the passage of wintertime cold fronts. *Journal of Geophysical Research*, v. 97, n.C6, p. 9507-9520, 1992. <http://dx.doi.org/10.1029/92JC00486>
- TECCHIO, R; DE SOUZA, D; C., DA SILVA, M. B. L; DE OLIVEIRA COSTA, M. C; DE CAMARGO, R; HARARI, J. Mean sea level, tidal components and surges in Guanabara Bay (Rio de Janeiro) from 1990 to 2021. *International Journal of Climatology*, 44(13), p. 4629–4648, 2024. <https://doi.org/10.1002/joc.8600>

- TEIXEIRA, G.L.G; BORBA, E.P; COELHO, A.L; TEIXEIRA, F.V.B; MATHIAS, R.S.B. Estudo Preliminar dos impactos do processo de ressurgência na navegação: Um estudo de caso na Baía de Guanabara. In: XV Simpósio sobre Ondas, Marés, Engenharia Oceânica e Oceanografia por Satélite (OMAR-SAT). Apresentação pôster. 2023.
- TRUCCOLO, E. C; FRANCO, D; SCHETTINI, C. A. E. The low frequency sea level oscillations in the northern coast of Santa Catarina, Brazil. *Journal of Coastal Research*, SI 39, p. 547-552, 2006.
- VEDANA, J.; PAIOTTI, M.; SCHVAMBACH, A. Relação da intensidade e direção do vento com a Maré meteorológica. *Metodologias e Aprendizado*, v.4, p. 73-81, 2021. <https://doi.org/10.21166/metapre.v1i.1455>
- WANG, B; LIU, S; WANG, B; WU, W; WANG, J; SHEN, D. Multi-step ahead short-term predictions of storm surge level using CNN and LSTM network. *Acta Oceanol. Sin*, v.40, p. 104–118, 2021. <https://doi.org/10.1007/s13131-021-1763-9>
- YOU, S.H; SEO, J.W. Storm surge prediction using an artificial neural network model and cluster analysis. *Nat. Hazards*, v. 51, p. 97–114, 2009. <https://doi.org/10.1007/s11069-009-9396-x>
- ZEE, David. Ressacas: Retratos da Urgência pela Adequação das Cidades. Olhar Oceanográfico. 2020. Disponível em: <https://olharoceanografico.com/ressacas-retratos-da-urgencia-pela-adequacao-das-cidades/>.
- ZHAO, J; FAN, Y; MU, Y. Sea Level Prediction in the Yellow Sea From Satellite Altimetry With a Combined Least Squares-Neural Network Approach, *Marine Geodesy*, v.42, n.4, p. 344-366, 2019. <https://doi.org/10.1080/01490419.2019.1626306>