

USO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL (*DEEP LEARNING*) PARA PREVISÃO METEOROLÓGICA EM REGIÕES POLARES: APLICAÇÕES EM OPERAÇÕES AÉREAS NA ANTÁRTICA

Artificial intelligence (deep learning) models for weather forecasting in polar regions: applications in flight operations in Antarctica

Alana de Lima Pontes Gadelha¹

Resumo: Este trabalho teve como objetivo desenvolver ferramentas de apoio aos modelos numéricos operacionais de previsão do tempo, a fim de contribuir para previsões mais precisas em operações aéreas nas regiões polares. A motivação está ligada ao Programa Antártico Brasileiro (PROANTAR), que depende de informações meteorológicas confiáveis para garantir a segurança de pousos, decolagens e demais atividades logísticas e científicas na região. Para tanto, investigou-se o uso de modelos de *Deep Learning* aplicados à previsão horária da temperatura do ar à superfície no Aeródromo SCRM, na Antártica, utilizando quase 15 anos de observações METAR. O pré-processamento incluiu a transformação de variáveis temporais e da direção do vento, a fim de capturar sua natureza cíclica. Foram avaliados um modelo heurístico de referência (*baseline*), MLP, CNN, LSTM e BiLSTM. Entre eles, a BiLSTM apresentou o melhor desempenho, obtendo os menores erros e destacando-se pela capacidade de capturar dependências temporais de longo prazo em padrões meteorológicos complexos. Além disso, as previsões foram comparadas às saídas do modelo numérico de última geração ICON-LAM. Embora o ICON-LAM tenha demonstrado alta acurácia, a BiLSTM apresentou resultados competitivos, com custo computacional significativamente menor. Esses achados reforçam que a implementação operacional da Inteligência Artificial (IA) representa inovação disruptiva para as Forças Armadas, demonstrando que modelos de *Deep Learning* baseados em memória podem atuar como ferramentas complementares aos modelos numéricos tradicionais, apoiando a previsão do tempo e ampliando a segurança operacional em aeródromos remotos da Antártica.

Palavras-chave: Inteligência Artificial. Previsão. Antártica. ICON-LAM.

Abstract: This study aimed to develop support tools for operational numerical weather prediction models, contributing to more accurate forecasts that can be directly applied to flight operations in polar regions. The motivation is closely linked to the Brazilian Antarctic Program (PROANTAR), which depends on reliable meteorological information to ensure the safety of landings, takeoffs, and other logistical and scientific activities in Antarctica. To this end, the use of Deep Learning models was investigated for hourly forecasting of surface air temperature at the SCRM Aerodrome in Antarctica, using nearly 15 years of METAR observational data. Preprocessing included the transformation of temporal variables and wind direction to capture their cyclical nature. The evaluated models comprised a baseline heuristic, MLP, CNN, LSTM, and BiLSTM. Among them, the BiLSTM achieved the best performance, yielding the lowest errors and standing out for its ability to capture long-term temporal dependencies in complex weather patterns. Furthermore, forecasts were compared with outputs from the state-of-the-art ICON-LAM numerical model. While ICON-LAM demonstrated high accuracy, the BiLSTM provided competitive results with significantly lower computational cost. These findings highlight that the operational implementation of Artificial Intelligence (AI) represents a disruptive innovation for the armed forces, demonstrating that memory-based Deep Learning models can serve as complementary tools to traditional numerical models, supporting weather forecasting and enhancing operational safety at remote aerodromes in Antarctica.

Keywords: Artificial Intelligence. Forecasting. Antarctica. ICON-LAM.

1. Capitão de Corveta do Centro de Hidrografia da Marinha. Doutoranda na Universidade Federal Fluminense, Niterói, RJ - Brasil. E-mail: alana@marinha.mil.br, alanaipg@id.uff.br

1. INTRODUÇÃO

Muitos estudos têm explorado a aplicação de técnicas de *Deep Learning* à previsão do tempo. No entanto, ainda existe uma lacuna importante quanto à avaliação de sua eficácia em previsões localizadas e pontuais (XU, 2024). Previsões meteorológicas confiáveis são essenciais para o planejamento de operações aéreas, a mitigação de riscos e a otimização de recursos, aumentando a eficiência e a segurança operacional (ZHANG et al., 2025). Tradicionalmente, a previsão do tempo é realizada por meio de modelos de Previsão Numérica do Tempo (*Numerical Weather Prediction* – NWP), baseados em equações físicas que descrevem a atmosfera. Embora robustos, esses modelos apresentam limitações, como a necessidade de grande poder computacional, dificuldades na exploração de grandes volumes de dados observacionais e compreensão parcial de certos processos físicos. Nesse contexto, métodos de *Deep Learning* emergem como alternativas promissoras, capazes de capturar relações complexas e não lineares nos dados meteorológicos, além de reduzir o custo computacional.

A motivação deste estudo reside no desafio de prever, com alto grau de confiabilidade, variáveis meteorológicas essenciais para a segurança das operações aéreas no continente antártico. Em especial, destaca-se a temperatura do ar à superfície, variável crítica por influenciar diretamente os processos de congelamento de pistas, impactando pouso e decolagens, além de estar associada a eventos extremos, como neve e chuva. Para tal, foi utilizada uma série temporal de mais de 15 anos de observações do Relatório Meteorológico de Aeródromo (*Meteorological Aerodrome Report* – METAR) provenientes da estação meteorológica automática do Aeródromo Tenente Rodolfo Marsh Martin (SCRM)¹, localizado na Base Presidente Eduardo Frei Montalva, na Antártica. Esse aeródromo constitui peça estratégica de apoio logístico a diversas nações, incluindo o Brasil, sendo fundamental para o transporte de pessoas e suprimentos à Estação Antártica Comandante Ferraz (EACF), no âmbito do Programa Antártico Brasileiro (PROANTAR).

¹ código ICAO é uma designação de quatro letras usada globalmente para identificar aeroportos, atribuída pela Organização da Aviação Civil Internacional (*International Civil Aviation Organization* – ICAO)

Além das operações aéreas, a previsão precisa da temperatura é igualmente necessária para a execução de todas as atividades *outdoor* — isto é, realizadas fora das bases de pesquisa ou dos navios de apoio antártico durante a Operação Antártica (OPERANTAR). Essas operações não são apenas desejáveis, mas obrigatórias, dado o risco à sobrevivência em condições extremas. A pesquisa com modelos de *Deep Learning* sugeridos neste estudo fornecerá apoio direto aos previsores do Serviço Meteorológico Marinho (SMM) do Centro de Hidrografia da Marinha (CHM), responsáveis pela elaboração diária dos boletins de previsão para a EACF. Tal contribuição alinha-se ao Plano Estratégico da Marinha (PEM 2040), que estabelece como prioridade a manutenção da capacidade logística de apoio à pesquisa científica naquela região. Pela simplicidade de sua operacionalização, a metodologia desenvolvida pode igualmente beneficiar outros Serviços Meteorológicos Operacionais.

2. OBJETIVOS

O objetivo principal deste estudo foi propor o uso operacional de modelos de inteligência artificial (IA), especificamente modelos de *Deep Learning*, como ferramentas complementares aos modelos numéricos, contribuindo para uma melhor previsão do tempo e para a segurança operacional nos aeródromos de regiões polares remotas. Além deste, destacam-se os seguintes objetivos: (i) desenvolvimento de técnicas de pré-processamento de dados meteorológicos provenientes de estações automáticas; e (ii) análise comparativa entre os modelos de IA e o modelo numérico *Icosahedral Nonhydrostatic-Limited Area Mode* (ICON-LAM), visando à redução de custo computacional para previsões de variáveis meteorológicas locais.

3. MATERIAL E MÉTODOS

3.1 REFERENCIAL TEÓRICO

3.1.1 Modelo Numérico ICON-LAM

O modelo ICON-LAM (IRIZA-BURCĂ et al., 2024) foi desenvolvido pelo Serviço Meteorológico Alemão (*Deutscher*

Wetterdienst – DWD), em conjunto com o Instituto Max Planck de Meteorologia, com o objetivo de oferecer um sistema unificado para previsões meteorológicas globais e regionais, além de aplicações climáticas. Sua estrutura baseia-se em uma grade icosaédrica que evita os problemas das singularidades dos polos dos modelos em latitude-longitude. Isso favorece uma representação mais homogênea do globo e facilita a paralelização eficiente em supercomputadores (DEUTSCHER WETTERDIENST, 2024). O ICON-LAM é um modelo não-hidrostatico, o que o torna adequado para simulações de alta resolução, capturando melhor processos atmosféricos verticais, como convecção.

No CHM, a modelagem atmosférica é fruto dessa parceria eficaz com o DWD. O modelo encontra-se no estado da arte dos modelos numéricos e está operacional no CHM, com execuções diuturnas (00 e 12 GMT)² para a região da Antártica, com resoluções espaciais de 6,5 e 2,1km.

3.1.2 Modelos de Deep Learning

Deep learning é uma abordagem de aprendizado de máquina que utiliza redes neurais profundas (com múltiplas camadas), capazes de identificar automaticamente padrões complexos e dinâmicas não lineares em grandes volumes de dados, especialmente em ambientes complexos e de alta dimensionalidade, como os dados meteorológicos (ZHANG et al., 2025). Os *Multilayer Perceptron* (MLP) são modelos fundamentais de aprendizado profundo e servem como base conceitual para redes neurais recorrentes (*recurrent neural networks* – RNN), que são mais adequadas para dados sequenciais, como séries temporais. Sua principal limitação está na ineficiência em capturar dependências temporais. As redes neurais convolucionais (*convolutional neural networks* – CNN) são um tipo especializado de rede neural para processamento de dados com topologia em forma de grade e têm como objetivo extrair padrões locais recorrentes, como ciclos ou tendências de curto prazo, porém apresentam limitação ao lidar com dependências de longo prazo (SONG et al., 2025). As RNNs possuem estruturas aprimoradas, como as *long short-term memory* (LSTMs) e as *bidirectional long short-term memory* (BiLSTMs), métodos

amplamente utilizados em aprendizado de sequências e previsão de séries temporais (KAREVAN; SUYKENS, 2018). As BiLSTMs estendem as LSTMs tradicionais ao processar a sequência nos dois sentidos: do passado para o futuro e do futuro para o passado, percorrendo os dados de entrada duas vezes e capturando informações tanto prospectivas quanto retrospectivas (ZHANG; HUO; SHAO, 2023), permitindo ao modelo uma visão mais completa do contexto de cada ponto na sequência e melhorando a precisão em tarefas como previsão de séries temporais.

Neste estudo, foi utilizada a biblioteca de *software TensorFlow*, descrita em Géron (2019), e adotadas as seguintes configurações, comumente descritas como hiperparâmetros para modelos de *Deep Learning*: 20 épocas, ou seja, 20 ciclos completos de treinamento para todos os modelos descritos, e erro quadrático médio (*mean squared error* – MSE) como função de custo (*loss function*). Como *baseline*, foi escolhido o modelo *autoregressive integrated moving average* (ARIMA), que representa uma das abordagens estatísticas mais tradicionais para modelagem e previsão de séries temporais univariadas (BABU; KRISHNA; VAIDEHI, 2023). O modelo serviu apenas como base de comparação e foi utilizado para prever apenas um passo à frente, ou seja, um valor futuro de temperatura com base na última observação. O modelo MLP utilizou duas camadas ocultas (*fully connected*) com 32 neurônios cada, além da função de ativação não linear (*rectified linear unit* – ReLU). A última camada foi configurada com apenas um neurônio, por se tratar de uma tarefa de regressão. O modelo CNN foi executado com uma camada de convolução, com *kernel* de tamanho 3 e sem *padding*. A rede neural recorrente LSTM foi treinada com uma camada oculta unidirecional de 32 neurônios e um neurônio na camada de saída. A última rede treinada, a BiLSTM, apresentou uma camada oculta bidirecional de 32 neurônios, totalizando 64 neurônios na saída (32 no sentido direto e 32 no sentido reverso).

3.1.3 Métricas de Erro de Previsão utilizadas

Para mensurar, de forma objetiva, o desempenho da previsão de temperatura do modelo proposto neste estudo, foram utilizadas quatro métricas de desempenho (Tabela 1), em que (\hat{Y}_i) representam os valores previstos, (Y_i) os valores observados reais e (n) o número total de observações, correspondente ao tamanho da sequência analisada.

² *Greenwich Mean Time* (GMT) é o horário médio local no Observatório Real de Greenwich, Londres, contado a partir da meia-noite.

3.2 ESTRATÉGIAS DE PRÉ-PROCESSAMENTO

3.2.1 Coleta e tratamento dos dados da série temporal da estação automática

A fase de pré-processamento envolve normalização, transformação e tratamento de valores omissos. Os dados utilizados foram coletados na estação meteorológica automática do aeroporto SCRM, denominados METAR. Esses dados são decodificados, conforme ilustrado na Figura 1, e convertidos para o formato de séries temporais, a fim de possibilitar melhor visualização e compreensão dos padrões atmosféricos observados. Neste estudo, os dados foram baixados *online*, por meio da biblioteca do *Python Meteostat*³. A série temporal totaliza mais de 15 anos de dados, iniciando em 1º de janeiro de 2010 e encerrando em 30 de junho de 2025. A Figura 2 apresenta o comportamento anual da temperatura. De posse desses dados, iniciou-se a fase exploratória com o intuito de identificar a distribuição das variáveis

meteorológicas, por meio de gráfico de correlação, e verificar quais delas apresentavam maior associação. O pré-processamento demonstrou que as variáveis temperatura do ponto de orvalho e umidade relativa apresentaram as maiores correlações. Todos os gráficos e experimentos realizados neste

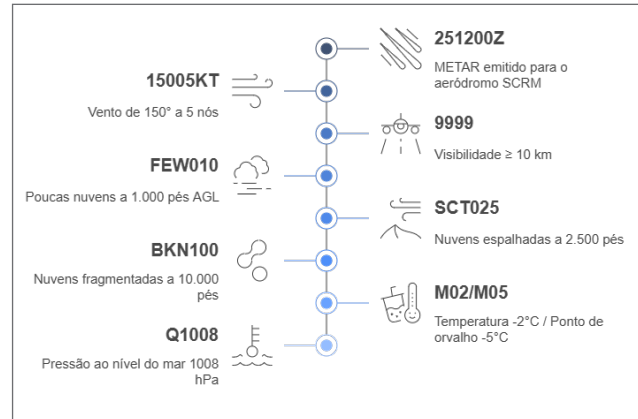


Figura 1. Exemplo de decodificação de uma mensagem METAR (visualização gerada pelo <https://www.napkin.ai/>).

Tabela 1. Métricas de erro de previsão.

Métrica	Definição	Fórmula
Erro quadrático médio (MSE)	Mede a média dos quadrados das diferenças entre valores observados e previstos.	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
Erro absoluto médio (<i>mean absolute error</i> - MAE)	Representa a média das diferenças absolutas entre valores observados e previstos.	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
Erro percentual absoluto médio (<i>mean absolute percentagem error</i> - MAPE)	Expressa o erro médio em termos percentuais, facilitando a interpretação da precisão do modelo.	$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $
Raiz do erro quadrático médio (<i>root mean square error</i> - RMSE)	Calcula a raiz quadrada da média dos erros quadráticos, mantendo a métrica na mesma unidade da variável prevista	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$




Figura 2. Série temporal da temperatura do ar a 2 metros (normalizada), no aeroporto SCRM, na Antártica.

³ *Python library-Meteostat*: <https://dev.meteostat.net/python/#installation>.

estudo podem ser acessados em Gadelha (2025). A direção do vento apresentou correlação positiva, porém necessita ser convertida para radianos para uso adequado em modelos de *Deep Learning*.

Como direções angulares (0° – 360°) não são ideais como entrada, utilizou-se a conversão em componentes vetoriais (X , Y) por meio de funções trigonométricas, após transformação de graus para radianos. Por se tratar de dado meteorológico, a direção indica de onde o vento provém (0° = norte), sendo necessária sua conversão para o formato cartesiano. De modo semelhante, o tempo (em segundos) também não constitui uma entrada adequada para algoritmos de *Deep Learning*, pois apresenta natureza cíclica, com padrões diários e sazonais bem definidos, não capturados por representações lineares. Por exemplo, os horários 2023-01-01 08:00:00 e 2024-01-01 08:00:00 correspondem à mesma hora do dia, embora estejam separados por milhares de segundos. Para resolver essa limitação, aplicaram-se transformações senoidais e cossenoidais, conforme fórmula apresentada, que mapeiam o tempo no círculo trigonométrico. Essa codificação temporal foi aplicada tanto para a hora do dia (ciclo de 24 horas) quanto para o dia do ano (ciclo de 365 dias).

$$\sin\left(2\pi \cdot \frac{t}{\text{Período}}\right), \quad \cos\left(2\pi \cdot \frac{t}{\text{Período}}\right)$$

Por fim, realizou-se a normalização dos dados, etapa essencial no pré-processamento para *Deep Learning*. A normalização assegura que todos os atributos (variáveis) estejam na mesma escala, evitando que magnitudes elevadas dominem o treinamento do modelo. A técnica aplicada foi a padronização (*z-score*), cuja fórmula é: atributo normalizado = atributo - média / desvio padrão.

3.2.2 Extração da série temporal do Modelo ICON-LAM

Neste trabalho, foi utilizado o modelo numérico ICON-LAM na sua versão regional, com resolução espacial de 6,5 km, aplicado à Região Antártica. A grade utilizada possui dimensões de 1.201 x 1.121 pontos, abrangendo latitudes de $-56,00^{\circ}$ a $14,00^{\circ}$ e longitudes de $270,00^{\circ}$ a $345,00^{\circ}$. A extração da série temporal foi realizada para o ponto geográfico de latitude $-62,1917^{\circ}$ e longitude $-58,9867^{\circ}$, correspondente à localização do aeroporto SCRM, com o objetivo de obter dados o mais próximos possível da estação meteorológica

automática. Para essa comparação, foi extraída uma série de um ano e seis meses de dados horários.

4. RESULTADOS

Para os modelos de *Deep Learning*, foram utilizados os dados do METAR (15 anos de dados, após a etapa de pré-processamento), divididos em dados de treinamento, validação e teste, na proporção de 70% (aproximadamente 10 anos e 6 meses de dados), 20% (cerca de 3 anos de dados) e 10% (aproximadamente 1 ano e 6 meses de dados), respectivamente. Na pesquisa, foi implementada uma janela de tempo deslizante. Essa técnica é amplamente utilizada na modelagem de séries temporais para transformar dados sequenciais em formato supervisionado. Consiste em segmentar a série original em subsequências de tamanho fixo, correspondentes a intervalos de observações passadas, que constituem os dados de entrada (*inputs*) utilizados para prever um ou mais valores futuros (*outputs*). À medida que a janela desliza ao longo do tempo, múltiplos pares de entrada e saída são gerados. Essa abordagem é particularmente eficaz na preparação de dados para modelos de aprendizado profundo, como redes neurais convolucionais e recorrentes, pois permitem que dependências temporais sejam aprendidas de forma robusta e estruturada. Os quatro (4) modelos foram treinados utilizando janelas deslizantes com diferentes comprimentos temporais (3, 6, 12, 24 e 48 horas), empregadas simultaneamente como horizonte de entrada e de saída em cada conjunto (*batch*) de treinamento. Observou-se que, em alguns modelos, a utilização do maior comprimento de janela (48 horas de dados de entrada e 12 horas de previsão) favoreceu o desempenho preditivo, possivelmente em razão da maior disponibilidade de informações temporais relevantes. A Figura 3 apresenta um (1) exemplo aleatório de previsão horária de temperatura do ar realizada pelos modelos de *Deep Learning* e pelo ICON-LAM, referente ao dia 04 de junho de 2024, entre 09 e 18 horas, com horizonte total de previsão de 10 horas.

Embora a LSTM tenha apresentado ótimos resultados, a BiLSTM obteve o melhor desempenho, destacando-se nas métricas MAE, MAPE e RMSE (Figura 4). Esse resultado pode ser atribuído à sua arquitetura bidirecional, que permite ao modelo acessar tanto o passado quanto o futuro dentro

da janela de entrada. Tal característica é especialmente vantajosa em problemas de previsão meteorológica, nos quais as relações entre variáveis não dependem apenas do histórico recente, mas também de padrões que se repetem ao longo do tempo. Em comparação com os demais modelos, como o *Baseline*, a MLP e até mesmo as CNN, as redes recorrentes profundas mostraram-se mais adequadas para capturar a complexidade inerente às séries temporais de temperatura na região da Antártica. A última série avaliada foi a do modelo ICON-LAM, cuja série temporal extraída correspondeu a

1 ano e 6 meses de dados previstos de temperatura do ar a 2 metros, comparados em diversos momentos com os dados reais observados (extraídos do METAR), além dos dados obtidos com os modelos de *Deep Learning*. O ICON-LAM já apresenta ótimos resultados em relação aos dados observados (Figura 3); entretanto, as redes neurais recorrentes, em especial a BiLSTM, mostraram-se competitivas e capazes de prever valores mais próximos dos observados. Neste estudo, o ICON-LAM apresentou desvantagem quanto ao tempo de processamento: 37 minutos, em comparação com 10 minutos




Figura 3. Comparação dos modelos de *Deep Learning* para uma janela de previsão de 10 horas à frente, em comparação com os dados reais observados e com os dados previstos pelo modelo numérico ICON-LAM.

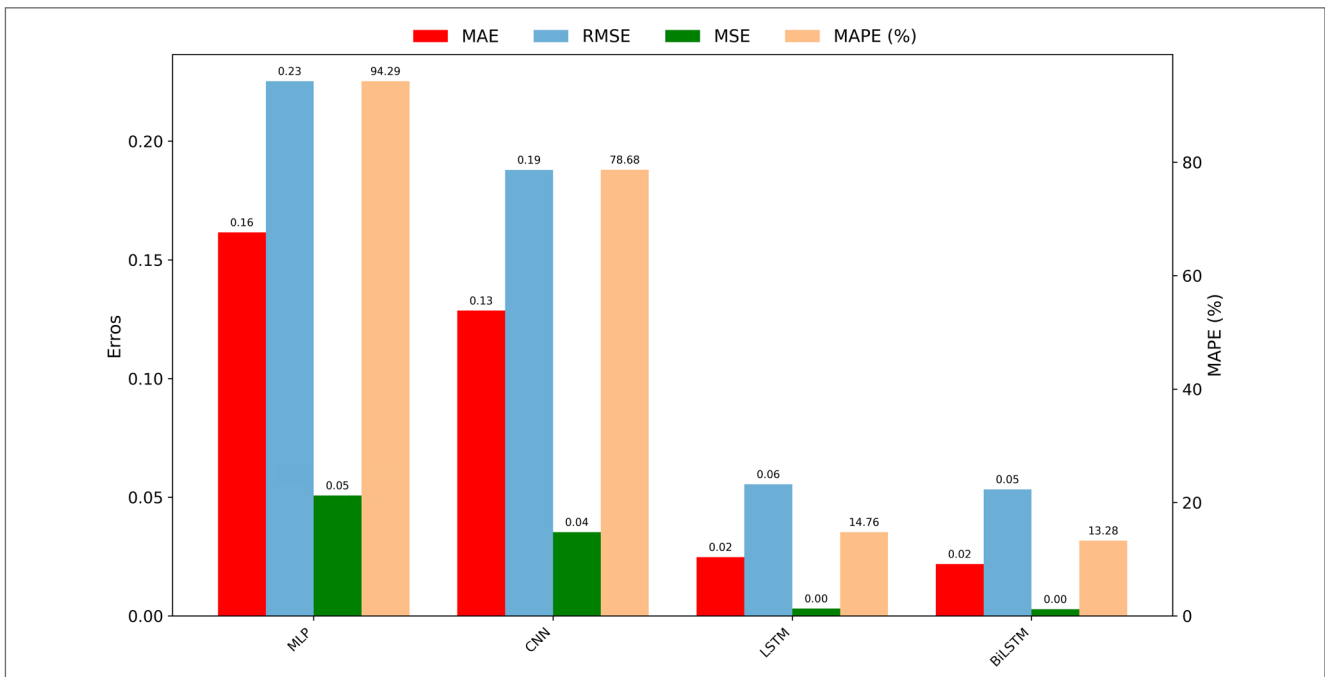


Figura 4. Métricas de erro dos modelos de *Deep Learning*.

da BiLSTM. Ressalta-se, contudo, que o tempo da execução do modelo refere-se a uma área conforme descrito na seção “Extração da série temporal do Modelo ICON-LAM” e a múltiplas variáveis.

Outra preocupação deste trabalho foi registrar os tempos de execução do treinamento e do teste/inferência, conforme apresentado na Tabela 2, o que evidencia a necessidade de utilização de *graphics processing unit* (GPU) e de supercomputadores para execuções operacionais, caso o objetivo seja reduzir o tempo de processamento. Entretanto, para a realização deste trabalho, todos os experimentos foram conduzidos em ambiente *Google Colab* (GADELHA, 2025), inclusive com a utilização de GPU.

5. CONCLUSÃO

Este trabalho propõe uma mudança de paradigma no que concerne à previsão de variáveis meteorológicas em aeródromos. Os resultados evidenciaram o potencial do uso de modelos de IA (*Deep Learning*) como ferramentas complementares aos modelos numéricos atmosféricos operacionais, especialmente para aplicações em regiões remotas e sensíveis, como a Antártica. O estudo avaliou diferentes abordagens para a previsão de temperatura horária no aeroporto SCRM, comparando modelos tradicionais, como o ARIMA, e arquiteturas de redes neurais profundas, como MLP, CNN, LSTM e BiLSTM. Os experimentos demonstraram que as redes recorrentes, especialmente a BiLSTM, apresentaram desempenho significativamente superior nas métricas de erro (MAE, MAPE e RMSE), destacando sua capacidade de capturar dependências temporais de longo prazo e padrões sazonais. Além da comparação entre os modelos de *Deep Learning*, os resultados foram confrontados com previsões

produzidas pelo modelo numérico regional ICON-LAM, o qual demonstrou alta aderência aos dados observados. Ainda assim, a BiLSTM apresentou desempenho competitivo, com previsões próximas às observadas, sendo executada em apenas 10 minutos. A implementação operacional de modelos de IA nas Forças Armadas representa uma inovação disruptiva e já se mostra viável em termos de aplicabilidade prática. Os experimentos realizados neste estudo foram conduzidos em conta gratuita do *Google Colab*, evidenciando que a execução dos modelos não exige necessariamente o uso de supercomputadores. Isso demonstra que tais ferramentas podem ser empregadas de forma acessível e com baixo custo computacional. A partir dessa experiência inicial, vislumbra-se a expansão do uso desses modelos para outros aeródromos, bem como a extensão da abordagem a diferentes variáveis meteorológicas, essenciais para operações de pouso e decolagem no continente Antártico. Essa evolução tecnológica apresenta potencial para promover avanços significativos na previsão do tempo em regiões polares, nas quais a precisão das informações meteorológicas é determinante para a segurança e a eficiência operacional.

AGRADECIMENTOS

Agradece-se à Marinha do Brasil, representada pela Diretoria de Hidrografia e Navegação (DHN) e pelo Centro de Hidrografia da Marinha (CHM), pelo tempo concedido para a realização desta pesquisa. Registra-se reconhecimento especial aos Professores Lúcia Maria de Assumpção Drummond e Leandro Santiago de Araújo, do Instituto de Computação (IC) da Universidade Federal Fluminense (UFF), pelos valiosos ensinamentos e orientações sobre Inteligência Artificial, sem os quais este trabalho não teria sido possível.

Tabela 2. Tempos de execução, em segundos, para treinamento e testes/inferências dos modelos, em Central Processing Unit (CPU) e Graphics Processing Unit (GPU).

Modelo	Treino CPU	Treino GPU	Teste CPU	Teste GPU
ARIMA (<i>Baseline</i>)	0,032	0,018	1,136	1,097
MLP (24 <i>Inputs</i>)	73,618	62,407	1,141	2,614
CNN (3 <i>Inputs</i>)	119,969	95,317	1,125	1,612
LSTM (12 <i>Inputs</i>)	1038,652	635,180	2,968	1,742
BiLSTM (24 <i>Inputs</i>)	1829,633	580,637	3,867	2,074

REFERÊNCIAS

- BABU, A. R.; KRISHNA, G.; VAIDEHI, V. Hybrid deep learning model for multivariate time series forecasting. *IEEE Access*, v. 11, p. 13817-13828, 2023.
- DEUTSCHER WETTERDIENST (DWD). *ICON Tutorial 2024: A comprehensive guide to the Icosahedral Nonhydrostatic (ICON) modeling framework*. 2024. Disponível em: <https://www.dwd.de/>. Acesso em: 29 jul. 2025.
- GADELHA, A. *Código-fonte do projeto de previsão de temperatura na Antártica*. 2025. Disponível em: https://github.com/alanagadelha/DeepLearning_AntarticaWork/tree/main. Acesso em: 18 ago. 2025.
- GÉRON, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems*. 2. ed. Sebastopol, CA: O'Reilly Media, 2019. Disponível em: <https://www.oreilly.com/library/view/hands-on-machine-learning/9781492032632/>. Acesso em: 23 ago. 2025.
- IRIZA-BURCĂ, D.; DUMITRACHE, R. C.; MACO, B. A.; HUȘTIU, M.; FUNDEL, F.; RIEGER, D.; POTTHAST, R. Comparison of COSMO and ICON-LAM high-resolution numerical forecast for Romanian territory: case studies and evaluation. *Atmosfera*, v. 38, p. 421-451, 2024. <https://doi.org/10.20937/ATM.53305>
- KAREVAN, Z.; SUYKENS, J. A. Spatio-temporal stacked LSTM for temperature prediction in weather forecasting. *arXiv preprint*, arXiv:1811.06341, 2018. Disponível em: <https://arxiv.org/abs/1811.06341>. Acesso em: 23 ago. 2025.
- SONG, X.; DENG, L.; WANG, H.; ZHANG, Y.; HE, Y.; CAO, W. Deep learning-based time series forecasting: a review. *Artificial Intelligence Review*, v. 58, n. 23, 2025. <https://doi.org/10.1007/s10462-024-10989-8>
- XU, M. Comparative analysis of machine learning models for weather forecasting: a Heathrow Case Study. *The Earth*, v. 2, n. 9 (Issue 5), 2024. <https://doi.org/10.61173/3jeb3612>
- ZHANG, H.; LIU, Y.; ZHANG, C.; LI, N. Machine learning methods for weather forecasting: a survey. *Atmosphere*, v. 16, n. 1, p. 82, 2025. <https://doi.org/10.3390/atmos16010082>
- ZHANG, K.; HUO, X.; SHAO, K. Temperature time series prediction model based on time series decomposition and Bi-LSTM network. *Mathematics*, v. 11, n. 9, p. 2060, 2023. <https://doi.org/10.3390/math11092060>