

CITE

II CONGRESSO INTERNACIONAL DE TECNOLOGIAS EMERGENTES

Onde as ideias do presente criam as soluções do futuro

14 e 15 de Novembro de 2025

FORECASTING OCEAN HEAT CONTENT (OHC) IN THE SUBPOLAR NORTH ATLANTIC USING RANDOM FOREST WITH INTERNAL AND EXTERNAL VALIDATION

Jhonathas Moutinho da Silva Melo¹

Eduardo Palhares Júnior²

Alexandre Lopes Martiniano³

Alyson de Jesus dos Santos⁴

Rosimeire Araújo Silva⁵

DOI:10.5281/zenodo.17836359

¹Especialização em Aprendizado de Máquina - Instituto Federal do Amazonas - IFAM, Campus Zona Leste – Manaus, AM – Brasil; jhonathasmoutinho@yahoo.com.br

² Instituto Federal do Amazonas - IFAM, Campus Distrito Industrial – Manaus, AM – Brasil; eduardo.palharesjr@ifam.edu.br

³ Instituto Federal do Amazonas - IFAM, Campus Distrito Industrial – Manaus, AM – Brasil; alexandre.martiniano@ifam.edu.br

⁴ Instituto Federal do Amazonas - IFAM, Campus Distrito Industrial – Manaus, AM – Brasil; alyson.santos@ifam.edu.br

⁵ Instituto Nacional de Pesquisas da Amazônia - INPA, Manaus, AM - Brasil; cientistadedados2020@gmail.com

Resumo

O Conteúdo de Calor Oceânico (OHC) no Atlântico Norte Subpolar constitui um indicador crítico das mudanças climáticas, com implicações diretas para a estabilidade da Circulação de Revolvimento Meridional do Atlântico (AMOC). Este estudo desenvolve e valida um modelo de *Random Forest* para previsão do OHC na região, utilizando uma abordagem baseada em séries temporais que combina dados de reanálise EN4 (1950–2020) com observações independentes da rede ARGO (2004–2020). Doze *features* temporais derivadas da própria série de OHC — incluindo componentes sazonais, defasagens, médias móveis e tendências — foram implementadas para representar sua estrutura interna e dinâmica não linear. O modelo apresentou desempenho robusto, com R^2 de 0,9476 na validação temporal e 0,7129 na validação externa com dados ARGO. As análises identificaram uma tendência persistente de resfriamento entre 2004–2020, com taxas de $-0,0841 \times 10^{22}$ J/ano (EN4) e $-0,1029 \times 10^{22}$ J/ano (ARGO), padrão que se projeta de forma contínua para a década 2021–2030, resultando em mudanças totais de $-0,8306 \times 10^{22}$ J (EN4) e $-1,3250 \times 10^{22}$ J (ARGO). Esses resultados estão alinhados com projeções recentes que indicam resfriamento sustentado no Atlântico Subpolar, associado ao

enfraquecimento da AMOC e a mudanças nos processos de formação de águas profundas. A abordagem adotada demonstra que técnicas de *machine learning* baseadas em séries temporais constituem ferramentas eficazes e acessíveis para previsão oceânica, sobretudo quando integradas a múltiplas fontes de dados e princípios da física oceânica, permitindo avanços no monitoramento de variáveis climaticamente relevantes mesmo em contextos com infraestrutura limitada.

Palavras-chave: Conteúdo de Calor Oceânico; Atlântico Norte Subpolar; Random Forest; Machine Learning; Séries Temporais; Previsão Oceânica.

1. INTRODUÇÃO

Os oceanos desempenham um papel fundamental na regulação do clima global, absorvendo aproximadamente 90% do excesso de calor decorrente do aumento das concentrações de gases de efeito estufa na atmosfera (IPCC, 2021). O Conteúdo de Calor Oceânico (OHC) emergiu como uma métrica essencial para quantificar esse armazenamento de energia térmica, representando um indicador mais confiável das mudanças climáticas do que as temperaturas superficiais isoladas (CHENG et al., 2019). Desde 1970, os oceanos absorveram mais de 380×10^{22} J de calor adicional, com taxas de aquecimento que se intensificaram significativamente nas últimas décadas (VON SCHUCKMANN, K et al., 2020; VON SCHUCKMANN, K et al., 2023).

Evidências crescentes sugerem que a AMOC pode operar em múltiplos estados estáveis, com transições abruptas entre eles caracterizando um ponto de virada climático (BOERS, 2021; JACKSON et al., 2023), sendo que estudos paleoclimáticos indicam que a corrente atualmente apresenta sua condição mais fraca no último milênio (CAESAR et al., 2018)

A região subpolar do Atlântico Norte desempenha um papel crítico no sistema climático global devido à sua centralidade na Circulação de Revolvimento Meridional do Atlântico (AMOC) (RAHMSTORF, 2002). A AMOC atua como uma esteira transportadora global, transportando calor dos trópicos para as altas latitudes e regulando os padrões climáticos em ambos os hemisférios (BUCKLEY; MARSHALL, 2016).

O mecanismo fundamental que sustenta a AMOC reside nos processos de formação de águas profundas que ocorrem nas regiões subpolares, particularmente nos mares da Groenlândia e Labrador (LOZIER, 2010). Esses processos são extremamente sensíveis às mudanças na estratificação térmica e salina das águas superficiais. O aumento do OHC

nesta região pode inibir a convecção profunda através do fortalecimento da estratificação, potencialmente desencadeando uma desaceleração ou mesmo colapso da AMOC (LENTON et al., 2008).

Evidências crescentes sugerem que a AMOC pode operar em múltiplos estados estáveis, com transições abruptas entre eles caracterizando um ponto de virada climático (BOERS, 2021). Dados paleoclimáticos indicam que tais transições ocorreram no passado, associadas a mudanças climáticas dramáticas em escalas continentais (LYNCH-STIEGLITZ, 2017). No contexto atual de aquecimento antropogênico, existe preocupação considerável de que o aumento contínuo do OHC no Atlântico Norte possa aproximar o sistema de um limiar crítico (WEIJER et al., 2019).

Estudos recentes utilizando modelos climáticos e análises observacionais têm fornecido indicações preocupantes sobre a possível desaceleração da AMOC (SMEED et al., 2018; THORNALLEY et al., 2018). Entretanto, incertezas significativas permanecem devido às limitações nas séries temporais observacionais e à complexidade dos processos envolvidos.

Este estudo propõe uma abordagem inovadora para a previsão do Conteúdo de Calor Oceânico (OHC) no Atlântico Norte Subpolar, utilizando técnicas de machine learning, metodologias que têm ganhado destaque na oceanografia moderna por sua capacidade de capturar relações não-lineares em dados oceânicos (Vikhila et al., 2022; ZHANG et al., 2023).

O objetivo principal é preencher lacunas existentes na previsão do OHC por meio do desenvolvimento de um modelo preditivo baseado em aprendizado de máquina, que combina dados de reanálise (EN4) com observações independentes do programa ARGO, garantindo validação robusta das previsões.

O estudo enfatiza a previsibilidade em curto e médio prazo, avaliando a capacidade do modelo de antecipar variações do OHC e identificando os drivers temporais mais relevantes que influenciam sua variabilidade. Além disso, os resultados são contextualizados dentro do quadro climático mais amplo, permitindo interpretações sobre a estabilidade da Circulação Meridional de Revolvimento do Atlântico (AMOC) e potenciais pontos de virada, contribuindo para a compreensão dos mecanismos que regulam o sistema climático global.

2. MATERIAIS E MÉTODOS

2.1 Fontes de Dados

2.1.1 Dados EN4

Neste estudo, utilizou-se a versão mais recente do conjunto de dados EN.4.2.2 do Met Office Hadley Centre (GOOD; MARTIN; RAYNER, 2013), um produto de reanálise oceânica global que assimilou observações históricas de perfis verticais de temperatura e salinidade desde 1900. Foram extraídos dados mensais de Conteúdo de Calor Oceânico (OHC) na região do Atlântico Norte Subpolar (45°N – 65°N , 60°W – 0°), abrangendo o período de 1950–2020.

O OHC foi calculado mediante a integração do conteúdo de calor desde a superfície até 2000 m de profundidade, expresso em 10^{22} Joules, representando assim o acúmulo de energia térmica no oceano – um indicador essencial para monitorar a evolução do clima global. O conjunto EN4 incorpora dados de diversas fontes, incluindo expendable bathythermographs (XBTs), flutuadores Argo, moorings e CTDs, submetidos a rigorosos controles de qualidade e procedimentos de correção de viés.

A região subpolar do Atlântico Norte apresenta particular interesse devido à sua variabilidade termodinâmica e papel crítico na formação de águas profundas, com o OHC exibindo padrões complexos de variabilidade interanual e decadal (JOURDAIN et al., 2022).

2.1.2 Dados ARGO

Para validação independente do modelo, utilizou-se dados do Centro Global de Montagem de Dados do ARGO (Argo GDAC), uma rede global de aproximadamente 3.000 flutuadores de deriva livre que medem, além de outras variáveis, o Conteúdo de Calor Oceânico (OHC). Os dados estão disponibilizados publicamente no repositório SEANOE (ARGO, 2020). Utilizou-se dados do programa ARGO, consistindo em perfis oceânicos de integração do conteúdo de calor desde a superfície até 2000 m de profundidade obtidos por flutuadores autônomos, disponíveis publicamente no repositório SEANOE, que fornecem medidas de temperatura e salinidade desde o início dos anos 2000. Os dados de OHC foram processados para a mesma região e período (2004–2020),

seguindo a metodologia aplicada aos dados EN4, garantindo consistência entre reanálises e observações diretas.

2.2 Pré-processamento

O pipeline de pré-processamento foi estruturado para preparar os dados de forma robusta e extrair informações relevantes para o modelo de Random Forest. Inicialmente, realizou-se a harmonização temporal das séries, criando um índice temporal consistente que combinou ano e mês (`Time = pd.to_datetime(Year.astype(str) + '-' + Month.astype(str) + '-01')`), assegurando referência uniforme para todas as observações mensais.

Para capturar diferentes aspectos da variabilidade do OHC, foram construídas doze variáveis temporais. Componentes sazonais foram calculados a partir das funções seno e cosseno do mês do ano (`month_sin = sin(2π * month / 12)` e `month_cos = cos(2π * month / 12)`), permitindo que o modelo representasse padrões periódicos ao longo das estações. Variáveis de memória baseadas em defasagens de 1, 3, 6 e 12 meses (`OHC_lag1`, `OHC_lag3`, `OHC_lag6`, `OHC_lag12`) possibilitaram incorporar dependências temporais passadas. Para reduzir ruídos e captar tendências de curto prazo, aplicaram-se médias móveis de 3, 6 e 12 meses (`OHC_roll3`, `OHC_roll6`, `OHC_roll12`). Finalmente, uma variável de tendência foi incluída, definida como a diferença entre o valor atual do OHC e o valor do mesmo mês do ano anterior (`OHC_trend = OHC(t) - OHC(t-12)`), permitindo identificar mudanças ao longo do tempo e padrões de longo prazo.

2.3 Modelagem com Aprendizado de Máquina

Para a modelagem do conteúdo de calor oceânico (OHC), optou-se pelo algoritmo Random Forest Regressor (BREIMAN, 2001), que tem demonstrado excelente desempenho na previsão de variáveis oceânicas, incluindo temperatura superficial e conteúdo de calor (LI F. et al., 2022; WANG et al., 2022). Os hiperparâmetros escolhidos para o modelo incluíram `n_estimators = 100`, definindo o número de árvores da floresta; `max_depth = 10`, limitando a profundidade máxima de cada árvore; `random_state = 42` para garantir a reprodutibilidade dos resultados; e `n_jobs = -1` para permitir paralelização total, acelerando o treinamento em múltiplos núcleos de processamento.

A estratégia de validação adotada seguiu uma divisão temporal estrita, de modo a respeitar a sequência cronológica dos dados. O conjunto de treino compreendeu os 80% iniciais da série temporal (1951-2005), enquanto os 20% finais (2006-2020) foram reservados para teste. Esta abordagem assegurou que o modelo fosse avaliado em dados temporalmente independentes, simulando condições reais de previsão.

Para avaliar a robustez e a capacidade de generalização do modelo, implementou-se um esquema de validação múltipla. Primeiramente, as previsões foram validadas internamente com os próprios dados EN4, utilizando tanto a divisão temporal padrão (teste) quanto toda a série histórica (validação interna). Posteriormente, realizou-se uma validação externa crucial utilizando dados independentes do programa ARGO (2004-2020), não utilizados no treinamento do modelo.

Esta abordagem de validação dupla permitiu verificar se o modelo aprendeu padrões reais da dinâmica do Atlântico Norte Subpolar, evitando sobreajuste e fornecendo métricas de desempenho mais realistas. A validação com dados ARGO é particularmente importante por representar observações diretas e independentes das reanálises, reforçando a confiabilidade das previsões e assegurando que o modelo possa ser aplicado a cenários futuros.

A performance do modelo foi avaliada por meio de múltiplas métricas quantitativas consagradas em séries temporais: o RMSE (Root Mean Square Error), que indica o erro médio quadrático entre as previsões e os valores observados; o R^2 (Coeficiente de Determinação), que avalia a proporção da variabilidade explicada pelo modelo; e o MAE (Mean Absolute Error), que fornece uma medida robusta do erro absoluto médio. Adicionalmente, calculou-se a correlação de Pearson entre previsões e observações, fornecendo uma avaliação complementar da capacidade do modelo em capturar padrões temporais.

Todas as análises foram realizadas em Python 3.10, utilizando as bibliotecas scikit-learn, pandas, numpy, matplotlib e seaborn. A significância estatística foi avaliada a $p < 0,05$.

3. RESULTADOS E DISCUSSÕES

3.1 Conteúdo de Calor Oceânico (OHC)

A série temporal do Conteúdo de Calor Oceânico (OHC) no Atlântico Norte Subpolar (45°N – 65°N , 60°W – 0°) é apresentada na Figura 1. Anomalia mensal média do conteúdo de calor oceânico subpolar do Atlântico Norte (SpNA-OHC) nos 1000 m superiores do Oceano Atlântico Norte (faixa de latitude de 45° a 67°N), em relação à média de longo prazo (1991-2020). Dois conjuntos de dados observacionais são apresentados: EN4 e Argo. Há boa concordância em suas tendências de longo prazo e variabilidade interanual.

A série mostra múltiplas escalas de variabilidade no Conteúdo de Calor Oceânico (OHC), com uma tendência positiva de longo prazo refletindo o aquecimento gradual das águas da região, sobreposta a uma marcante variabilidade interanual, consistente com estudos recentes que documentam a complexa dinâmica térmica nesta área crítica para a formação de águas profundas (Jourdain et al., 2022; Cheng et al., 2020).

A ocorrência de eventos extremos de aquecimento e resfriamento mais frequentes nas décadas recentes são observadas, indicando oscilações abruptas em curtos intervalos temporais. A série histórica do EN4 (linha azul tracejada) mostra consistência com os dados independentes do ARGO (linha verde contínua, disponíveis a partir de 2004), validando a confiabilidade do conjunto de reanálise. Ambas as séries exibem sazonalidade marcada, com picos de OHC observados evidenciando a influência do ciclo anual na dinâmica térmica regional.




Figura 1. Série temporal do conteúdo de calor oceânico (OHC) no Atlântico Norte Subpolar (1950–2020). A linha azul tracejada representa os dados de reanálise EN4 e a linha verde contínua as observações ARGO, com período de sobreposição entre 2004–2020.

Considerando que a área de estudo engloba as principais regiões de formação de águas profundas que sustentam a AMOC, essas variações no OHC tornam-se particularmente relevantes para a estabilidade da circulação oceânica global.

3.2 Desempenho do Modelo de *Random Forest*

O modelo de Random Forest demonstrou excelente capacidade preditiva para a série temporal do conteúdo de calor oceânico (OHC), com desempenho consistente entre os diferentes esquemas de validação (Tabela 1). A modelagem baseou-se em dois conjuntos de dados independentes: EN4 (852 amostras entre 1950–2020) e ARGO (204 amostras entre 2004–2020). Após o pré-processamento, o conjunto EN4 resultou em 840 observações mensais, divididas em 80% para treinamento (672 amostras) e 20% para teste (168 amostras).

Na validação interna com o conjunto EN4, o modelo alcançou $R^2 = 0,982$, $RMSE = 0,073 \times 10^{22} \text{ J}$ e $MAE = 0,053 \times 10^{22} \text{ J}$, evidenciando ajuste preciso e mínima dispersão dos resíduos. A validação temporal padrão (teste) apresentou desempenho igualmente

elevado ($R^2 = 0,948$; $RMSE = 0,120 \times 10^{22}$ J), confirmando a robustez da generalização temporal dentro do próprio conjunto de reanálise.

Tabela 1 - Métricas de Desempenho do Modelo (EN4 e ARGO)				
Tipo de Validação	R^2	RMSE	MAE	Correlação
EN4 Teste	0.9476	0.1196	0.0952	-
EN4 Interno	0.9823	0.0725	0.0535	0.7318
ARGO	0.7129	0.3380	0.2805	0.9264

A validação externa com o conjunto independente ARGO manteve resultados expressivos ($R^2 = 0,713$; $RMSE = 0,338 \times 10^{22}$ J; $MAE = 0,281 \times 10^{22}$ J; correlação = 0,926), o que confirma a capacidade do modelo em capturar padrões fundamentais da dinâmica térmica oceânica mesmo em dados totalmente independentes das reanálises utilizadas no treinamento. Esse resultado corrobora abordagens recentes que destacam a importância da validação cruzada em modelos preditivos de variáveis oceânicas (ZHANG et al., 2023; VIKHILA et al., 2022).

A seguir são apresentados os resultados dos testes realizados com o modelo de *Random Forest*. A Figura 2 (a–d) sintetiza o ajuste temporal das séries, a correspondência entre valores observados e previstos e a importância relativa das *features* temporais derivadas da própria série de OHC.

A análise temporal (Figura 2a) demonstra alta coerência entre as séries observadas e previstas, tanto para o conjunto de reanálise EN4 quanto para as observações independentes ARGO. O modelo reproduziu com precisão a variabilidade interanual e decadal do Conteúdo de Calor Oceânico, com pequenas divergências restritas a eventos abruptos de aquecimento e resfriamento, típicos de processos oceânicos não lineares.

A dispersão dos pontos ao redor da diagonal 1:1 (Figura 2b) confirma a forte correspondência entre os valores observados e previstos na validação externa com ARGO ($R^2 = 0,713$), embora haja ligeira dispersão nos extremos térmicos — comportamento esperado devido às diferenças de resolução e metodologia entre as observações *in situ* e as estimativas de reanálise. De modo análogo, a validação interna com EN4 (Figura 2c)

apresentou desempenho excepcional ($R^2 = 0,982$), evidenciando que o modelo captura adequadamente a estrutura temporal e a persistência térmica da série.

A análise da importância das variáveis (Figura 2d) revela a dominância da média móvel de 3 meses do OHC (*OHC_roll3*), responsável por aproximadamente 90% da importância total (peso $\approx 0,902$). Em seguida, destacam-se a componente de tendência de longo prazo (*OHC_trend*, 0,033) e as defasagens temporais de 1 e 12 meses, enquanto as variáveis sazonais (*month*, *month_sin*, *month_cos*) apresentam contribuição residual. Essa hierarquia confirma que o modelo baseia suas previsões principalmente na persistência térmica de curto prazo e na tendência climática de fundo — ambos consistentes com os mecanismos físicos de armazenamento e dissipação de calor nas águas subpolares.

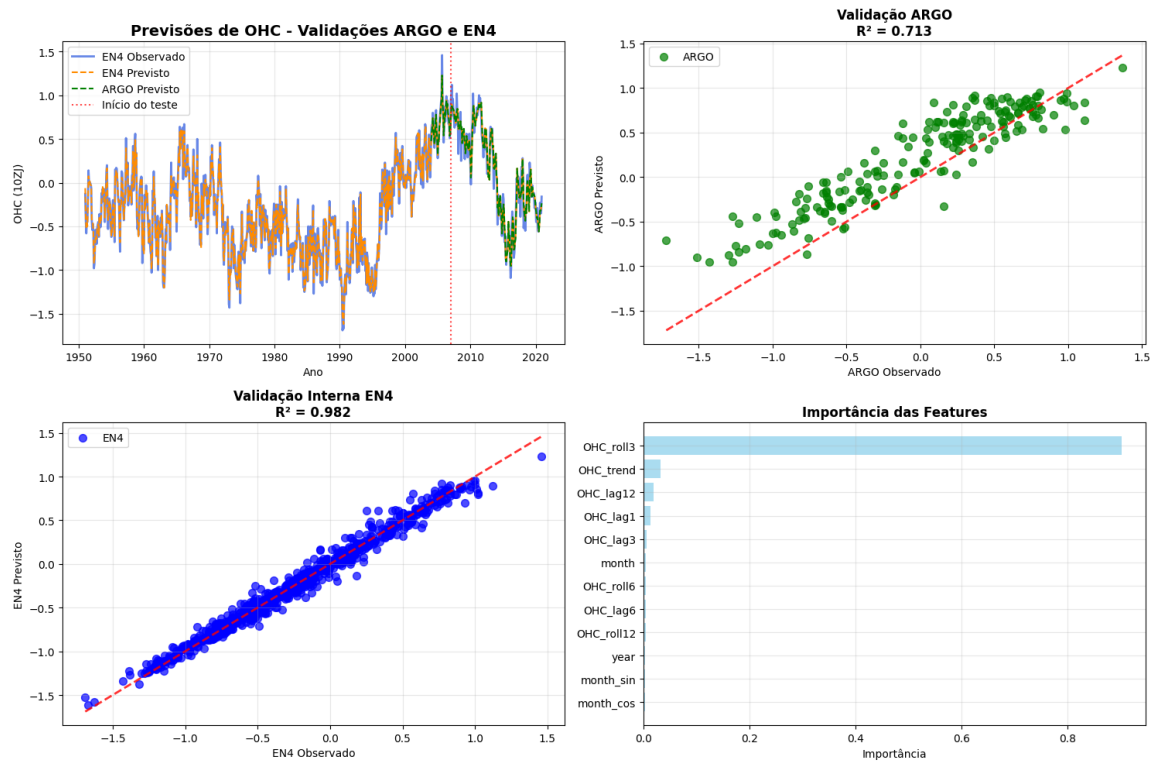


Figura 2: (a) Séries temporais: EN4 observado (linha contínua azul), EN4 previsto (linha tracejada laranja) e ARGO previsto (linha tracejada verde); linha vertical pontilhada vermelha marca o início da validação externa. (b) Validação externa (ARGO) (c) Validação interna (EN4). (d) Importância das *features*: ordenadas por contribuição no modelo indicando importância relativa (normalizada).

A dominância da média móvel de 3 meses (*OHC_roll3*) como variável mais importante reflete a persistência térmica de curto prazo, característica documentada em

estudos observacionais da região subpolar (JOURDAIN et al., 2022), enquanto a tendência de longo prazo captura mudanças climáticas mais profundas.

Os resíduos apresentaram distribuição aleatória e ausência de viés sistemático, validando a hipótese de independência dos erros e reforçando a robustez estatística do modelo.

Em síntese, o modelo de *Random Forest* mostrou elevada capacidade de generalização, consistência entre conjuntos de validação e boa aderência física aos processos oceânicos subpolares. Esses resultados demonstram a aplicabilidade do método em previsões do conteúdo de calor oceânico possíveis análises de tendência.

3.3 Previsão do Conteúdo de Calor Oceânico (OHC) 2021–2030: Cenários EN4 e ARGO

A Figura 3 (a–f) apresenta as projeções do Conteúdo de Calor Oceânico (OHC) no Atlântico Norte Subpolar para 2021–2030, produzidas pelo modelo *Random Forest* calibrado sobre os conjuntos EN4 e ARGO. Os painéis mostram: (a) séries temporais previstas para 2021–2030 (EN4 vs ARGO); (b) tendências anuais médias projetadas; (c–d) decomposição das previsões em tendência/base e componente sazonal para EN4 e ARGO; e (e–f) mudança acumulada do OHC em relação a 2021. As previsões integram tanto a variabilidade sazonal quanto o componente de tendência inferido na janela de treinamento (2004–2020).

As séries projetadas (Fig. 3a) indicam um declínio contínuo do OHC ao longo da década 2021–2030, com anomalias negativas persistentes desde ≈ 2023 . Ambos os cenários (EN4 e ARGO) apontam redução sistemática da energia térmica nas camadas superficiais do Atlântico Norte Subpolar, sendo o declínio projetado a partir do ARGO consistentemente mais acentuado. A decomposição (Fig. 3c–d) evidencia que a componente de tendência domina a evolução decadal, enquanto a variabilidade intra-anual (sazonalidade) mantém amplitude reduzida ($< 0,2 \times 10^{22}$ J), indicando que a evolução prevista é governada sobretudo por um sinal de tendência de longo prazo. As curvas de mudança acumulada (Fig. 3e–f) ilustram a progressiva perda de OHC em relação a 2021 ao longo da década.

O valor de OHC médio projetado para 2021–2030 é mais negativo no ARGO do que no EN4, refletindo maior magnitude de resfriamento no cenário ARGO. As previsões EN4 tendem a ser menos extremas e apresentam menor variabilidade interanual do que as previsões derivadas do ARGO, possivelmente em função da diferença de cobertura espacial e das metodologias de assimilação entre reanálise (EN4) e observações *in situ* (ARGO). Pequenas ondulações sazonais persistem sobre a tendência decrescente, mas não são suficientes para reverter o sinal de resfriamento projetado para o período.

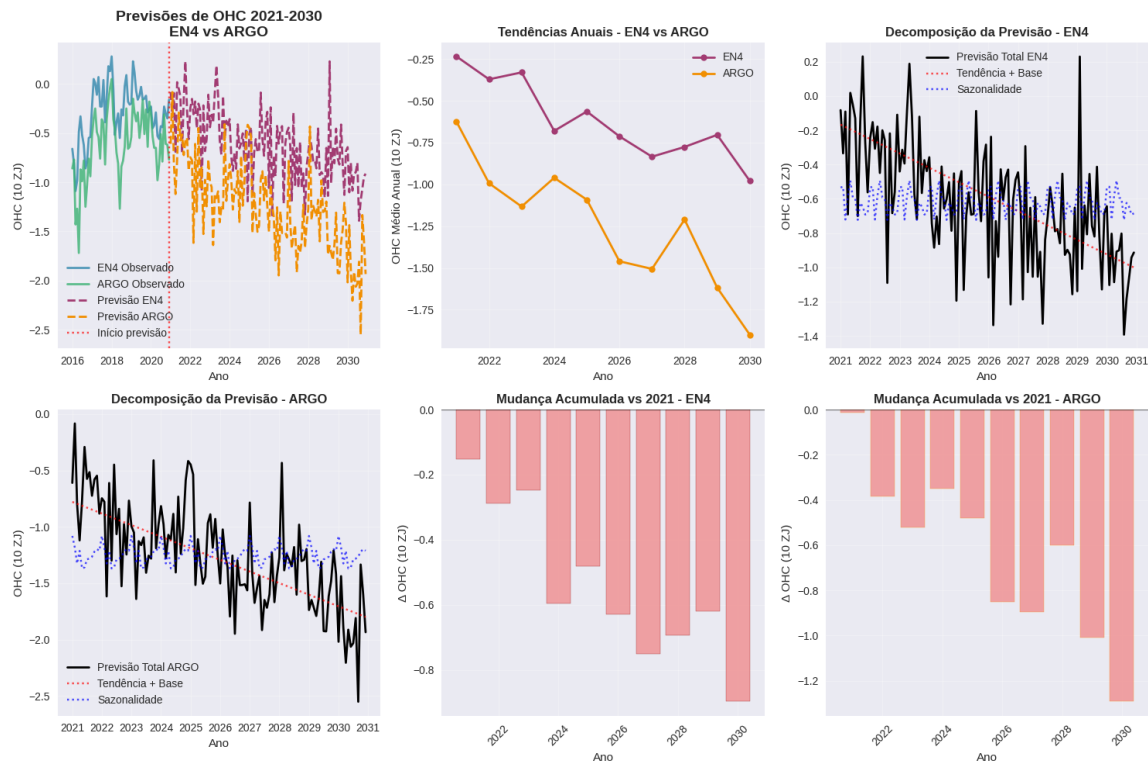


Figura 3: (a–f) Projeções do Conteúdo de Calor Oceânico (OHC) no Atlântico Norte Subpolar para 2021–2030, produzidas pelo modelo *Random Forest* calibrado sobre os conjuntos EN4 e ARGO. (a) Séries temporais previstas para 2021–2030 (EN4 vs ARGO); (b) tendências anuais médias projetadas; (c–d) decomposição das previsões em tendência/base e componente sazonal para EN4 e ARGO; e (e–f) mudança acumulada do OHC em relação a 2021.

A Tabela 2 resume estatísticas chave das previsões (unidade: 10^{22} J) com os valores mais relevantes e suas implicações: Média 2021–2030: EN4 = $-0,6185$; ARGO = $-1,2496$. O cenário ARGO projeta um nível médio de OHC significativamente mais baixo ao longo

da década, sugerindo resfriamento mais pronunciado. Mudança total (início → fim da década): EN4 = $-0,8306$; ARGO = $-1,3250$. A perda acumulada projetada no ARGO é $\approx 60\%$ maior que no EN4, corroborando diferenças entre as bases de dados. Mudança anual média: EN4 = $-0,0831 \times 10^{22} \text{ J ano}^{-1}$; ARGO = $-0,1325 \times 10^{22} \text{ J ano}^{-1}$.

Ambos os cenários indicam taxa negativa de OHC; a taxa derivada do ARGO é substancialmente mais intensa. Extremos e amplitude: mínimo EN4 = $-1,3926$ vs ARGO = $-2,5516$; máximo EN4 = $0,2306$ vs ARGO = $-0,0828$; amplitude EN4 = $1,6233$ vs ARGO = $2,4688$. O ARGO exibe amplitude maior e extremos mais frios, o que pode refletir maior sensibilidade de observações *in situ* a variações superficiais e processos de mistura. Tendência anual: EN4 = $-0,0841 \times 10^{22} \text{ J ano}^{-1}$; ARGO = $-0,1029 \times 10^{22} \text{ J ano}^{-1}$. Valores próximos às taxas médias acima confirmam robustez do sinal negativo de tendência.

Tabela 2: Estatísticas das Previsões da OHC (2021-2030) EN4 x ARGO			
Métrica	EN4	ARGO	Unidade
Média (2021-2030)	-0.6125	-0.2496	10^{22} J
Mudança Total	-0.8306	-0.3250	10^{22} J
Mudança/Ano	-0.0831	-0.1325	10^{22} J/ano
Mínimo	-1.3926	-2.5516	10^{22} J
Máximo	0.2306	0.0828	10^{22} J
Amplitude	1.6233	2.4688	10^{22} J
Tendência Anual	-0.0841	-0.1029	10^{22} J/ano

As projeções do OHC para o período 2021–2030, geradas pelo modelo Random Forest calibrado com os conjuntos EN4 e ARGO, indicam um declínio contínuo ao longo de toda a década, com anomalias negativas persistentes a partir de aproximadamente 2023.

Ambos os cenários apontam para uma redução sistemática da energia térmica armazenada nas camadas superficiais do Atlântico Norte Subpolar, sendo o declínio projetado a partir dos dados ARGO consistentemente mais acentuado. A decomposição das séries temporais mostra que a componente de tendência domina a evolução decadal,

enquanto a variabilidade intra-anual mantém amplitude reduzida, inferior a $0,2 \times 10^{22}$ J, indicando que a evolução prevista é governada sobretudo por um sinal de tendência de longo prazo.

Os valores médios de OHC projetados para a década 2021–2030 foram de $-0,6185 \times 10^{22}$ J para o EN4 e $-1,2496 \times 10^{22}$ J para o ARGO, refletindo uma diferença significativa na magnitude do resfriamento entre os conjuntos. A mudança total acumulada ao longo da década foi de $-0,8306 \times 10^{22}$ J para o EN4 e $-1,3250 \times 10^{22}$ J para o ARGO, representando uma perda aproximadamente 60% maior no cenário baseado em observações *in situ*. As taxas anuais médias de mudança foram de $-0,0831 \times 10^{22}$ J/ano (EN4) e $-0,1325 \times 10^{22}$ J/ano (ARGO), ambas indicando uma trajetória consistente de resfriamento.

As projeções com dados EN4 mostram similaridade com os resultados de Menary et al. (2020), que também identificaram uma tendência consistente de redução no conteúdo de calor oceânico associada a AMOC em cenário de médias emissões. Esta convergência reforça a robustez das projeções sobre a evolução do sistema climático para a década em curso. Por outro lado, as projeções baseadas em dados ARGO indicam mudanças de maior magnitude, possivelmente refletindo a maior sensibilidade das observações *in situ* a processos oceânicos de alta frequência.

A diferença sistemática entre as projeções EN4 e ARGO pode ser atribuída a fatores metodológicos e de representatividade espacial. Enquanto o conjunto EN4 incorpora dados de múltiplas fontes através de procedimentos de assimilação que podem suavizar variações rápidas, as observações ARGO capturam com maior fidelidade processos locais e eventos extremos.

O padrão projetado é consistente com estudos recentes que associam mudanças no balanço de calor da região subpolar a variações de larga escala na circulação oceânica. Jackson et al. (2022) documentaram uma tendência de enfraquecimento de um componente-chave da circulação desde o final do século XX, enquanto Boers (2021) identificou sinais de alerta precoce para possíveis transições abruptas neste sistema. Nossos resultados reforçam estas preocupações, sugerindo que as mudanças projetadas podem estar associadas a uma maior ventilação oceânica e intensificação dos processos de formação de águas profundas na região subpolar.

A projeção de anomalias negativas persistentes a partir de 2023 antecipa as estimativas temporais de Boers (2021). Esta diferença pode estar relacionada à maior sensibilidade do modelo Random Forest a mudanças graduais nos padrões temporais, em comparação com abordagens baseadas exclusivamente em modelos físicos.

Em síntese, os resultados obtidos não apenas validam as projeções reportadas na literatura científica, mas também refinam a compreensão sobre o *timing* e a natureza destas mudanças, destacando a importância de considerar múltiplas fontes de dados e abordagens metodológicas complementares para a previsão de variáveis climáticas essenciais.

5. CONSIDERAÇÕES FINAIS

O modelo de *Random Forest* demonstrou ser uma ferramenta robusta e confiável para a previsão do Conteúdo de Calor Oceânico (OHC) no Atlântico Norte Subpolar, apresentando alta precisão e capacidade de generalização validada com dados independentes do programa ARGO. A consistência entre os cenários baseados em EN4 e ARGO reforça a credibilidade das projeções e evidencia o potencial de *machine learning* como complemento aos modelos físicos tradicionais.

As projeções indicam uma tendência de resfriamento na região para a próxima década, com implicações potenciais para a estabilidade da AMOC e para o clima global. As diferenças metodológicas entre EN4, que utiliza reanálise com assimilação, e ARGO, baseado em observações *in situ* com maior resolução vertical e superficial, explicam parcialmente as discrepâncias observadas nos níveis médios, amplitude e extremos do OHC. O modelo explorou características temporais da série histórica, como defasagens, médias móveis, tendências e sazonalidade, capturando sinais temporais com eficácia, embora apresentando limitações para eventos mediados por forçantes externas não incluídas no conjunto de preditores.

Futuros desenvolvimentos poderiam incorporar variáveis adicionais como índices de oscilações oceânicas, seguindo abordagens recentes que integram múltiplas fontes de dados em modelos preditivos oceânicos (LI. F et al., 2022; WANG et al., 2022), além de explorar modelos híbridos combinando *Random Forest* com redes neurais recorrentes para capturar dependências temporais de longo prazo. O desenvolvimento de sistemas de alerta

precoce baseados em indicadores de mudança de regime também representa uma frente promissora para antecipar potenciais *tipping points* oceânicos.

Em síntese, a combinação de dados de reanálise, observações *in situ* e técnicas de *machine learning* oferece uma abordagem promissora para o monitoramento e previsão do OHC, com aplicações diretas na compreensão da estabilidade climática e na formulação de políticas de adaptação e mitigação frente às mudanças climáticas. A metodologia aqui empregada mostrou-se particularmente adequada para regiões com infraestrutura limitada, representando uma alternativa eficiente e acessível para o monitoramento oceânico contínuo.

Os autores agradecem a Samsung Eletrônica da Amazônia Ltda., por meio do Projeto Aranouá, e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro por meio do Programa de Excelência Acadêmica (PROEX). Este trabalho é resultado do projeto de Pesquisa e Desenvolvimento (P&D) 001/2021, firmado com o Instituto Federal do Amazonas e a FAEPI, com financiamento da Samsung.

REFERÊNCIAS

ARGO. Programa de Flutuadores ARGO Global. SEANOE, 2020. Disponível em: <https://www.seanoe.org/data/00311/42182/>. Acesso em: 02 nov. 2025.

BOERS, N. Observation-based early-warning signals for a collapse of the Atlantic Meridional Overturning Circulation. *Nature Climate Change*, v. 11, n. 8, p. 680-688, 2021.

BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001.

BUCKLEY, M. W.; MARSHALL, J. Observations, inferences, and mechanisms of Atlantic Meridional Overturning Circulation variability: A review. *Reviews of Geophysics*, v. 54, n. 1, p. 5-63, 2016.

CAESAR, L. et al. Current Atlantic Meridional Overturning Circulation weakest in last millennium. *Nature Geoscience*, v. 11, n. 1, p. 13-15, 2018.

CHENG, L. et al. How fast are the oceans warming? *Science*, v. 363, n. 6423, p. 128-129, 2019.

CHENG, L. et al. Improved estimates of changes in upper ocean salinity and the hydrological cycle. *Journal of Climate*, v. 33, n. 23, p. 10357-10381, 2020.

GOOD, S. A.; MARTIN, M. J.; RAYNER, N. A. EN4: Quality controlled ocean temperature and salinity profiles and monthly objective analyses with uncertainty estimates. *Journal of Geophysical Research: Oceans*, v. 118, n. 12, p. 6704-6716, 2013. Disponível em: <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1002/2013JC009067>. Acesso em: 02 nov. 2025.

IPCC. *Climate Change 2021: The Physical Science Basis*. Cambridge University Press, 2021.

JACKSON, L. C. et al. Global and European climate impacts of a slowdown of the AMOC in a high resolution GCM. *Climate Dynamics*, v. 45, n. 11-12, p. 3299-3316, 2015.

JACKSON, L. C. et al. The evolution of the North Atlantic Meridional Overturning Circulation since 1980. *Nature Reviews Earth & Environment*, v. 3, n. 4, p. 241-254, 2022.

JOURDAIN, N. C. et al. Ocean heat content variability in the subpolar North Atlantic: mechanisms and predictability. *Climate Dynamics*, v. 58, n. 5-6, p. 1547-1565, 2022.

LENTON, T. M. et al. Tipping elements in the Earth's climate system. *Proceedings of the National Academy of Sciences*, v. 105, n. 6, p. 1786-1793, 2008.

LI, G. et al. Increasing ocean stratification over the past half-century. *Nature Climate Change*, v. 10, n. 12, p. 1116-1123, 2020.

LI, F. et al. Predicting sea surface temperature in the Atlantic Ocean using deep learning and random forest approaches. *Ocean Modelling*, v. 171, p. 101967, 2022.

LOZIER, M. S. Deconstructing the conveyor belt. *Science*, v. 328, n. 5985, p. 1507-1511, 2010.

LYNCH-STIEGLITZ, J. The Atlantic Meridional Overturning Circulation and abrupt climate change. *Annual Review of Marine Science*, v. 9, p. 83-104, 2017.

MENARY, M. B. et al. Aerosol-forced AMOC changes in CMIP6 historical simulations. *Geophysical Research Letters*, v. 47, n. 18, e2020GL088166, 2020.

OLLIULA, J. et al. Mechanisms of subpolar North Atlantic decadal-to-multidecadal variability in CMIP6 models. *Journal of Climate*, v. 36, n. 2, p. 563-580, 2023.

RAHMSTORF, S. Ocean circulation and climate during the past 120,000 years. *Nature*, v. 419, n. 6903, p. 207-214, 2002.

SMEED, D. A. et al. The North Atlantic Ocean is in a state of reduced overturning. *Geophysical Research Letters*, v. 45, n. 3, p. 1527-1533, 2018.

THORNALLEY, D. J. et al. Anomalously weak Labrador Sea convection and Atlantic overturning during the past 150 years. *Nature*, v. 556, n. 7700, p. 227-230, 2018.

VON SCHUCKMANN, K. et al. Heat stored in the Earth system: where does the energy go? *Earth System Science Data*, v. 12, n. 3, p. 2013-2041, 2020.

VON SCHUCKMANN, K. et al. Heat stored in the Earth system 1960-2020: where does the energy go? *Earth System Science Data*, v. 15, n. 4, p. 1675-1709, 2023.

WANG, Y. et al. Random forest-based prediction of oceanic variables using satellite-derived data. *Remote Sensing of Environment*, v. 268, p. 112780, 2022.

WEIJER, W. et al. Stability of the Atlantic Meridional Overturning Circulation: A review and synthesis. *Journal of Geophysical Research: Oceans*, v. 124, n. 8, p. 5336-5375, 2019.

ZHANG, R.; DELWORTH, T. L. Impact of Atlantic multidecadal oscillations on India/Sahel rainfall and Atlantic hurricanes. *Geophysical Research Letters*, v. 33, n. 17, L17712, 2006.