



Previsão do El Niño - oscilação sul (ENOS), utilizando redes neurais artificiais

Forecast El Niño – southern oscillation (ENSO), using artificial neural networks

V. Azevedo¹; A. L. Amorim¹; W. C. Santos Sobrinho¹; F. L. Santos²;
R. B. Zanin²; A. C. Zuffo¹; A. L. Sotero¹; H. O. Fagundes¹

¹Universidade Estadual de Campinas, 13083-970, Campinas-São Paulo, Brasil

²Universidade do Estado de Mato Grosso, 78200-000, Profãgua - Cáceres-Mato Grosso, Brasil

*vinicius@azevedoambiental.com

(Recebido em 28 de julho 2025; aceito em 02 de outubro de 2025)

Este trabalho apresenta uma abordagem baseada em redes neurais artificiais para a previsão do fenômeno El Niño–Oscilação Sul (ENOS), utilizando como variável-alvo o Índice Oceânico de El Niño (ONI). Foram avaliadas quatro arquiteturas — Multilayer Perceptron (MLP), Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM) e CNN-LSTM — em horizontes de previsão definidos por defasagens temporais (lags) de 1 a 6 meses. O objetivo foi analisar o impacto do tempo de antecedência sobre a acurácia das previsões e delimitar o horizonte de utilidade prática dessas estimativas. As variáveis preditoras incluem indicadores oceanográficos e atmosféricos consolidados na literatura: anomalias de Temperatura da Superfície do Mar (TSM) na região Niño 3.4, Índice de Oscilação Sul (SOI), Índice Multivariado do El Niño versão 2 (MEI.v2) e o Padrão de Oscilação do Pacífico Norte-Americano (PNA). Para evitar vazamento de dados, adotou-se a separação temporal entre os conjuntos de treino e teste, sem embaralhamento. Os resultados indicam que, para lag 1, os modelos alcançam coeficientes de determinação (R^2) superiores a 0,94, demonstrando elevada capacidade de previsão em curto prazo. Com o aumento do lag, observa-se queda progressiva no desempenho, atingindo R^2 abaixo de 0,20 para lag 6. A análise comparativa, por meio de um score unificado baseado em R^2 , MAE e RMSE normalizados, evidenciou a robustez da MLP em diferentes janelas temporais, embora a LSTM tenha se destacado em horizontes mais longos. Os resultados destacam o potencial das redes neurais na captura de padrões climáticos de curto prazo e suas limitações para previsões em escalas temporais estendidas.

Palavras-chave: ENOS, redes neurais, previsão.

This study presents an approach based on artificial neural networks for forecasting the El Niño–Southern Oscillation (ENSO) phenomenon, using the Oceanic Niño Index (ONI) as the target variable. Four neural network architectures were evaluated — Multilayer Perceptron (MLP), Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), and CNN-LSTM — across forecasting horizons defined by temporal lags ranging from 1 to 6 months. The main objective was to analyze the impact of lead time on prediction accuracy and to determine the practical time limit of these estimates. The predictor variables include well-established oceanographic and atmospheric indicators: Sea Surface Temperature (SST) anomalies in the Niño 3.4 region, the Southern Oscillation Index (SOI), the Multivariate El Niño Index version 2 (MEI.v2), and the Pacific North American Pattern (PNA). To prevent data leakage, a temporal split was applied between the training and testing sets, without shuffling. The results indicate that, for lag 1, the models achieved coefficients of determination (R^2) above 0.94, demonstrating high short-term forecasting capability. However, as the lag increased, a progressive decline in performance was observed, reaching R^2 values below 0.20 for lag 6. A comparative analysis using a unified score based on normalized R^2 , MAE, and RMSE revealed the robustness of MLP across different temporal windows, although LSTM outperformed in longer-term horizons. These results highlight the potential of neural networks in capturing short-term climate patterns, while also emphasizing their significant limitations for extended forecasting timeframes.

Keywords: ENSO, neural networks, forecasting.

1. INTRODUÇÃO

A variabilidade climática interanual mais proeminente do planeta é impulsionada pelo El Niño–Oscilação Sul (ENOS), fenômeno originado no Pacífico tropical a partir da interação oceano–atmosfera [1] e com implicações globais nos padrões de precipitação, temperatura e

circulação atmosférica [2, 3]. Suas fases extremas, El Niño (aquecimento anômalo do Pacífico leste e central) e La Niña (resfriamento anômalo), afetam eventos extremos, produtividade agrícola, recursos hídricos e energia em escala global [4, 5]. No Brasil, a capacidade de prever o estado do ENOS com antecedência de meses é estratégica para setores como agricultura, energia elétrica e gestão de riscos de desastres [6].

Apesar de décadas de pesquisa, a previsão do ENOS ainda é um grande desafio [6] e tem papel estratégico no planejamento dos setores motrizes dos países, como o Brasil, uma vez que eventos El Niño intensos provocam impactos bilionários para o agronegócio [7], só para citar alguns. Modelos acoplados oceano-atmosfera baseados em princípios físicos têm sido a principal metodologia utilizada para a previsão operacional, mas sofrem com os vieses inerentes ao modelo, requisitos computacionais intensivos e limitações na representação de processos em pequena escala [8]. Modelos estatísticos, embora computacionalmente eficientes, enfrentam desafios na capacidade de capturar a complexa não-linearidade das interações oceano-atmosfera e a transição entre as fases do ENOS. Um desafio particular é a persistente "barreira de previsibilidade da primavera" [9], que é um período durante o primeiro semestre do ano quando a habilidade preditiva diminui drasticamente, tornando a previsão para o segundo semestre (crucial para o desenvolvimento de El Niño/La Niña) uma tarefa de grande dificuldade. Considerando o desafio da barreira de previsibilidade persistente, é importante que a previsão tenha antecedência de três a seis meses, o que permite a possibilidade de planejamento por setores sensíveis a variações climáticas causadas pelo fenômeno [5, 10]. Por exemplo, a definição da safra e do plantio no Centro-Oeste e Sudeste pode ser adaptada às previsões do ENOS; no setor elétrico, o Operador Nacional do Sistema (ONS) pode ajustar o despacho térmico frente aos cenários de redução na capacidade de geração de energia das centrais hidrelétricas [11]. Assim, melhorar os modelos preditivos do ENOS traz benefícios econômicos e estratégicos tangíveis.

O ENOS é parte de um sistema interconectado, onde a interação entre o oceano Pacífico Equatorial e a atmosfera é mediada por mecanismos como a circulação de Walker, as ondas de Kelvin e Rossby, e processos de ressurgência; esses mecanismos contribuem para a retroalimentação positiva durante o desenvolvimento dos eventos El Niño [12] e entendê-los é fundamental para que modelos baseados em aprendizado de máquina consigam extrair padrões climáticos robustos e significativos.

A caracterização operacional do ENOS (El Niño–Oscilação Sul) ocorre, principalmente, via o Índice Oceânico de El Niño (ONI). Esse índice é calculado a partir da anomalia da temperatura da superfície do mar (TSM) na região denominada Niño 3.4 (latitude 5°N–5°S, longitude 120°W–170°W). O ONI é obtido como uma média móvel de três meses consecutivos dessas anomalias e comparado com uma série climatológica de 30 anos, atualizada periodicamente. Esse índice é amplamente utilizado por agências meteorológicas, como a *National Oceanic and Atmospheric Administration* (NOAA), para indicar não apenas a presença do fenômeno, mas também sua intensidade e duração [13]. A Figura 1 ilustra a série histórica do índice ONI, com destaque para as classificações de intensidade dos eventos El Niño e La Niña.




Figura 1 – Série histórica do Índice Oceânico de El Niño (ONI) e faixas de intensidade dos eventos ENOS.

Embora o ENOS seja fortemente influenciado por mecanismos internos da interação oceano-atmosfera, estudos têm demonstrado que situações externas — como a variabilidade da irradiância solar (*Total Solar Irradiance* – TSI) — também podem modular a distribuição de energia na superfície dos oceanos tropicais. Essa modulação atua de forma indireta sobre processos como

ressurgência, convecção atmosférica e deslocamento da termoclina, alterando o padrão sazonal e decadal de fenômenos como o El Niño [14, 15]. A absorção de radiação solar pelos oceanos, condicionada ainda por fatores como albedo e cobertura de nuvens, compõe o pano de fundo energético sobre o qual as anomalias do ENOS se desenvolvem.

Apesar da relevância do fenômeno, prever com antecedência suas variações continua sendo um dos grandes desafios da climatologia moderna. A dinâmica do ENOS envolve múltiplos fatores oceânicos e atmosféricos que interagem criando um sistema não linear e, muitas vezes, caótico [16]. Essa complexidade faz com que os modelos estatísticos tradicionais, como regressões lineares ou modelos ARIMA, não sejam eficientes o suficiente, especialmente para projeções de médio e longo prazo [17].

Nesse contexto, abordagens baseadas em inteligência artificial têm ocupado espaço, sobretudo pelo uso de redes neurais artificiais (RNAs), capazes de revelar relações complexas e não lineares em séries temporais climáticas [18, 19]. Trabalhos recentes mostram que arquiteturas como LSTM e CNN-LSTM apresentam desempenho promissor na previsão do ENOS, especialmente para horizontes de curto prazo [20, 17].

A contribuição desses métodos está em explorar padrões ocultos de memória temporal e espacial que métodos estatísticos clássicos não capturam. Ainda assim, a literatura reforça que o ganho tende a ser limitado em defasagens mais longas, enfatizando a importância de se investigar os limites práticos de aplicação dessas arquiteturas [6, 21].

Assim, este trabalho realiza uma análise comparativa entre diferentes arquiteturas de redes neurais — MLP, RNN, LSTM e CNN-LSTM — aplicadas à previsão do índice ONI, considerando horizontes de 1 a 6 meses (*lags*). Objetiva-se, pois, compreender o limite temporal de acurácia dessas arquiteturas, fornecendo subsídios para aplicações práticas em setores vulneráveis às variações climáticas associadas ao ENOS.

2. MATERIAL E MÉTODOS

A metodologia compreende sete etapas principais: (i) coleta e organização dos dados climáticos, (ii) normalização das séries, (iii) criação de defasagens temporais (*lags*), (iv) análise de correlação entre variáveis, (v) definição das arquiteturas de rede, (vi) treinamento dos modelos e (vii) avaliação de desempenho.

Os dados utilizados foram obtidos de fontes públicas da NOAA – *National Oceanic and Atmospheric Administration*, referência internacional no monitoramento do ENOS. Foram consideradas séries mensais iniciadas em janeiro de 1950, contendo indicadores oceânicos e atmosféricos amplamente reconhecidos pela literatura: anomalias da temperatura da superfície do mar (SST) nas regiões Niño 3, Niño 3.4 e Niño 4, Índice de Oscilação Sul (SOI), Índice Multivariado do El Niño (MEI.v2), radiação de ondas longas (OLR) e o Padrão de Oscilação do Pacífico Norte-Americano (PNA). A variável-alvo do modelo é o próprio ONI, calculado com base na média móvel trimestral das anomalias de SST na região Niño 3.4.

Todas as variáveis foram normalizadas utilizando Min-Max *Scaling* com base no conjunto de treinamento. A divisão entre treino e teste seguiu proporção de 80/20, respeitando a ordem cronológica das observações para evitar vazamento de dados.

Para incorporar o efeito da memória climática e simular diferentes horizontes de previsão, foram criadas defasagens de 1 a 6 meses (*lags* de 1 a 6) para cada variável preditora. Com isso, cada modelo passou a prever o valor atual do ONI com base nas condições climáticas de 1 a 6 meses anteriores, permitindo investigar o desempenho das redes em diferentes janelas de antecipação.

A partir das séries defasadas, foi conduzida uma análise de correlação de Pearson entre as variáveis explicativas e o ONI. Inicialmente, foi gerada uma matriz completa contendo todas as variáveis. Em seguida, aplicou-se um filtro considerando apenas aquelas com coeficiente de correlação ($|r|$) maior ou igual a 0,80 em relação ao ONI. Essa filtragem teve por objetivo reduzir a dimensionalidade do problema e manter apenas os preditores com maior relevância estatística. A Figura 2 ilustra essa seleção, com a matriz original à esquerda e a versão filtrada à direita.




Figura 2 – Matriz de correlação de Pearson entre as variáveis climáticas disponíveis na série histórica (à esquerda) e a matriz filtrada com variáveis que apresentaram correlação com módulo igual ou superior a 0,80 em relação ao ONI_target (à direita). As variáveis selecionadas na matriz da direita foram utilizadas como entradas nos modelos de previsão do ENOS, por apresentarem associação estatística significativa com o índice ONI.

As redes neurais testadas foram: Perceptron Multicamadas (MLP), Rede Neural Recorrente (RNN), Rede Neural LSTM (*Long Short-Term Memory*) e uma arquitetura híbrida CNN-LSTM. A MLP foi composta por três camadas densas com 128, 64 e 1 neurônio. A RNN utilizou uma camada recorrente simples com 64 unidades, seguida de saída densa. A LSTM foi estruturada com 64 unidades e *dropout* de 0.2, enquanto a CNN-LSTM combinou uma convolução 1D (64 filtros, kernel 2x1), camada de *pooling* e uma LSTM final. As arquiteturas foram pensadas para capturar padrões de curto e longo prazo (RNN/LSTM), além de estruturas locais relevantes (CNN-LSTM).

A Figura 3 ilustra essas arquiteturas, destacando as camadas utilizadas em cada modelo e a transformação das entradas climáticas ao longo da rede.

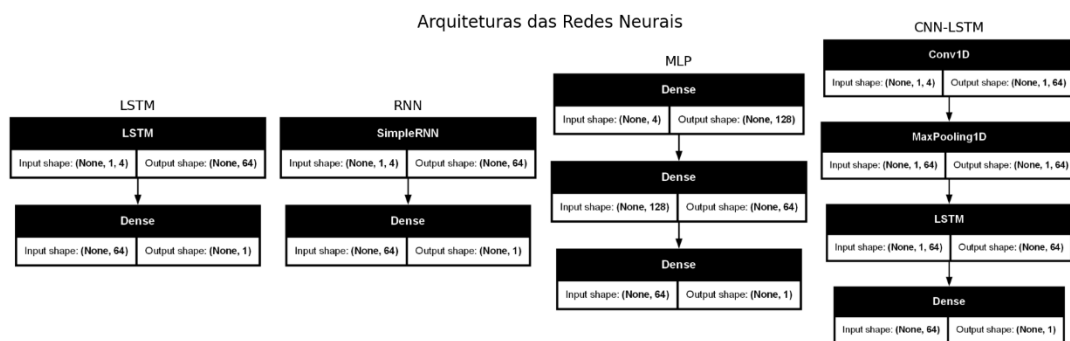


Figura 3 – Arquiteturas das redes neurais artificiais utilizadas: LSTM, RNN, MLP e CNN-LSTM. As caixas indicam as camadas de cada modelo, com os respectivos formatos de entrada e saída para o conjunto de dados do ENOS.

Todos os modelos foram implementados em Python 3.10, utilizando o ambiente Jupyter Notebook, com a biblioteca TensorFlow 2.15 e sua API Keras. O monitoramento do treinamento foi realizado com o TensorBoard, possibilitando o acompanhamento das métricas de perda e validação ao longo das épocas.

O processo de treinamento respeitou a ordem temporal dos dados (sem embaralhamento) e foi realizado por até 100 épocas com batch size de 16. A função de ativação nas camadas ocultas foi

ReLU, com saída linear. O otimizador utilizado foi o Adam, com taxa de aprendizado padrão de 0,001. A função de perda adotada foi o erro quadrático médio (MSE).

O desempenho dos modelos foi avaliado com base em três métricas complementares: Erro Absoluto Médio (MAE), Raiz do Erro Quadrático Médio (RMSE) e Coeficiente de Determinação (R^2). Além disso, as séries previstas foram comparadas graficamente com os valores observados do ONI para análise qualitativa da aderência dos modelos ao comportamento histórico do ENOS.

3. RESULTADOS E DISCUSSÃO

Os modelos de redes neurais artificiais demonstraram comportamento consistente em relação à defasagem temporal (*lag*), revelando uma tendência clara: quanto menor o horizonte de previsão, maior a acurácia preditiva. Essa relação inversa entre desempenho e *lag* foi observada de forma sistemática em todas as arquiteturas testadas (MLP, LSTM, RNN e CNN-LSTM), com destaque para os *lags* 1 e 2, que apresentaram os melhores resultados em termos de erro e correlação com a série real.

Avaliando as curvas de perda durante o treinamento, é possível observar que todos os modelos convergiram rapidamente, estabilizando o erro a partir da 10ª época. A maioria manteve bons níveis de generalização, com perdas de validação próximas das perdas de treinamento. A MLP, em especial, apresentou curvas mais regulares e com menor oscilação mesmo em *lags* mais longos, o que ajuda a explicar seu bom desempenho global. Esse comportamento pode ser visualizado na Figura 4, que exibe as curvas de perda de treino e validação para cada arquitetura e *lag*.

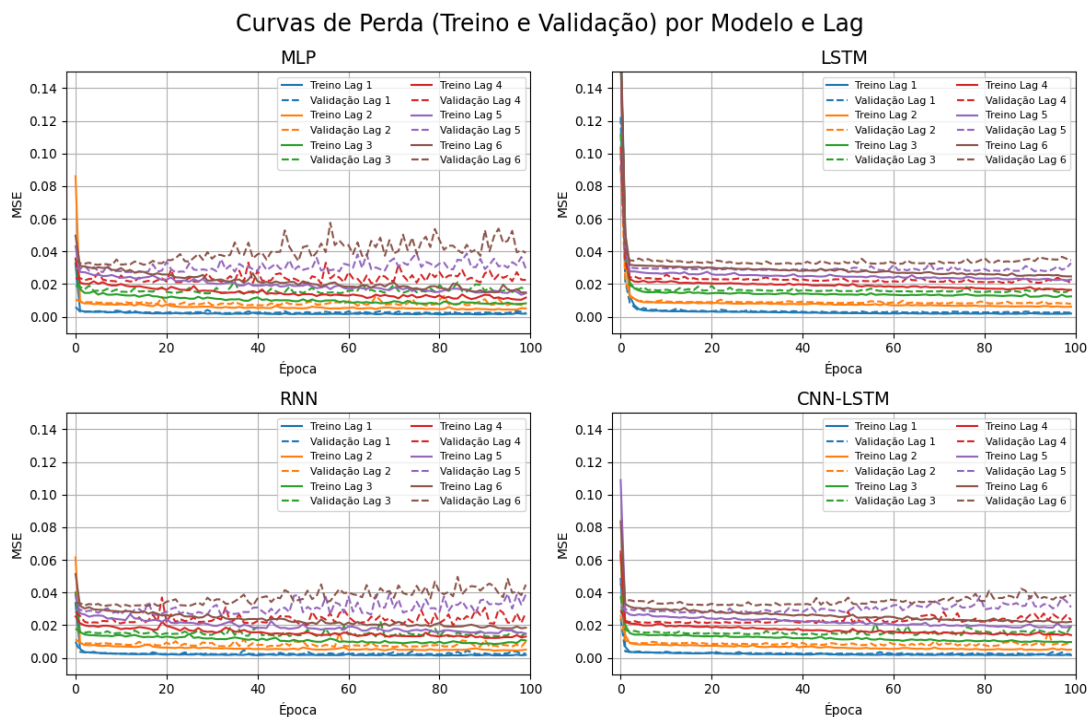


Figura 4 – Curvas de perda (erro quadrático médio) para treino e validação ao longo das épocas, para os modelos MLP, LSTM, RNN e CNN-LSTM, com defasagens variando de 1 a 6 meses.

Outro aspecto relevante observado nos experimentos é a ocorrência de *overfitting* em *lags* mais longos (≥ 4 meses). As curvas de perda mostram que, embora o erro de treinamento continue diminuindo, a perda de validação estabiliza ou até aumenta, sugerindo que os modelos passam a memorizar padrões espúrios da série histórica sem capacidade de generalização. Esse comportamento é consistente com a literatura, que destaca a redução da previsibilidade em horizontes mais distantes devido ao caráter caótico da interação oceano-atmosfera [6, 21]. Além disso, a chamada barreira de previsibilidade da primavera [9] contribui para agravar essa

limitação, tornando a acurácia dos modelos significativamente menor em *lags* superiores a três meses. Dessa forma, os resultados obtidos neste estudo reforçam que as redes neurais artificiais são eficazes no curto prazo, mas enfrentam sérios desafios quando aplicadas a previsões de médio a longo prazo.

Ao analisarmos diretamente as métricas de desempenho (MAE, RMSE e R^2), evidencia-se a superioridade da MLP nos *lags* mais curtos. No lag 1, esse modelo alcançou R^2 de 0,95, com MAE de 0,164 e RMSE de 0,209. Também teve o melhor desempenho no lag 2 ($R^2 = 0,83$) e no lag 5 ($R^2 = 0,32$). O LSTM, por sua vez, mostrou estabilidade em *lags* mais avançados, liderando nos lags 4 ($R^2 = 0,52$) e 6 ($R^2 = 0,20$). Já o RNN obteve o melhor resultado apenas no lag 3 ($R^2 = 0,64$), mas foi também o único modelo com resultado negativo em R^2 no lag 6 ($-0,04$), indicando limitação para previsões distantes. A Figura 5 sintetiza esses resultados quantitativos e permite a comparação direta entre arquiteturas.




Figura 5 – Desempenho dos modelos de redes neurais artificiais com base em três métricas (MAE, RMSE e R^2) para os diferentes lags de previsão do índice ONI.

Para compreender o comportamento qualitativo das previsões, a Figura 6 compara as séries previstas e observadas do índice ONI nos lags 1 e 6. No horizonte mais curto, os modelos são capazes de capturar com precisão picos e vales da série, inclusive eventos extremos como o El Niños de 1982–1983, 1997–1998 e 2015–2016. No lag 6, entretanto, as previsões tornam-se mais suaves, com perda de sincronia e redução da amplitude, dificultando a utilização em sistemas de alerta precoce.

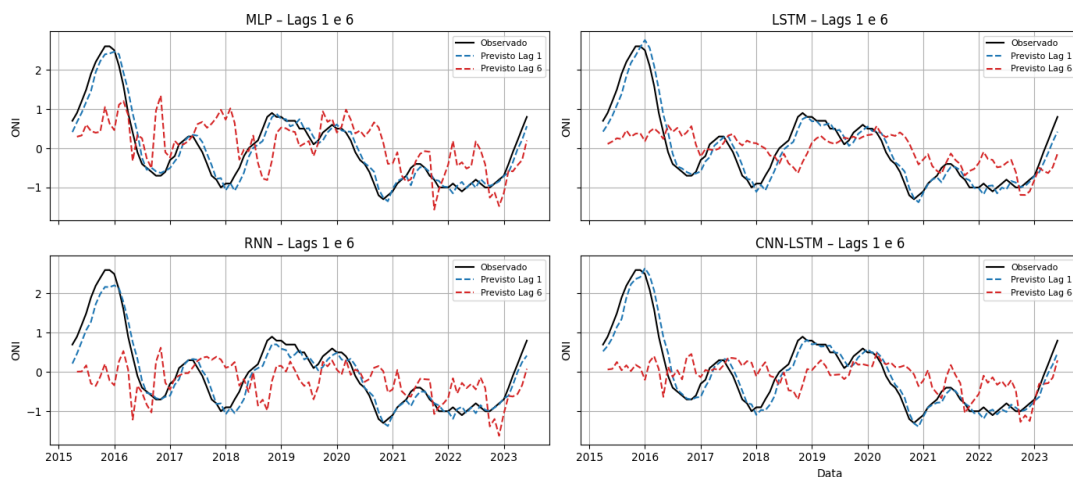


Figura 6 – Comparação entre os valores observados e previstos do índice ONI para os lags 1 e 6. Modelos reproduzem bem a série no curto prazo, mas perdem precisão e amplitude nas previsões de longo prazo.

Como forma complementar de avaliação, a Figura 7 apresenta os modelos com melhor desempenho em cada lag, segundo três métricas distintas: maior R^2 , menor MAE e menor RMSE. Essa abordagem permite identificar quais arquiteturas se destacaram em cada horizonte de

previsão e sob diferentes critérios de desempenho. Nota-se que a MLP apresentou o melhor coeficiente de determinação (R^2) nos dois primeiros lags, demonstrando forte capacidade de ajuste em previsões de curto prazo. Já o modelo LSTM destacou-se principalmente em lags mais longos, sendo o mais preciso em termos de erro médio absoluto (MAE) e raiz do erro quadrático médio (RMSE) no lag 6. A alternância entre os modelos, conforme a métrica e o horizonte considerado, reforça a importância de múltiplos critérios para uma avaliação equilibrada do desempenho preditivo.




Figura 7 – Modelos com desempenho superior por métrica e horizonte de previsão (lag). Cada barra representa a arquitetura com melhor resultado em termos de R^2 (mais alto), MAE e RMSE (mais baixos) para cada valor de lag. A alternância entre modelos reflete variações no desempenho conforme a métrica adotada e o horizonte de previsão.

Os resultados obtidos também encontram respaldo em outros estudos [21] que demonstraram que, mesmo com arquiteturas avançadas de *deep learning*, a previsibilidade do ENOS sofre forte limitação para horizontes superiores a seis meses. De forma semelhante, [6] revisaram o estado da arte e concluíram que a acurácia preditiva decai rapidamente com o aumento do lag, reforçando a dificuldade de superar a barreira de previsibilidade da primavera. Esses achados corroboram os resultados deste trabalho, que evidenciaram a queda acentuada no desempenho das redes neurais a partir do lag 4. Além disso, estudos como os de [3, 16] destacam que a intensificação do aquecimento global pode amplificar a frequência e a intensidade dos eventos extremos de ENOS, aumentando a importância de métodos preditivos robustos, mas também impondo novos desafios metodológicos.

4. APLICAÇÕES PRÁTICAS E LIMITAÇÕES

A previsão dos eventos ENOS por redes neurais artificiais antecipa as variações no índice ONI e abre caminho para a construção de sistemas de suporte à decisão baseados em aprendizado de máquina. Assim, modelos de previsão podem ser incorporados a plataformas já consagradas como ANA, INMET, CPTEC etc., de forma que os mesmos seriam combinados com entradas de diferentes fontes climáticas. Essa integração tecnológica é relevante para órgãos de planejamento hídrico e meteorológico e, dessa forma, um sistema de alerta baseado em limites probabilísticos poderá permitir o rastreamento contínuo da evolução dos padrões oceânicos.

Os modelos também podem ser adaptados para aplicações específicas por regiões, sendo treinados com dados localizados, o que ampliaria o uso em escala regional, como o gerenciamento de bacias hidrográficas, controle de queimadas, estimativa de produtividade agrícola sob influência do ENOS.

Assim, ainda que os modelos aqui testados demonstrem bom desempenho em curto prazo, o uso operacional em horizontes longos exige cautela, seja pela necessidade de variáveis adicionais (espaciais e multiescalares), seja pela integração de arquiteturas mais avançadas, como *Transformers*, que têm sido exploradas recentemente em modelagem climática.

Entretanto, há desafios metodológicos a se enfrentar. Em paralelo, a estrutura dos modelos é baseada em séries temporais unidimensionais, que limita a representação de padrões espaciais e

a propagação de anomalias. Incluir componentes multivariados com estrutura georreferenciada pode aumentar a generalização, principalmente para aplicações que exigem previsão regionalizada. Outro ponto crítico é a interpretação dos resultados: ainda que os modelos apresentem bons indicadores de desempenho, suas previsões podem ser pouco compreensíveis do ponto de vista físico, o que pode restringir a sua aceitação em ambientes operacionais mais conservadores.

Finalmente, o custo computacional também é um fator limitante significativo. Operacionalizar o treinamento de modelos requer infraestrutura robusta, composta por unidades de processamento gráfico (GPUs), unidades de armazenamento de alta velocidade e capacidade de paralelização. A manutenção de modelos baseados em séries temporais dinâmicas, como o índice ONI, requer atualizações periódicas e a revalidação dos parâmetros de entrada. Em alguns ambientes operacionais, torna-se ainda mais necessária a disponibilidade de dados em tempo quase real, além da integração com *pipelines* automatizados de ingestão, processamento e previsão.

5. CONCLUSÃO

Este estudo avaliou o desempenho de quatro arquiteturas de redes neurais artificiais — MLP, RNN, LSTM e CNN-LSTM — na previsão do índice ONI associado ao ENOS, considerando defasagens temporais (lags) de 1 a 6 meses.

Os resultados indicaram que todas as arquiteturas apresentam alta acurácia em horizontes de curto prazo (até 3 meses), com coeficientes de determinação (R^2) superiores a 0,93 no lag 1 e baixos valores de erro ($MAE < 0,19$ e $RMSE < 0,24$). A MLP mostrou robustez em lags curtos, enquanto a LSTM apresentou maior estabilidade em horizontes mais longos, ainda que com queda significativa de desempenho.

A análise evidenciou que previsões confiáveis do ENOS com base em redes neurais artificiais se restringem ao curto prazo, até três meses de antecedência. Para prazos superiores, observou-se perda sistemática de acurácia, associada tanto à defasagem temporal quanto à natureza caótica do sistema climático. Essa limitação reforça a necessidade de explorar variáveis adicionais (ex.: componentes espaciais) e arquiteturas mais avançadas em estudos futuros.

Adicionalmente, destaca-se que o ENOS está inserido em um sistema dinâmico e multifatorial, sensível a interações atmosféricas e oceânicas em escalas globais. Fatores externos, como a variabilidade da irradiância solar, podem desempenhar papel importante na modulação do fenômeno, sendo recomendada, em estudos futuros, a incorporação de variáveis associadas à radiação solar (como TSI, proxies solares ou padrões de atividade solar), o que pode ampliar o horizonte útil de previsão dos modelos.

Assim, a principal contribuição deste trabalho foi demonstrar, de forma comparativa, a influência do horizonte de previsão sobre o desempenho das redes neurais artificiais na modelagem do ENOS, delimitando o potencial e as limitações práticas dessas ferramentas no contexto climático.

Por fim, recomenda-se a continuidade da pesquisa com a ampliação da base de dados, o uso de abordagens multivariadas com integração de componentes espaciais, e a exploração de arquiteturas mais avançadas, como *Transformers* e redes híbridas, que têm apresentado resultados promissores na modelagem de séries temporais climáticas complexas.

6. AGRADECIMENTOS

Os autores agradecem à Universidade Estadual de Campinas (Unicamp), em especial ao Departamento de Recursos Hídricos da Faculdade de Engenharia Civil, Arquitetura e Urbanismo, pelo suporte técnico e acadêmico ao longo do desenvolvimento desta pesquisa. Agradecem também à Universidade do Estado de Mato Grosso (UNEMAT), pelo incentivo à produção científica e à formação continuada. Por fim, expressam sua gratidão à Comissão Organizadora do 8º Simpósio sobre Sistemas Sustentáveis (8SSS), pela oportunidade de divulgar este trabalho em um espaço de relevância científica e interdisciplinar.

7. REFERÊNCIAS BIBLIOGRÁFICAS

1. Rasmusson EM, Carpenter TH. Variations in tropical sea surface temperature and surface wind fields associated with the Southern Oscillation/El Niño. *Monthly Weather Rev.* 1982;110(5):354-84.
2. McPhaden MJ, Zebiak SE, Glantz MH. ENSO as an integrating concept in Earth science. *Science.* 2006;314:1740-5. doi: 10.1126/science.1132588
3. Cai W, Santoso A, Wang G, Yeh SW, An SI, Cobb KM, et al. ENSO and greenhouse warming. *Nat Clim Chang.* 2015;5:849-59. doi: 10.1038/nclimate2743
4. Trenberth KE, Branstator GW, Karoly D, Kumar A, Lau NC, Ropelewski J. Progress during the TOGA decade in understanding and modeling global teleconnections associated with ENSO. *J Clim.* 1998;11(5):1089-111.
5. Grimm AM. Interannual climate variability in South America: impacts on seasonal precipitation, extreme events and possible effects of climate change. *Stoch Environ Res Risk Assess.* 2011;25:537-54. doi: 10.1007/s00477-010-0420-1
6. Zhang RH, Gao C, Feng L. Recent ENSO evolution and its real-time prediction challenges. *Nat Sci Rev.* 2022;9(4):nwac052. doi: 10.1093/nsr/nwac052
7. Assad ED, Oliveira AF, Nakai AM, Pavão E, Pellegrino G, Monteiro JE. Impactos e vulnerabilidades da agricultura brasileira às mudanças climáticas. In: Brasil. Ministério da Ciência, Tecnologia e Inovação (MCTI), Secretaria de Políticas e Programas de Pesquisa e Desenvolvimento, Coordenação-Geral de Mudanças Globais de Clima. Modelagem climática e vulnerabilidades Setoriais à mudança do clima no Brasil. Brasília (DF): MCTI; 2016 p. 127-87. Disponível em: https://repositorio.enap.gov.br/bitstream/1/8030/7/ModelagemClimticaeVulnerabilidadeSetoriaisMudanadoClimanoBrasil_compressed.pdf.
8. Bellenger H, Guilyardi É, Leloup J, Lengaigne M, Vialard J. ENSO progression and diversity in 20th century simulations from CMIP5. *J Clim.* 2014;27(3):1097-114.
9. Webster PJ. The annual cycle and the predictability of the tropical coupled ocean-atmosphere system. *Meteorol Atmos Phy.* 1995;56(1-2):33-55.
10. Tominaga LK, Santoro J, Amaral R, organizadores. Desastres naturais: conhecer para prevenir. 3. ed. São Paulo: Instituto Geológico; 2015. Disponível em: https://www.infraestruturameioambiente.sp.gov.br/wp-content/uploads/sites/233/2017/05/Conhecer_para_Prevenir_3ed_2016.pdf.
11. Operador Nacional do Sistema Elétrico (ONS). Nota Técnica – NT-ONS DGL 0031/2022 – Análise da situação hidrológica: Avaliação das condições do SIN em função do risco hidrológico. Brasília (DF): ONS; abr 2020 [acesso em 18 jul 2025]. Disponível em: <https://share.google/zgAGfPCgCH4OsXm94>.
12. Bjerknes J. Atmospheric teleconnections from the equatorial Pacific. *Mon Weather Rev.* 1969;97(3):163-172.
13. National Oceanic and Atmospheric Administration (NOAA). Oceanic Niño Index (ONI); 2023 [acesso em 22 jul 2025]. Disponível em: https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php.
14. Lean JL, Rind DH. How natural and anthropogenic influences alter global and regional surface temperatures: 1889 to 2006. *Geophys Res Lett.* 2008;35(18):L18701. doi: 10.1029/2008GL034864
15. Meehl GA, Arblaster JM, Matthes K, Sassi F, van Loon H. Amplifying the Pacific climate system response to a small 11-year solar cycle forcing. *Science.* 2009;325(5944):1114-8. doi: 10.1126/science.1172872
16. Santoso A, McPhaden MJ, Cai W. The defining characteristics of ENSO extremes and the strong 2015/2016 El Niño. *Rev Geophys.* 2017;55:1079-129. doi: 10.1002/2017RG000560
17. Liu Z, Coleman N, Patrascu FI, Yin K, Li X, Mostafavi A. Artificial intelligence for flood risk management: A comprehensive state-of-the-art review and future directions. *Int J Disaster Risk Reduct.* 2025;116:105122. doi: 10.2139/ssrn.5008577
18. Chen M, Challita U, Saad W, Yin C, Debbah M. Artificial neural networks-based machine learning for wireless networks: A tutorial. *IEEE Commun Surv Tutor.* 2019;21(4):3039-71. doi: 10.1109/COMST.2019.2926625
19. Dastres R, Soori M. Artificial Neural Network Systems. *Int J Imaging Robot.* 2021;21(2):13-25.
20. Aydin C, Caliskan H. Artificial intelligence approaches for flood prediction and monitoring. In: Singh D, Elkhatab Y, Hussain I, editors. *Intelligent and cloud computing*. Singapore: Springer. 2022. p. 35-46.
21. Ham YG, Kim JH, Luo JJ. Deep learning for multi-year ENSO forecasts. *Nature.* 2019;573:568-72. doi: 10.1038/s41586-019-1559-7