

Uma abordagem usando redes neurais artificiais para a previsão de curto prazo de altura de ondas marítimas em região portuária

Vanessa Colla Paspaltzis¹, Alan James Peixoto Calheiros¹

¹Instituto Nacional de Pesquisas Espaciais - INPE

{vanessa.paspaltzis, alan.calheiros}@inpe.br

Abstract. *This study explored the application of the artificial neural network LSTM for short-term wave height forecasting in a port region, using meteorological data collected in situ and satellite image data. First, an exploratory data analysis was performed and an asynchronous correlation was verified between wave height, wind velocity and cloud top brightness temperature data at the study site (Terminal da Unitapajos). Three experiments were performed varying the input parameters of the artificial neural network. The results suggest that both wind and infrared brightness temperature data can be used as precursors of significant wave height events at the location, increasing the accuracy of predictions. However, new experiments will be needed to reduce errors and generate forecasts with a sufficient reliability for port operations.*

Resumo. *Este estudo utilizou a rede neural artificial LSTM para previsão de curto prazo da altura de ondas em região portuária, usando dados coletados in situ e de imagens de satélite. Em primeiro momento, foi realizada análise exploratória dos dados e verificada uma associação assíncrona entre altura de ondas, temperatura de brilho do topo das nuvens e intensidade dos ventos na área de estudo (Terminal da Unitapajos). Três experimentos foram realizados variando os parâmetros de entrada da rede neural artificial. Os resultados sugerem que tanto os dados de ventos como de temperatura de brilho no infravermelho podem ser usados como precursores de eventos de altura de ondas mais significativos no local, aumentando a precisão das previsões. No entanto, novos experimentos serão necessários para reduzir erros e gerar previsões com confiabilidade suficiente para as operações portuárias.*

1. Introdução

Estudos relacionados à previsão da altura de ondas são de importância singular para a segurança da navegação e das operações portuárias, tendo em vista que as condições de onda afetam várias atividades marítimas e são um fator limitante para a realização de certas operações [FAN et al., 2020]. Dentre as ferramentas que auxiliam na compreensão e na previsão dos processos meteorológicos e hidrodinâmicos costeiros, podemos citar a modelagem numérica [RAMMING et al., 1980] e algoritmos de Inteligência Artificial (IA) [AHMAD, 2019], validados por comparações com dados obtidos em observações na região de estudo.

Os métodos tradicionais de previsão de ondas - modelos numéricos globais e regionais - podem não apresentar resolução espacial e temporal necessária para as tomadas de decisões em portos, visto que estes precisam de previsões não só precisas,

mas também de alta resolução temporal, para pontos/locais específicos de interesse. As técnicas de IA são robustas e, geralmente, precisas o suficiente, apresentando vantagens em relação aos métodos tradicionais de modelagem física, principalmente, no quesito de menor custo computacional ([JAMES et al., 2018],[MAXWELL et al., 2018]). Além disso, as técnicas de IA possibilitam a integração de recursos de aprendizado de máquina em sistemas de modelagem orientados por dados e têm se mostrado uma ferramenta poderosa para analisar dados oceanográficos e de tempo com alta precisão de forma eficiente ([AHMAD, 2019]).

Neste contexto, a hipótese científica adotada para este trabalho é que as técnicas de IA podem ser utilizadas como ferramenta para a previsão de curto prazo (*nowcasting*) de altura de ondas em região portuária, representando os fenômenos locais com grau de confiabilidade suficiente para operações portuárias. Para testar esta hipótese, o objetivo principal deste estudo é explorar a aplicação de técnicas de aprendizado de máquina, mais especificamente de redes neurais artificiais, para a previsão de altura das ondas no Terminal Portuário de Barcarena, localizado no estado do Pará, utilizando-se de dados meteo-oceanográficos coletados *in situ* e dados extraídos de imagens do satélite GOES16, a fim de desenvolver um modelo capaz de compreender e reproduzir os principais padrões e tendências da série temporal de altura de ondas observadas no terminal e gerar previsões de curto prazo. Uma ferramenta de previsão como esta pode trazer inúmeros benefícios, tanto para o planejamento das atividades portuárias, com para promover maior segurança durante na execução dos trabalhos, evitando tanto acidentes de trabalho como ambientais.

2. Material e Métodos

Nesta seção serão apresentados e descritos os dados utilizados neste trabalho, os métodos de tratamento e análises realizadas previamente à construção da Rede Neural Artificial (RNA) como parte de análise exploratória [MILO et al., 2020], bem como a preparação dos dados para aplicação da rede escolhida.

O conjunto de dados observados foi coletado na estação de monitoramento meteo-oceanográfico instalada no Terminal da Unitapajos (Figura 1), localizado no estado do Pará - Brasil, e mantida pela empresa HidroMares. A estação é composta por um anemômetro, o qual realiza a medição de intensidade e direção de ventos com resolução temporal de 5 minutos, e por um perfilador acústico de correntes com sensor de pressão embutido - ADCP (*Acoustic Doppler Current Profiler*; modelo SL 500), o qual realiza a medição de altura das ondas, dentre outras variáveis, com resolução temporal de 20 minutos. Neste trabalho, foram utilizados os dados coletados no período de 01/01/2020 até 01/12/2021, totalizando 2 anos de dados.

Além dos dados observados coletados *in situ*, também foram utilizados dados extraídos de imagens do sensor ABI (*Advanced Baseline Imager*), canal 13 (10,3 μm), do Satélite Geoestacionário GOES-16 [SCHMIT et al., 2017], operado pela NASA e pela Administração Nacional Oceânica e Atmosférica dos EUA (NOAA). O GOES-16 orbita a 75,2°W e fornece imagens de alta resolução espacial (0,5 - 2 km) e temporal (de até 10 min) da América do Norte e do Sul, e do Oceano Atlântico até a costa oeste da África, através de 16 bandas espectrais em comprimentos de onda visíveis e infravermelhos através do sensor ABI.

As imagens do GOES16, em Temperatura de Brilho (K, T^b_{IR}), foram previamente




Figura 1. Localização da estação de monitoramento meteo-oceanográfico instalada e mantida pela HidroMares no Terminal da Unitapajos.

processadas, onde foi feito um recorte dentro da área de estudo, utilizando os limites de $50.899658^{\circ}\text{W}$ a $43.549805^{\circ}\text{W}$ e 2.040279°S a 2.284551°N (Figura 2). Em seguida, foram calculados parâmetros estatísticos da temperatura de brilho (e.g. Tb_{IR} mínima, média, máxima e desvio padrão) para cada imagem obtida durante o período de estudo. Assim, foram obtidas séries temporais destes parâmetros estatísticos de Tb_{IR} ao longo do período de estudo para os mesmos instantes dos dados observados *in situ*. O objetivo de utilizar os dados de Tb_{IR} , com resolução de $2 \times 2 \text{ km}$ e 10 minutos de latência, foi inserir indicações de sistemas meteorológicos (e.g. núvens precipitantes ou não) e ambiente (e.g. gradiente de temperatura espacial) que podem estar relacionados com o processo de geração de altura de ondas no local.

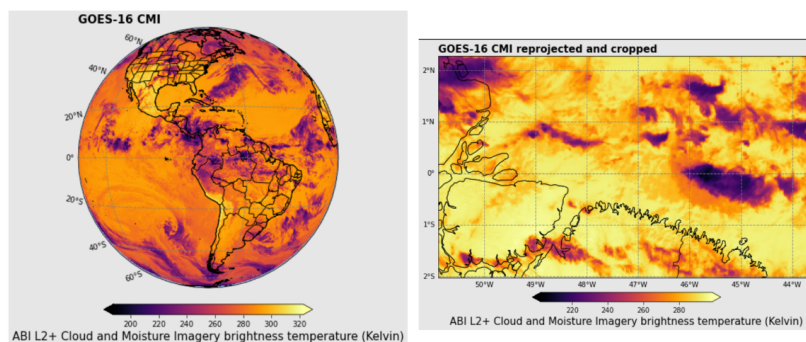


Figura 2. Ilustração dos dados de Tb_{IR} obtidos a partir de imagens do GOES-16 antes (direita) e depois (esquerda) do recorte da área de interesse.

O tratamento dos dados consistiu basicamente nas seguintes etapas: (1) subamostragem de todas as séries do conjunto de dados a cada 20 min (menor resolução temporal do conjunto de dados); (2) verificação e retirada de dados espúrios (dados não realísticos); e (3) verificação e preenchimento de dados faltantes (*gaps*) nas séries temporais, com interpolação linear. Em seguida, foi realizada análise exploratória do conjunto de dados (4), na qual foram feitas análises de correlação entre os parâmetros meteo-oceanográficos disponíveis com o parâmetro de interesse de previsão (altura de onda), bem como análises de autocorrelação e de padrões diários (ciclos diurnos) nos dados meteo-oceanográficos. Por fim, antes de submeter os dados à RNA, também foram feitas: normalização dos da-

dos (6) e separação dos conjuntos de entrada e saída da RNA, bem como dos conjuntos de treinamento e teste (7). Para a análise exploratória, foi calculada a correlação de Pearson entre as séries multivariadas estudadas. No caso dos dados de ventos, foi realizada também a decomposição vetorial dos dados de intensidade e direção dos ventos nas componentes zonal (u) e meridional (v).

2.1. Previsão por Rede Neural Artificial

As RNA são modelos de aprendizado de máquina inspirados em redes neurais biológicas – o cérebro humano - o qual possui complexas teias de neurônios interconectados. Da mesma forma que nosso cérebro, as RNA são compostas por neurônios que se ligam uns aos outros formando, de fato, uma rede. O tipo de RNA mais comum são as redes neurais *feed-forward*, onde os conjuntos de neurônios são organizados em camadas: uma camada de entrada, uma camada de saída e pelo menos uma camada intermediária oculta. As RNA *feed-forward* são limitadas a tarefas de classificação “estática”. No entanto, para modelar tarefas de previsão de tempo, um classificador dinâmico é mais adequado, como as redes neurais recorrentes (RNNs) - um tipo especial de RNA no qual as conexões dos neurônios formam uma sequência temporal, agindo como uma memória interna que permite considerar tendências temporais em suas previsões. A principal limitação das RNNs é que são restritas a “olhar para trás no tempo” para aproximadamente dez passos de tempo. Esse problema foi resolvido com a rede neural Long Short-Term Memory (LSTM), a qual possui células de memória de longo prazo [STAUDEMAYER et al., 2019].

A LSTM possui uma estrutura mais complexa, sendo formada por 3 portas (*gates*), cada um recebe informações de diferentes prazos no tempo, selecionando o que deve ou não ser “esquecido”. Assim, a cada intervalo de tempo, algumas memórias são deletadas e algumas são adicionadas. Desta forma, uma rede LSTM pode aprender a reconhecer uma entrada importante, armazená-la no estado de longo prazo, preservá-la e extraí-la quando necessário. Por este motivo a rede neural LSTM tem sido bem-sucedida na identificação de padrões de longo prazo em séries temporais e previsões de altura de ondas [GERON, 2019],[FAN et al., 2020].

Assim, neste trabalho foi decidido utilizar a rede LSTM para geração das previsões de alturas de ondas. Foram realizados diferentes experimentos variando o conjunto de dados de entrada, mas mantendo a mesma combinação de hiper-parâmetros da rede neural, com o objetivo de avaliar a influência de cada variável no resultado da rede. O primeiro modelo construído (M1) utiliza apenas dados de altura de ondas no conjunto de entrada. Já o segundo modelo (M2) contém tanto dados de altura de ondas como de intensidade dos ventos no conjunto de entrada. Por fim, no terceiro modelo (M3), além dos dados de altura de onda e de ventos, também foram incluídas no conjunto de entrada as estatísticas de temperatura de brilho. Em todos os cenários foi adotado como saída do modelo os dados de altura de onda para as 2 horas seguintes, com resolução temporal de 20 min (6 passos de tempo). Devido às altas correlações observadas entre as séries para ciclos diários, foi escolhido utilizar as últimas 24 horas dos dados no conjunto de entrada em todos os experimentos, também com resolução temporal de 20 min (72 passos de tempo). A arquitetura de rede é composta por duas camadas LSTM de 50 unidades e uma camada densa. A Tabela 1 apresenta a combinação de hiper-parâmetros da rede neural utilizada nos experimentos.

O conjunto de dados foi normalizado entre -1 e 1 e dividido em treinamento

(01/01/2020 até 31/10/2021) e teste (novembro e dezembro de 2021) em todos os experimentos. Durante o treinamento, 20% do conjunto de treino foi usado para validação.

Tabela 1. Combinação de hiper-parâmetros da rede neural

Nº camadas ocultas	1
Nº unidades na camada oculta	50
Nº unidades na camada de entrada	50
Otimizador	Adam
Taxa de aprendizado	1×10^{-3}

3. Resultados

3.1. Análise exploratória dos dados

Os dados de altura de ondas coletados *in situ* estão apresentados na Figura 3. Neste trabalho, foi utilizado o parâmetro denominado WH10/100, o qual representa as alturas 10% mais altas registradas durante o período de amostragem (20 minutos), e é o parâmetro utilizado para as tomadas de decisões do terminal portuário. Para melhor visualização da distribuição destes dados, foi feita uma classificação das alturas em três faixas, utilizado como referência os percentis de 66 ($P_{66} = 0,29$ m) e de 99 ($P_{99} = 1,20$ m): ondas baixas e moderadas ($< P_{66}$); ondas altas ($\geq P_{66}$ e $< P_{99}$); e ondas extremas ($\geq P_{99}$). Com base na figura é possível observar que ondas com altura maior ou igual a 1,20 m já são consideradas extremas para o local, ou seja, sua ocorrência é rara.




Figura 3. Série temporal dos dados de altura de onda coletados *in situ* na estação de monitoramento, durante o período de estudo.

A Figura 4 apresenta a matriz de correlação de Pearson entre as séries multivariadas estudadas. As variáveis com maiores correlações com altura de onda foram a intensidade do vento médio (correlação de 0.33) e a intensidade das componentes zonal (0.34) e meridional do vento (0.23). Já para a temperatura de brilho, a correlação mais alta encontrada com a altura de onda foi de apenas 0,11, para a temperatura de brilho média.

Com objetivo de explorar em maior detalhe as relações entre intensidade dos ventos e alturas das onda, foi realizada uma análise para verificação de sazonalidade a partir de *boxplots* mensais (Figura 5). Analisando estes resultados, podemos observar que há




Figura 4. Matriz de correlação entre os parâmetros: Tb_{IR} média ($mean$), desvio padrão de Tb_{IR} (std), Tb_{IR} mínima (min) e máxima (max), intensidade do vento médio ($WindSpeedAvg$), da componente zonal ($Wind_U$) e da componente meridional do vento ($Wind_V$), e altura de onda ($WH10/100$).

um padrão muito semelhante nas variações mensais de ambas as variáveis. Entre os meses de abril e julho, tanto os valores de alturas de ondas como de intensidade dos ventos são mais baixos. Já durante os meses de setembro e outubro, as alturas de ondas e as intensidades dos ventos são predominantemente mais altas. Portanto, esta é uma evidência de que as variações sazonais de altura de ondas estão associadas às variações sazonais de ventos no local de estudo, apesar de as correlações de Pearson calculadas diretamente entre as variáveis terem sido baixas. Desta forma, os resultados indicam que existe relação entre estas variáveis, mas que pode não ser linear. Os gráficos também mostram que os maiores valores de altura registrados ocorreram nos meses de janeiro e março, provavelmente ocasionado por eventos locais específicos, visto que estes dados estão apresentados como *outliers*.

A fim de avançar na análise exploratória dos dados, foi realizada também a análise de autocorrelação para as variáveis de altura de onda, intensidade do vento e Tb_{IR} (Figura 6). Podemos observar que, com exceção da Tb_{IR} média, as demais variáveis apresentam um padrão semelhante: iniciam com autocorreção elevada e com diminuição gradativa conforme os passos de tempo avançam, seguido de um aumento dos valores de autocorreção após aproximadamente 24-25 horas. Este padrão sugere, portanto, a ocorrência de ciclos diurnos no local tanto para as ondas como para ventos. Desta forma, também foi realizada uma análise de ciclo diurno para as variáveis estudadas. Para esta análise, os dados foram inicialmente agrupados pelo horário do dia. Em seguida, foi feito o cálculo do valor médio para cada horário. Por fim, foi calculada a correlação cruzada entre as séries médias diurnas (Figuras 7 e 8).

Os resultados mostram que há uma elevada correlação tanto entre altura de onda e intensidade do vento (correlação de 0,97), como entre altura de onda e Tb_{IR} média (correlação de -0,94), com um *lag* de 280 min para a primeira, e de 140 min para a segunda. Isto é, em média, 280 min após o maior pico médio diário de intensidade do vento, e 140 min após o menor pico diário de Tb_{IR} média para a área de estudo, ocorre o pico máximo diário de altura de onda na estação de monitoramento. Estes resultados podem refletir os ciclos diurnos naturais da convecção, maré e brisa da região e foram

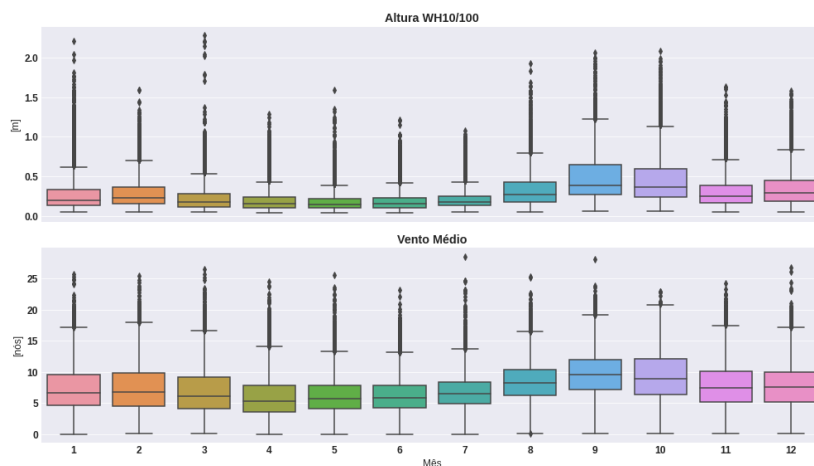


Figura 5. **Boxplots mensais de altura de onda e de intensidade do vento médio.**

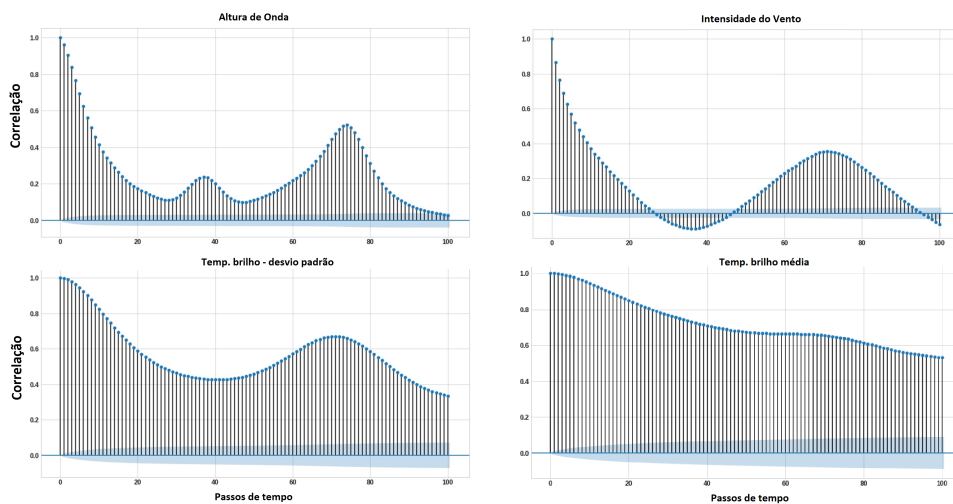


Figura 6. **Análise de autocorrelação para as séries de altura de onda, intensidade do vento médio, desvio padrão de Tb_{IR} e Tb_{IR} mínima.**

levados em consideração na escolha do número de passos de tempo de dados de entrada da RNA, para representar os processos locais com maior fidelidade.

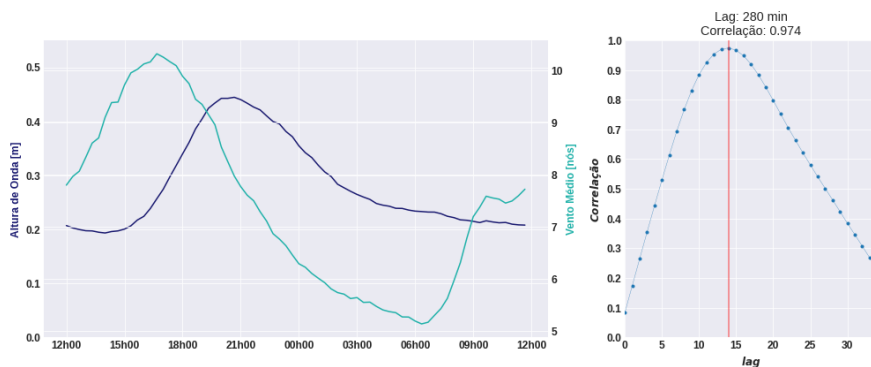


Figura 7. **Análise de correlação cruzada para as séries de médias diárias de altura de onda e de intensidade do vento médio.**




Figura 8. Análise de correlação cruzada para as séries de médias diárias de altura de onda e de Tb_{IR} média.

3.2. Avaliação dos modelos de previsão de altura de onda

Uma vez realizado o pré-processamento e análise exploratória do conjunto de dados, nesta seção são analisadas os resultados das previsões de altura de onda com base nas informações pré-estabelecidas. Os valores de RMSE obtidos para o conjunto de teste dos três modelos foram de 0,073 m (M1), 0,071 m (M2) e 0,067 (M3), indicando que a inclusão dos dados de ventos e dos dados de Tb_{IR} tiveram um efeito positivo no desempenho do modelo, aumentando a assertividade das previsões.

Na Figura 9 estão ilustradas as comparações entre os dados observados e os valores previstos para cada um dos três modelos. Apesar dos valores relativamente baixos de RMSE vistos anteriormente, analisando a figura podemos observar que os três modelos apresentaram elevada variabilidade, com muitos pontos previstos divergindo dos valores observados. A Figura 10 apresenta, por sua vez, os erros "instantâneos" do modelo M3, considerando o cálculo simples da diferença entre dado observado e previsto, para cada passo de tempo de previsão ($t+20$ min, $t+40$ min, ... até $t+2h$). Podemos observar que, como esperado, há uma tendência de aumento de erros do modelo conforme o passo de tempo de previsão aumenta, sendo o primeiro passo de tempo ($t+20$ min) o que apresenta os menores erros (concentrados na faixa de ± 10 cm). Já para o último passo de tempo ($t+2h$), os erros se concentram na faixa de ± 25 cm. Para todos os passos de tempo, no entanto, foram observadas ocorrências de erros superiores a 75 cm.

Por fim, a Figura 11 apresenta a matriz de confusão para os resultados das previsões do modelo M3 realizadas com 20 min, 1h e 2h de antecedência, considerando como referência o valor do limite operacional de 45 cm utilizado pelo Terminal. Podemos observar que para este limite o modelo tem obtido bons resultados.

4. Considerações Finais

Este trabalho teve como objetivo explorar a aplicação da rede neural artificial LSTM na previsão de curto prazo de altura de ondas no Terminal Portuário de Barcarena, a partir de dados observados coletados *in situ*, em uma estação de monitoramento meteo-oceanográfico instalada no Terminal, bem como dados extraídos de imagens do satélite GOES-16, a fim de verificar se este método é capaz de gerar previsões com confiabilidade suficiente para as operações portuárias. A análise exploratória dos dados permitiu a identificação de alguns padrões no conjunto de dados, como variações sazonais e ciclos




Figura 9. Comparação entre os dados observados e previstos pelos modelos.




Figura 10. *Boxplots* das diferenças entre os dados observados e previstos pelo modelo 03, para cada passo de tempo de previsão (de 20 min até 2 horas no futuro). Linhas pontilhadas indicam a faixa de erros de $\pm 0,1$ m.




Figura 11. Matriz de confusão previsões de altura de onda (WH) realizadas com 20 min, 1h e 2h de antecedência.

diurnos, bem como associações assíncronas entre as séries multivariadas estudadas. Além disso, os resultados sugerem que tanto os dados de ventos como de temperatura de brilho no infravermelho podem ser usados como precursores de eventos de altura de ondas mais significativos no local, aumentando a precisão das previsões.

O modelo preditivo que utilizou no conjunto de entrada da rede neural tanto dados de altura de onda como os dados de ventos e de temperatura de brilho foi o que apresentou os melhores resultados. Foi observado que os erros são consideravelmente menores para o primeiro passo de tempo da previsão ($t+20$ min), do que para o último passo de tempo ($t+2h$). Para os primeiros passos de tempo, os erros absolutos estão concentrados próximo

da faixa de 10 cm, enquanto no último passo de tempo, na faixa de 25 cm. Para todos os passos de tempo, no entanto, ocorreram erros pontuais acima de 75 cm.

Apesar do resultado promissor para os primeiros passos de tempo, o modelo ainda não está conseguindo prever com boa assertividade as alturas de ondas para até 2 horas no futuro, visto que erros acima de 20 cm são considerados significativos para as operações. Para os próximos passos deste trabalho, pretende-se evoluir nos experimentos utilizando a LSTM e possivelmente outras redes neurais artificiais, variando ainda mais os conjuntos de dados de entrada e explorando variações de arquiteturas de rede e de hiper-parâmetros, a fim de otimizar as previsões e obter resultados mais satisfatórios.

5. Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Agradecemos também à Unitapajos e à HidroMares, em especial ao Alexandre De Caroli, pela disponibilização dos dados e suporte concedido nas análises, os quais possibilitaram a realização desta pesquisa.

Referências

- Ahmad, H. (2019). Machine learning applications in oceanography. *Aquatic Research*, 2(3), 161-169. <https://doi.org/10.3153/AR19014>
- Fan, S., Xiao, N., Dong, S. (2020). A novel model to predict significant wave height based on long short-term memory network. *Ocean Engineering*, 205, 107298.
- Géron, A. (2019). *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn TensorFlow*. Alta Books.
- James, S. C., Zhang, Y., O'Donncha, F. (2018). A machine learning framework to forecast wave conditions. *Coastal Engineering*, 137, 1-10. <https://doi.org/10.1016/j.coastaleng.2018.03.004>
- Maxwell, A. E., Warner, T. A., Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817.
- Milo, T., Somech, A. (2020). Automating exploratory data analysis via machine learning: An overview. In *Proceedings of the 2020 ACM SIGMOD International Conference on Management of Data* (pp. 2617-2622).
- Ramming, H-G., Kowalik, Z. (1980). *Numerical Modelling of Marine Hydrodynamics: Applications to Dynamic Physical Process*, Vol. 26, Elsevier, pp. 368.
- Schmit, T. J., Griffith, P., Gunshor, M. M., Daniels, J. M., Goodman, S. J., Lehair, W. J. (2017). A closer look at the ABI on the GOES-R series. *Bulletin of the American Meteorological Society*, 98(4), 681-698. DOI: <https://doi.org/10.1175/BAMS-D-15-00230.1>
- Staudemeyer, R. C., Morris, E. R. (2019). Understanding LSTM—a tutorial into long short-term memory recurrent neural networks. arXiv preprint arXiv:1909.09586.