

# Modelos de Deep Learning em auxílio à previsão de variáveis meteorológicas em aeroportos na Antártica

**Alana de Lima Pontes Gadelha<sup>1</sup>**

Lúcia Maria A. Drummond<sup>2</sup>

Leandro Santiago<sup>2</sup>

<sup>1</sup> Centro de Hidrografia da Marinha - CHM, Niterói-Brasil

<sup>2</sup> Instituto de Computação, Universidade Federal Fluminense - UFF – Niterói RJ – Brasil

November 5, 2025

## Motivação

# Motivação

- Propor o uso de modelos de Inteligência Artificial (IA), especificamente de modelos de *Deep Learning*, como ferramentas complementares aos modelos numéricos, contribuindo para uma melhor previsão do tempo e segurança operacional nos aeródromos de regiões polares remotas;
- O Brasil mantém a base EACF (Estação Antártica Comandante Ferraz), em cumprimento ao **PRO**grama **ANTÁR**tico Brasileiro (**PROANTAR**).
  - Uso do aeródromo Tenente Rodolfo Marsh Martin (SCRM), Chile.
  - Atua como apoio logístico para diversas nações e é usado para transporte de suprimentos e pessoal.

# Motivação



## Problema

# Previsão Meteorológica em Ambientes Extremos

## 1. Desafios da previsão meteorológica na Antártica

- Condições climáticas extremas dificultam a precisão dos modelos;
- Modelos NWP tradicionais, como o ICON-LAM, exigem alto poder computacional;
- A demora no processamento limita respostas rápidas a mudanças locais.

## 2. Importância para operações aéreas

- Previsões confiáveis garantem segurança em pouso e decolagens;
- O planejamento seguro depende de dados locais eficazes e ágeis.

## 3. Necessidade de alternativas eficientes

- Soluções com menor custo computacional são essenciais;
- Modelos locais possibilitam respostas rápidas em regiões inóspitas.

## Contribuições

# Contribuições

Assim, as principais contribuições desse trabalho são:

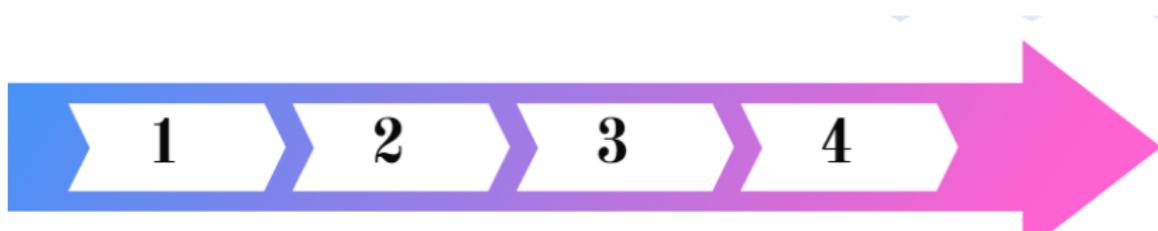
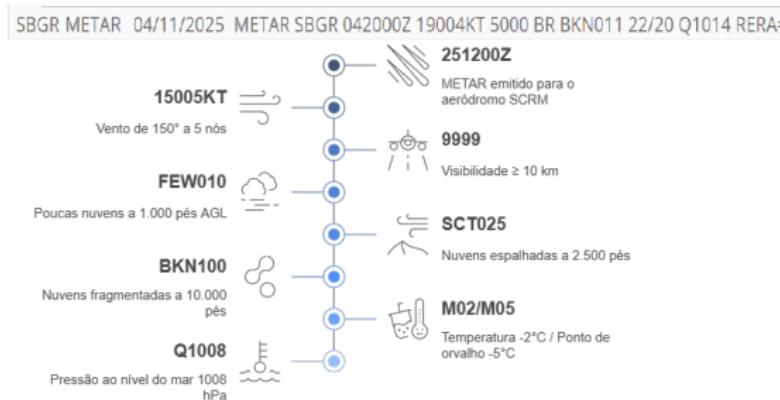
- 1 Desenvolvimento de técnicas de pré-processamento de dados meteorológicos provenientes de estações automáticas, além da correta extração dos dados, provenientes do output, do modelo numérico ICON-LAM;
- 2 Proposta de utilização de modelos de *Deep Learning* para previsão de temperatura e pressão, em apoio à segurança de aterrizações e decolagens de aeronaves;
- 3 Análise comparativa dos resultados qualitativos, além dos tempos de execução das estratégias de *Deep Learning*, em relação aos resultados e tempo de processamento do Modelo Numérico ICON-LAM, executado em um supercomputador HPE (Hewlett Packard Enterprise).

## Material e Método

# Estratégias de Pré-processamento

- Coleta e pré-processamento dos Dados Meteorológicos da estação automática de SCRM, com 15 anos de dados horários.
- Pré-processamento com os dados numéricos do Modelo ICON-LAM, com 1 ano e 6 meses de dados a cada 3 horas.

# Estratégias de Pré-processamento



## Coleta

Dados METAR coletados na estação do aeroporto SCRM entre 01/2010 e 06/2025.

## Tratamento

Remoção e correção de valores faltantes para garantir integridade dos dados.

## Normalização

Padronização via z-score aplicada para uniformizar as variáveis.

## Seleção de Variáveis

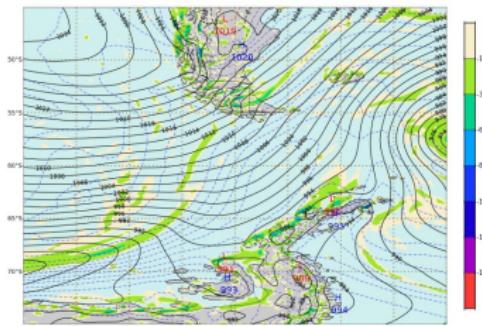
Incluídas variáveis meteorológicas relevantes e excluídas as sem correlação significativa.

# Estratégias de Pré-processamento

## ICON-LAM (ICOsaheiral Nonhydrostatic Limited Area Mode)

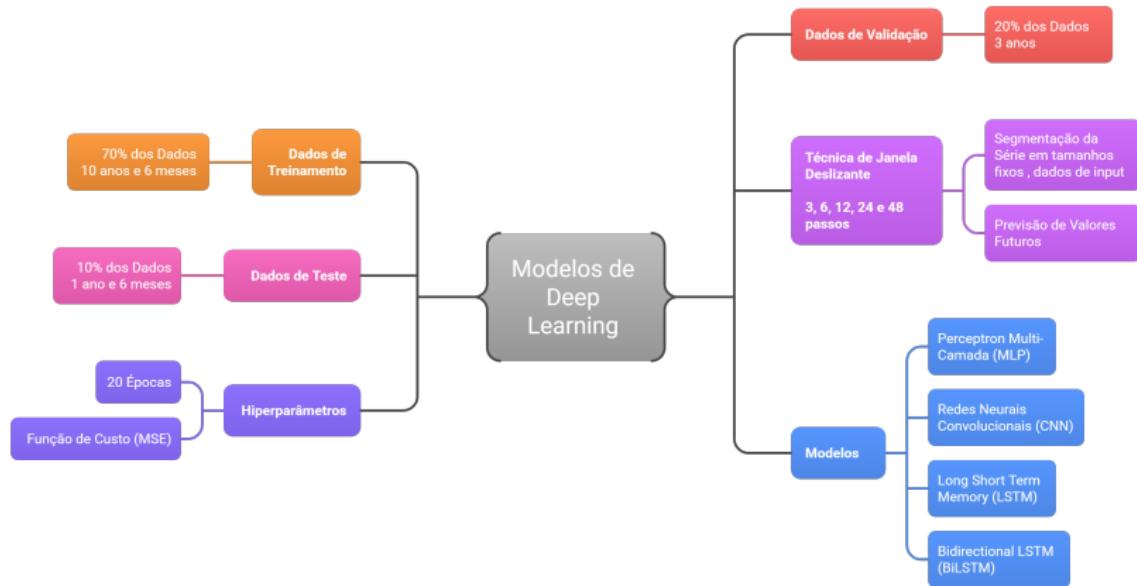
- Resolução espacial de **6,5 km**, aplicado à região da Antártica;
- A grade utilizada possui dimensões de **1201 x 1121 pontos**, abrangendo latitudes de **-56,00° a -14,00°** e longitudes de **270,00° a 345,00°**;
- A extração da série temporal foi realizada para o ponto geográfico de **latitude -62,1917° e longitude -58,9867°**, correspondente à localização do **aeroporto SCRM**, obtendo dados próximos da estação meteorológica automática e permitindo a comparação direta.

Modelo ICONLAM6.5Km/CHM - PRNMM (hPa) + Esp. (850-1000 hPa) + Vort. Neg (1000 hPa)  
Ref: 12Z04Nov2025 (Tue) +PROG000h/Val: 12Z04Nov2025 (Tue)



## Experimentos

# Configuração do Experimentos



# Configuração do Experimentos

## Comparação de Modelos de Rede Neural

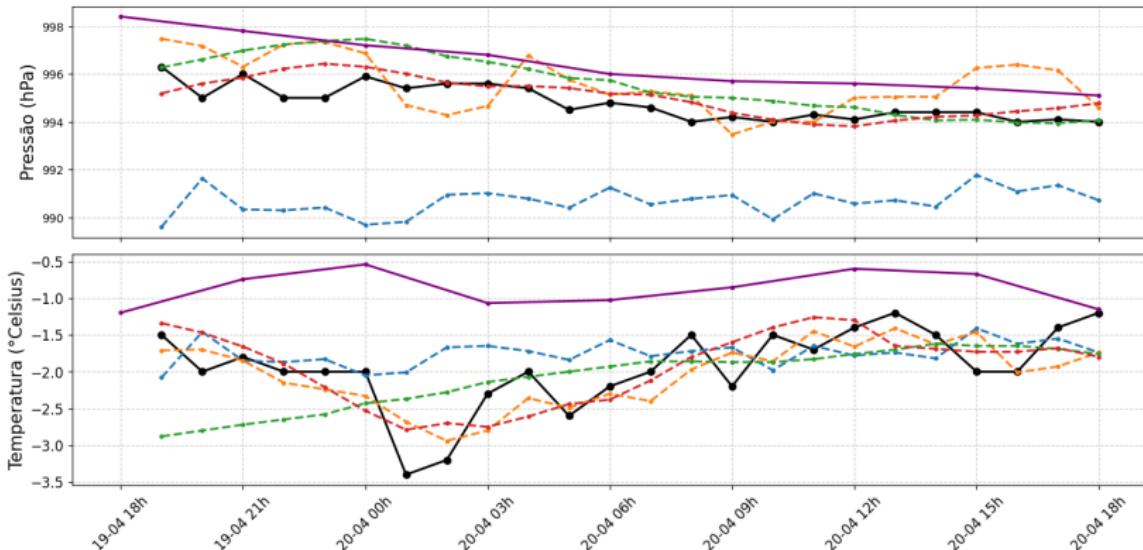
Característica	MLP	CNN	LSTM	BiLSTM
<b>Tipo</b>	Rede neural tradicional	Especializada em padrões espaciais	Rede neural recorrente	Rede neural recorrente bidirecional
<b>Dados de Entrada</b>	24 inputs	3 inputs (1D)	48 inputs / 12 outputs	24 inputs / 24 outputs
<b>Arquitetura</b>	Flatten() → Dense(32) → Dense(32) → Dense(1) → Reshape(	Conv1D(32, k=3, padding='same') → Dense(32) → Dense(1)	LSTM(32) → Dense(24) → Reshape(	Bidirectional(LSTM(32)) → Dense(24) → Reshape(
<b>Função de Ativação</b>	ReLU nas duas Dense(32); linear na saída	ReLU no conv1D e na Dense(32); linear na saída	ReLU implícita? (LSTM tem gates internas; Dense(24) é linear por padrão)	idem LSTM; Dense de saída linear
<b>Tamanho do Passo</b>	$24 \times 15 \rightarrow 1$ passo(batch, 1, 1)	$3 \times 15 \rightarrow 1$ passo(batch, 1, 1)	$\approx 48 \times 15 \rightarrow 12$ ou 24 passos (Reshape(	$24 \times 15 \rightarrow 24$ passos(batch, 24, 1)
<b>Parâmetros</b>	12,641 (360→32→32→1)	2,561 (Conv: 1,472; Dense32: 1,056; Dense1: 33)	6,936 (LSTM32: 6,144; Dense24: 792)	13,848 (BiLSTM: 12,288; Dense: 1,560)

## Resultados

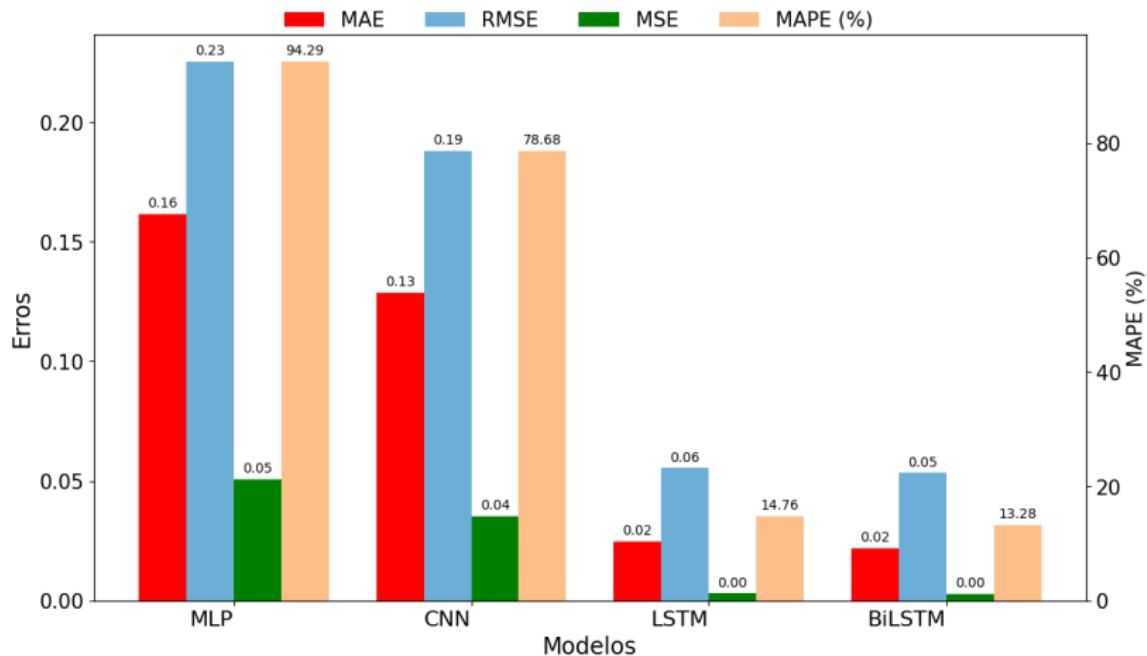
# Configuração Computacional e Resultados

- **Modelo ICON-LAM** executado em supercomputador **HPE Apollo K6000** com 336 CPUs **Intel® Xeon® Gold 6248R a 3 GHz**, distribuídos em 7 nós;
- **Treinamento dos modelos de Deep Learning** realizado no ambiente **Google Colab**, utilizando a biblioteca **TensorFlow** e aceleradores como **GPUs**;

● Observado      ● CNN  
 ● MLP              ● BiLSTM  
 ● LSTM              ● ICON-LAM



# Resultados



# Resultados

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

**Table:** Tempos de execução em segundos, para treinamento e testes/inferências dos modelos, tanto em CPU quanto em GPU.

- Modelos leves como MLP e CNN apresentam maior latência na GPU devido a custos fixos com transferência de dados e inicialização;
- CPU é mais eficiente para janelas curtas e redes rasas, onde *overhead* de GPU impacta negativamente o desempenho;
- Redes recorrentes como LSTM e BiLSTM se beneficiam do paralelismo da GPU, reduzindo significativamente o tempo de inferência e treinamento.

## Conclusão

# Conclusão e trabalhos futuros

## Conclusão

- Desempenho Superior do BiLSTM em Previsões Meteorológicas; Capacidade avançada de capturar padrões diários e sazonais por processamento bidirecional que considera passado e futuro simultaneamente;
  - Um dos principais diferenciais do modelo BiLSTM está no tempo de execução: aproximadamente 10 minutos, frente aos aproximadamente 37 minutos do ICONLAM.
  - Desempenho superior nas métricas de erro, garantindo previsões mais precisas;

## Trabalhos Futuros

- Futuros trabalhos poderão explorar estratégias híbridas, focando na melhoria da dinâmica do próprio modelo ICON-LAM em prever variáveis, por meio das estratégias de Deep Learning;
- Além de expandir para as demais estações meteorológicas;

# Obrigada