

Um Modelo Espaço-temporal Para Previsão De Ondas Oceânicas Usando Redes Neurais Artificiais

Alexandre J. S. Hackenhaar¹, Felipe C. Minuzzi²
 UFSM, Santa Maria, RS

Conhecer informações atualizadas e previsões sobre o estado do mar, especialmente das condições das ondas, é de grande importância para muitas aplicações, como segurança no mar e na costa, planejamento de infraestrutura de instalações marítimas e plataformas *offshore*, operações de transporte e projetos de energias renováveis que ocorrem no oceano, alertas de catástrofes naturais e avanço nas pesquisas em Geociências [1]. Notadamente, as ondas oceânicas podem ser simuladas a partir de modelos físicos-matemáticos e existem diversos algoritmos numéricos de última geração capazes de realizar esta tarefa; Todavia, o aumento da capacidade computacional de processamento, aliada à disponibilidade de bibliotecas confiáveis para obtenção de informações em séries históricas, tem permitido o avanço de poderosos algoritmos de inteligência artificial que ganham popularidade em diversas aplicações devido a sua capacidade de analisar rapidamente volumes muito grandes de dados e fazer previsões tão acuradas quanto os modelos tradicionais.

Nesse sentido, algoritmos de aprendizado de máquina já têm sido utilizados para a previsão de ondas oceânicas, aparecendo como uma alternativa às abordagens atuais e ao trabalho dos modelos físicos que são comparativamente mais demorados [3]. No trabalho realizado por [4] os autores destacam a utilização de aprendizado de máquinas e redes neurais para realização de previsões climáticas. Entretanto, os mesmos evidenciam que as abordagens clássicas dessas aplicações raramente exploram as dependências espaço-temporais do sistema.

Observa-se que quando o comportamento do sistema em estudo é dominado por variáveis espaciais ou temporais, como é o caso das ondas, essas limitações podem ser superadas utilizando abordagens de aprendizagem profunda ou modelos híbridos, pois este tipo de técnica é capaz de extrair de forma automática características espaço-temporais, permitindo assim uma melhor compreensão do problema e aumentando a capacidade de previsão de eventos sazonais, de longo alcance e que ocorrem em diferentes escalas de tempo. São exemplos disso os padrões climáticos extremos, previsões de precipitação e modelagem de fenômenos de transporte [4].

A modelagem de ondas oceânicas é dada por um sistema composto por relações matemáticas diversas que resultam em uma equação do balanço, descrita por:

$$\frac{DF}{Dt} = S_{in} + S_{nl} + S_{ds} \quad (1)$$

onde $F = F(k, x, t)$ é o espectro de onda e $k = (f, \theta)$, o vetor de onda com frequência f . Ainda, S_{in} é o termo de contribuição atmosférica devido principalmente a ação dos ventos sobre a superfície da água; S_{nl} representa as interações não lineares entre ondas, que são fundamentais para descrever a estabilização do espectro de onda e, por fim, o termo S_{ds} representa os fatores de dissipação da energia das ondas. Dessa forma, o problema de previsão de ondas oceânicas traduz-se em encontrar

¹alexandre.schweig@acad.ufsm.br

²felipe.minuzzi@ufsm.br

uma solução para o espectro de onda F , descrito por [2]:

$$\begin{aligned} \frac{\partial F}{\partial t} + \mathbf{c}_g \cdot \nabla_{\mathbf{c}_g} F &= S_{in}(\mathbf{u}, F, t) + S_{ni}(F, t) + S_{ds}(F, t) & f \in (0, \infty), \theta \in [0, 2\pi], \\ & & (\mathbf{x}, t) \in D \times I \\ F(f, \theta, \mathbf{x}, t_0) &= F_0(f, \theta, \mathbf{x}) & \mathbf{x} \in D, \theta \in [0, 2\pi] \\ F(f, \theta, \mathbf{x}, t) &= 0 & \mathbf{x} \in \partial D \\ F(f, \theta, \mathbf{x}, t) &= F(f_{hf}(t), \theta, \mathbf{x}, t) & f \in [f_{hf}, \infty] \end{aligned} \quad (2)$$

em que D é uma região de interesse no oceano, $I = [t_0, t_f]$ é o intervalo de tempo entre o instante inicial e o prazo da previsão e ∂D representa a fronteira da região. Ainda, F_0 é o espectro inicial de onda, f_{hf} é a frequência de corte que delimita a parte mais alta da frequência do espectro de onda, p é um parâmetro a ser determinado e \mathbf{u} é o campo de vento conhecido para todo $t \in I$.

Ademais, dentro do estudo do comportamento das ondas, uma das variáveis mais importantes a ser determinada para fins práticos é a altura significativa de onda denotada por H_s , definida pela média do terço das alturas mais altas de uma determinada região marítima. A obtenção dessa variável é facilitada uma vez que se conhece o espectro de ondas F . Assim, denominando $s_{\frac{1}{3}}$ como o limite inferior do terço das alturas mais altas, define-se H_s como:

$$H_s = \frac{\int_{s_{\frac{1}{3}}}^{\infty} \frac{2s}{8m_0} e^{-\frac{s^2}{8m_0}}}{\int_{s_{\frac{1}{3}}}^{\infty} \frac{2s}{8m_0} e^{-\frac{s^2}{8m_0}}} \quad (3)$$

na qual $m_0 = m_0(F)$ é um parâmetro que depende do espectro de onda. A solução de (3) aproximada numericamente é $H_s = 4\sqrt{(m_0)}$.

Assim, o presente trabalho tem como objetivo construir e utilizar uma rede neural do tipo LSTM (*Long-Short Term Memory*) para realizar a previsão espaço-temporal da altura significativa de onda em uma região da costa brasileira delimitada no litoral do Rio Grande do Sul. A falta de estudos prévios que abordem a previsão da altura significativa de onda explorando as dependências espaço-temporais por meio de redes neurais é motivadora para a realização deste trabalho, uma vez que destaca a oportunidade única de contribuir para um campo em crescente expansão e para pesquisas futuras.

Agradecimentos

Agradecemos à CAPES pela ajuda financeira no desenvolvimento deste trabalho.

Referências

- [1] F. Ardhuin, J. E. Stopa, B. Chapron, F. Collard et al. “Observing sea states”. Em: **Frontiers in Marine Science** (2019), p. 124. DOI: 10.3389/fmars.2019.00124.
- [2] L. Farina. **Ondas Oceânicas de Superfície**. 2a. ed. São Paulo: SBMAC, 2012. ISBN: 978-85-86883-64-4.
- [3] F. C Minuzzi e L. Farina. “A deep learning approach to predict significant wave height using long short-term memory”. Em: **Ocean Modelling** 181 (2023), p. 102151.
- [4] M. Reichstein, G. Camps-Valls, B. Stevens, M. Jung, J. Denzler, N. Carvalhais e F. Prabhat. “Deep learning and process understanding for data-driven Earth system science”. Em: **Nature** 7743 (2019), pp. 195–204. DOI: 10.1038/s41586-019-0912-1.