

MODELAGEM OCEÂNICA DA TSM SOB O CENÁRIO SSP5-8.5 COM MULTI-MODEL ENSEMBLE DO CMIP6

Nome do Autor(es)

Victor Gabriel de Jesus Cursi

Nome do Orientador(es)

Luiz Carlos Rodrigues de Medeiros

Luciana Novais Correia Santos

E.E. Lydia Kitz Moreira

Glossário

Sigla/Termo	Significado
AMOC	Circulação de Revolvimento Meridional do Atlântico (Atlantic Meridional Overturning Circulation)
API	Interface de Programação de Aplicações (Application Programming Interface)
Bias	Viés - O erro sistemático médio de um modelo em comparação com as observações.
CMIP6	Projeto de Intercomparação de Modelos Acoplados, Fase 6 (Coupled Model Intercomparison Project Phase 6)
Dataset	Conjunto de dados. Refere-se aos modelos climáticos.
Ensemble	Conjunto. Refere-se ao conjunto de modelos utilizados no estudo.
ENSO	El Niño-Oscilação Sul (El Niño-Southern Oscillation)
ESGF	Earth System Grid Federation - O portal onde os dados do CMIP6 são baixados.

Forçante Radiativa	É a alteração no balanço de energia da Terra causada por fatores naturais ou humanos. É medida em watts por metro quadrado (W/m ²)
GEE	Gases de Efeito Estufa
gn	Grade Nativa (Grid Native) - Refere-se à grade original em que a simulação do modelo foi executada.
GODAS	Sistema Global de Assimilação de Dados Oceânicos (Global Ocean Data Assimilation System)
Grade/grid Tripolar	Possui três polos artificiais em vez de apenas o polo norte geográfico.
IPCC	Painel Intergovernamental sobre Mudanças Climáticas (Intergovernmental Panel on Climate Change)
LTM	Média de Longo Prazo (Long Term Mean) - A climatologia de um período de referência.
Multi-model ensemble	Conjunto de multi-modelos. Refere-se a um conjunto de multi-modelos utilizados para projetar ou reanalisar o clima.
N_members	refere-se ao número de membros de um <i>ensemble</i> (ou conjunto de simulações) realizados com o mesmo modelo climático.
NASA	Administração Nacional da Aeronáutica e Espaço (National Aeronautics and Space Administration)

NetCDF	Formato de Dados Comuns em Rede (Network Common Data Form) - O formato .nc dos arquivos.
Niño 3.4	Uma das principais regiões de monitoramento do ENSO no Pacífico Equatorial.
NOAA	Administração Nacional Oceânica Atmosférica (National Oceanic and Atmospheric Administration)
ODV	Visualizador de Dados Oceânicos (Ocean Data View)
OISSTv2	Temperatura da Superfície do Mar por Interpolação Ótima, Versão 2 (Optimum Interpolation Sea Surface Temperature)
Omon	Dados Oceânicos Mensais (Ocean Monthly) - O table_id para variáveis oceânicas com frequência mensal.
Pixel	Cada pixel representa um pequeno ponto com uma cor específica, e milhões deles juntos formam imagens em telas, fotos ou vídeos.
Plot	Refere-se ao ato de criar uma figura mediante código.
PSL	Laboratório de Ciências Físicas (Physical Sciences Laboratory) da NOAA.
QGIS	Sistema de Informação Geográfica Quantum (Quantum Geographic Information System)

rlilplfl	Etiqueta da Variante (Variant Label) - O "código de identidade" de uma simulação específica do CMIP6.
RCP	Representative Concentrations Pathway ou Caminho de Concentração Representativo
Regridding	“Regradeamento” - O processo de interpolar dados de uma grade espacial para outra.
RMSE	Raiz do Erro Quadrático Médio (Root Mean Square Error)
Script	Código. Refere-se ao código utilizado para a visualização dos dados projetados.
SSP	Trajectoria Socioeconômica Compartilhada (Shared Socioeconomic Pathway)
SSP5-8.5	Um cenário futuro de altas emissões de GEE, com um forçamento radiativo de 8.5 W/m ² em 2100.
SST	Temperatura da Superfície do Mar (Sea Surface Temperature).
TOS	Temperatura da Superfície do Oceano (Temperature of Ocean Surface) - O nome padrão (variable_id) para SST no CMIP6.
TSM	Temperatura da Superfície do Mar (Acrônimo em português).

WCRP	Programa Mundial de Pesquisa Climática (World Climate Research Programme)
Workflow	Fluxo de trabalho. Refere-se ao conjunto metodológico empregado no estudo.
xESMF	Biblioteca em Python para regradeamento, baseada na ferramenta ESMF (Earth System Modeling Framework).

RESUMO

Os oceanos desempenham papel fundamental na regulação do sistema climático terrestre, sendo a Temperatura da Superfície do Mar (TSM) um indicador-chave para o monitoramento e projeção das mudanças climáticas. Este estudo investiga as projeções de variação da TSM para o final do século XXI (2081–2100), com base em um conjunto de 12 modelos climáticos do CMIP6, sob o cenário de altas emissões SSP5-8.5. A metodologia adotada incluiu a avaliação do desempenho dos modelos em relação aos dados de reanálise GODAS, por meio de métricas estatísticas como viés (*Bias*) e erro quadrático médio (RMSE). Os resultados indicam um aquecimento médio global da TSM de $3,01\text{ }^{\circ}\text{C} \pm 0,52\text{ }^{\circ}\text{C}$ em comparação ao período histórico (1981–2010), com variações entre $2,00\text{ }^{\circ}\text{C}$ e $4,01\text{ }^{\circ}\text{C}$ entre os modelos. As projeções evidenciam os riscos climáticos associados ao cenário de altas emissões e ressaltam a relevância da abordagem multi-modelo para a análise das incertezas inerentes às simulações climáticas.

Palavras-chave: TSM. SSP5-8.5. Mudanças Climáticas. Multi-Model Ensemble. CMIP6.

INTRODUÇÃO

Uma das frases mais impactantes dos últimos anos: “é inequívoco que a influência humana aqueceu a atmosfera, o oceano e a terra.” (IPCC, 2021), revela que as ações antropogênicas estão diretamente ligadas as mudanças climáticas recentes. De acordo com Henrique Cortez (2022), as mudanças observadas ao longo do século XX incluem aumentos na temperatura global do ar e do oceano, aumento do nível do mar global, redução generalizada

da cobertura de neve e gelo, e mudanças na circulação atmosférica e oceânica, bem como variações nos padrões climáticos regionais, que influenciam as chuvas sazonais. Essas mudanças são causadas pelo calor extra no sistema climático devido à adição dos GEE (Gases do Efeito Estufa) à atmosfera. Esses GEE adicionais são gerados principalmente por atividades humanas, como a queima de combustíveis fósseis (carvão, petróleo e gás natural), desmatamento, agricultura e mudanças no uso da terra. (FENG, L. et al., 2020)

Objetivos de Desenvolvimento Sustentável (ODS)

A relevância deste projeto, é amplificada por sua conexão direta com os Objetivos de Desenvolvimento Sustentável (ODS) estabelecidos pela Organização das Nações Unidas (ONU). Os ODS são uma iniciativa da ONU criada em 2015 como parte da Agenda 2030. Elas reúnem 17 objetivos globais (ver Figura 1) que visam diferentes metas para o desenvolvimento da humanidade. Os objetivos são usados como guia para governos, empresas e sociedade trabalharem juntos em prol de um futuro mais justo e sustentável para todos. (ORGANIZAÇÃO DAS NAÇÕES UNIDAS, 2025)

Figura 1: ODS's



Fonte: Google (INSTITUTO CATARINENSE DE RECURSOS HUMANOS, 2025)

A pesquisa aborda diretamente o ODS 13 (Ação contra a mudança global do clima) (ver Figura 1), ao realizar análises e fornecer projeções detalhadas que são essenciais para a compreensão e mitigação das mudanças climáticas futuras. Ademais, ao focar na variável da


Temperatura da Superfície do Mar, o projeto também contribui para o ODS 14 (Vida na água), pois o aquecimento oceânico é uma das principais ameaças para o ecossistema marinho, a biodiversidade e a segurança alimentar de comunidades costeiras. Por fim, os resultados também indicam ligação com o ODS 11 (Cidades e comunidades sustentáveis), devido ao aquecimento dos oceanos estar ligado a elevação do nível do mar e mudanças nos padrões de chuvas, representando um risco direto às comunidades que povoam as zonas costeiras e cidades despreparadas para intensas chuvas e mudanças robustas nos padrões climáticos regionais. (COLUSSO, 2023)

Oceanos

Os oceanos absorveram ao longo dos últimos 60 anos uma quantidade oito vezes maior do que a quantidade que os humanos utilizaram nesse período para realizar tarefas como cozinhar, gerar eletricidade, na indústria, etc. (FENG, L. et al., 2020). Cobrindo mais de 70% da superfície terrestre, o oceano global tem uma capacidade térmica muito alta. Ele absorveu cerca de 90% do aquecimento ocorrido nas últimas décadas devido à intensificação dos GEE. Sendo a maioria da energia concentrada na superfície, a uma profundidade de zero a 700 metros. Esses primeiros metros do oceano, são responsáveis por armazenar tanto calor quanto toda a atmosfera terrestre. (NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, 2024)

Os oceanos desempenham um papel fundamental, sendo considerados o “ar-condicionado” do planeta. Por meio do MOC (Circulação de Revolvimento Global), os oceanos transferem calor às regiões polares, esfriam as regiões tropicais, e realizam trocas de massas d’água, trazendo um equilíbrio natural para o planeta (MARCÍLIO, 2020). Sendo assim, o Oceano Austral (Antártico), é considerado o mais importante, conectando as 3 maiores bacias oceânicas através da Corrente Circumpolar Antártica, desempenhando um papel fundamental no equilíbrio do sistema climático da Terra (MARCÍLIO, 2020). A Figura a seguir, ilustra as principais correntes marítimas de maneira clara e objetiva. Sendo cada uma delas, essenciais para a manutenção do clima terrestre.

Figura 2: Ilustração das Principais Correntes Marítimas



Fonte: Adaptado de BARDINE (2025)

Um dos principais problemas relacionados às mudanças climáticas nos oceanos, está nas variações anormais das características de massas d'água. As massas d'água são um conjunto de água em que suas características diferem do oceano em que está inserida (ex: água fria levada para região tropical). Quando há anomalia da TSM (Temperatura Superficial do Mar), ocorre o derretimento do gelo e de geleiras nas regiões polares por meio das modificações em massas d'água fria (CIÊNCIA NO MAR, 2025). Com isso, o derretimento de geleiras derruba blocos de gelo no mar, e o derretimento desses blocos, adoça a água da região intermediária (entre 500 e 1500 metros de profundidade). Diferente da água salgada, que detém mais íons dissolvidos, responsáveis por reagir com o dióxido de carbono e reter grande parte do CO₂. A água doce também absorve CO₂, entretanto, com menor capacidade de retenção do que a água salgada. Ou seja, com menor capacidade de retenção do CO₂ por parte dos oceanos (diminuição da salinidade), o CO₂ permanece na atmosfera, causando assim o aumento da temperatura do ar por meio do efeito estufa (CIÊNCIA NO MAR, 2025).

El Niño

Um dos principais eventos relacionados às correntes marítimas é o El Niño. Sendo um fenômeno climático conhecido como El Niño-Oscilação Sul (ENSO), caracterizado por um aquecimento anormal das águas superficiais do Pacífico Equatorial. Sendo esse aquecimento resultado do enfraquecimento dos ventos alísios (CPTEC/INPE, 2025). Os ventos alísios são ventos constantes que sopram dos trópicos em direção ao Equador, eles são responsáveis por “empurrar” as águas quentes superficiais para oeste do Oceano Pacífico, causando ressurgência das águas frias superficiais próximas à costa da América do Sul (ver Figura 1 - Corrente de Humboldt ‘fria’ e Corrente Sul e Norte Equatorial ‘quente’). O enfraquecimento desses ventos, leva ao acúmulo das águas quentes superficiais localizadas próximas à costa da América do Sul, levando ao aquecimento anormal das águas do Pacífico Equatorial Leste. Essas alterações provocam mudanças imensas nos padrões de circulação atmosférica, principalmente nos padrões de chuvas do globo. Trazendo assim, impactos climáticos globais. (MARCÍLIO, 2020)

Modelagem Climática

O relatório do IPCC (2021), avalia a resposta do clima a cinco possíveis cenários de emissões de GEE, cobrindo possíveis desenvolvimentos futuros e a intensidade dos fatores antropogênicos. Esses cenários são projetados a partir de períodos temporais, onde “Near Term” refere-se ao curto prazo (2021–2040), “Mid Term” ao médio prazo (2040–2060) e “Long Term” ao longo prazo (2081-2100) (ver Tabela 1).

A figura a seguir foi adaptada diretamente do IPCC AR6 (2021), e nos indica a magnitude da **mudança da temperatura do ar** em graus Celsius, considerando o cenário SSP (Shared Socioeconomic Pathway) e os cenários temporais.

Tabela 1: Cenários Temporais e SSP's

Cenários SSP's

Projeções futuras para cada cenário temporal e SSP.

	Near Term (2021-2040)	Mid Term (2040-2060)	Long Term (2081-2100)
Cenário	Melhor estimativa (°C)		
SSP1-1.9	1.5	1.6	1.4
SSP1-2.6	1.5	1.7	1.8
SSP2-4.5	1.5	2.0	2.7
SSP3-7.0	1.5	2.1	3.6
SSP5-8.5	1.6	2.4	4.4

Source: IPCC AR6 SPM (2021) • Created with Datawrapper

Fonte: Adaptado do IPCC (2021)

Os SSP são os Caminhos Socioeconômicos Compartilhados (Shared Socioeconomic Pathway), eles projetam as mudanças no cenário socioeconômico conforme as mudanças nas emissões de GEE até o ano de 2100. É acoplado a ele, o RCP (Representative Concentrations Pathway ou Caminho de Concentração Representativo) que forma um conjunto de concentração de GEE, medindo o nível da forçante radiativa projetada até o ano de 2100 (CURSI et al., 2025), (IPCC, 2021). Para este estudo, o cenário selecionado SSP 5-8.5, representa o SSP 5: um cenário de emissões de GEE que dobram em 2050, onde a principal característica é a exploração abundante de recursos como combustíveis fósseis e um estilo de vida com o uso abundante de recursos e energia, com o RCP 8.5: sendo o caminho nos quais as emissões continuam a aumentar ao longo do século XXI, e têm uma forçante radiativa de 8.5 W/m². (GEO COSTEIRA, 2021)

Os modelos climáticos são as ferramentas que aplicam esses cenários e nos entregam diferentes resultados que dependem das variáveis e do modelo em questão (IPCC, 2021). Esses modelos funcionam mediante cálculos matemáticos computacionais, que simulam o sistema climático da Terra, por meio de processos físicos, químicos e biológicos, que ocorrem na

atmosfera, oceanos, superfície terrestre e na criosfera. Os modelos podem simular o clima passado, analisar o presente ou projetar cenários futuros, utilizando leis da física (como conservação de energia, massa e momento), sendo executados em supercomputadores devido à enorme quantidade de cálculos envolvidos nas simulações. Os modelos climáticos nos permitem entender como os diferentes fatores (como as emissões de GEE, uso do solo, etc.) influenciam a evolução do clima global e regional ao longo do tempo. (Forest-GIS, 2022)

Devido à complexidade e a incerteza presente nos modelos individuais, são utilizados os MIPs (Model Intercomparison Projects). Que são iniciativas internacionais que reúnem os centros de pesquisa em todo o globo para comparar e avaliar os modelos climáticos sob padrões pré-definidos, que permitem verificar consistência, identificar incertezas entre os modelos, e melhorar a compreensão dos processos climáticos. Cada fase do MIP organiza experimentos, cujos resultados são disponibilizados para a comunidade científica e servem de base para relatórios, como os do IPCC. Nesse contexto, nosso estudo utiliza a fase mais recente, o CMIP6 (Coupled Model Intercomparison Project — Phase 6), a qual é a sexta fase do maior esforço internacional de comparação de modelos climáticos, coordenado pelo WCRP (World Climate Research Programme ou Programa Mundial de Pesquisa Climática). Ele reúne resultados de cerca de 100 modelos desenvolvidos por 49 centros de pesquisa ao redor do mundo, demonstrando sua variedade. Além disso, o CMIP6 foi a base científica principal utilizada no AR6 (Sixth Assessment Report ou Sexto Relatório de Avaliação) do IPCC (2021) (Forest-GIS, 2022).

HIPÓTESES

Hipótese 1: Os modelos climáticos do CMIP6 apresentam variações significativas na projeção da TSM para o período de 2081–2100, refletindo incertezas associadas ao cenário de altas emissões SSP5-8.5.

Hipótese 2: O desempenho histórico dos modelos, medido por métricas como *Bias* médio global, RMSE e Correlação espacial, influencia diretamente a confiabilidade das projeções futuras de TSM, sendo possível identificar modelos mais robustos para estudos climáticos de longo prazo.

OBJETIVO

Geral

O objetivo principal do projeto é analisar a projeção de mudança na Temperatura da Superfície do Mar (TSM) em escala global para o período *long term* (2081-2100), em relação ao período histórico 1981–2010, utilizando um *ensemble* de 12 modelos de simulação climática do projeto CMIP6 sob o cenário de altas emissões do SSP5-8.5.

Específicos

- **Selecionar** 12 modelos do projeto CMIP6 compatíveis com os interesses do projeto.
- **Avaliar** o desempenho de cada modelo, simulando o clima histórico, e calculando as métricas de *Bias* médio global, RMSE (Erro Quadrático Médio) ponderado pela área e o Coeficiente de Correlação espacial.
- **Analisar** as projeções futuras gerando um mapa da anomalia de TSM média projetada e uma tabela do desvio padrão entre os modelos.
- **Validar** a metodologia de análise e visualização dos dados utilizando o evento El Niño de 2023–2024 como estudo de caso, e comparando os dados observados com uma base de dados de referência.

METODOLOGIA

Nesta seção, apresentaremos os principais métodos utilizados na pesquisa. Desde as fontes, até a validação do *workflow* (fluxo de trabalho).

Fontes de Dados e ferramentas:

1. Fontes de Dados:

- a. Para os modelos climáticos das projeções, selecionamos e agrupamos um *ensemble* com 12 modelos de diferentes instituições pertencentes ao projeto CMIP6, e que continham a variável de interesse da Temperatura da Superfície do Mar (*TSM/TOS/SST*). A maioria das nomenclaturas e definições do projeto seguem os padrões oficiais definidos pelo World Climate Research Programme para o projeto CMIP6 (WORLD CLIMATE RESEARCH PROGRAMME, 2025).

- b. Outros elementos importantes para a filtragem foram: experimentos com o cenário de altas emissões SSP5-8.5; com simulações históricas (*historical*) que variam de 1850 a 2014; com um intervalo mensal (*Omon*) e com as variantes “r1i1p1f1”.
- c. Formato dos arquivos: NetCDF (.nc). Todos os arquivos foram baixados e filtrados diretamente do portal de busca oficial da Earth System Grid Federation (2025)

Tabela 2: Catálogo dos 12 Modelos Selecionados

Modelos (projeções)

Tabela com 12 modelos selecionados do CMIP6

	model	variable_ID	n_members	expID_historical	expID_ssp585	variante_label	grid_label	table_id
1	CanESM5-1	tos	72	1850-2014	2015-2100	r1i1p2f1	gn	Omon
2	CanESM5	tos	65	1850-2014	2015-2100	r1i1p1f1	gn	Omon
3	MIROC6	tos	50	1850-2014	2015-2100	r1i1p1f1	gn	Omon
4	ACCESS-ESM1-5	tos	40	1850-2014	2015-2100	r1i1p1f1	gn	Omon
5	IPSL-CM6A-LR	tos	33	1850-2014	2015-2100	r1i1p1f1	gn	Omon
6	MRI-ESM2-0	tos	12	1850-2014	2015-2100	r1i1p1f1	gn	Omon
7	CMCC-CM2-SR5	tos	11	1850-2014	2015-2100	r1i1p1f1	gn	Omon
8	CAS-ESM2-0	tos	4	1850-2014	2015-2100	r1i1p1f1	gn	Omon
9	BCC-CSM2-MR	tos	3	1850-2014	2015-2100	r1i1p1f1	gn	Omon
10	CESM2-WACCM	tos	3	1850-2014	2015-2100	r1i1p1f1	gn	Omon
11	FIO-ESM-2-0	tos	3	1850-2014	2015-2100	r1i1p1f1	gn	Omon
12	CMCC-ESM2	tos	1	1850-2014	2015-2100	r1i1p1f1	gn	Omon

Source: EARTH SYSTEM GRID FEDERATION, 2025 • Created with Datawrapper

Fonte: (EARTH SYSTEM GRID FEDERATION, 2025)

- d. Obs.: O modelo “CanESM5-1” foi utilizado a variante física “p2” ao invés da “p1”, por motivos de melhores resultados, já que a “p1” apresenta efeitos extremamente parecidos com o modelo antecessor “CanESM5” (SIGMOND et al., 2023). E com o modelo “MIROC6” foi realizada uma concatenação entre dois arquivos *historical* (1850–1950 com 1950–2014).
- e. Para o modelo com os dados observacionais (referência histórica), escolhemos o *dataset* GODAS (*Global Ocean Data Assimilation System*) (BEHRINGER et al., 1998; BEHRINGER e XUE, 2004), que pode ser obtido através do portal online do Physical Sciences Laboratory (PSL) da National Oceanic and Atmospheric Administration (NOAA).
- f. Para o modelo de dados observacionais do estudo de caso com o El Niño, foi utilizado o NOAA OISSTv2 High-Resolution (*Optimum Interpolation Sea Surface Temperature*)

(REYNOLDS et al., 2007). Que também pode ser obtido através do portal online do PSL da NOAA.

- g. É interessante salientar que neste estudo, utilizamos dois tipos de dados observacionais. Apesar de ambos serem referenciados como dados observacionais, há uma diferença entre eles. O OISSTv2 é um *dataset* de dados interpolados, enquanto o GODAS é um *dataset* de reanálise baseada na assimilação de dados. Onde os dados interpolados confiam primariamente nos dados de boias e satélites, preenchendo “lacunas” inteligentemente com cálculos matemáticos. E a reanálise é uma técnica de assimilação de dados, onde o modelo é corrigido com dados de observações reais durante as simulações históricas. Portanto, *dataset's* de dados interpolados são idealmente utilizados para análise de eventos específicos do passado (como o ENSO). Enquanto os modelos de reanálise são ideais para análise de climatologia, por existir consistência física entre as variáveis (temperatura, ventos, correntes, etc.). (REYNOLDS et al., 2007) (BEHRINGER; XUE, 2004)

2. Ferramentas:

- a. Os softwares e sites para visualização e análise inicial foram: Panoply, QGIS, Copernicus Monitoring Service LEARN, Copernicus Monitoring Service PRO e Ocean Data View (ODV).
- b. Para a edição e criação de tabelas, imagens, etc. Foram utilizados: Canva, Rows, DataWrapper, Gemini (Nano-Banana). Além deles, utilizamos IA+Python para criar gráficos a partir da biblioteca Seaborn.
- c. Para pesquisas e fontes: Google, Gemini 2.5 Pro, LMArena, ChatGPT, YouTube, Google Scholar, Cartopy API, Python API, Matplotlib API, PDF's, artigos e todas as fontes de informações encontradas na seção de Referências.
- d. Para o desenvolvimento do código na linguagem de programação Python versão 3.13, utilizamos o Anaconda Prompt e Microsoft Visual Studio Code 2025 para visualizar o código. O Gemini 2.5 Pro, GPT-5 e Claude Sonnet 3.5 como copiloto. As bibliotecas utilizadas foram: xarray, xesmf, numpy, matplotlib, cartopy, dask e seaborn.

Padronizações:

1. Padronização dos Dados:

- a. Decidimos padronizar as grades de resolução (*grid*) de cada modelo utilizado. O nosso dataset observacional GODAS tem um *grid* menor do que os demais modelos climáticos. Isso nos leva ao problema de desalinhamento dos mapas, que se torna um obstáculo para o processo de cálculos e *plot* do resultado.
- b. Por isso, utilizamos um método de *regridding* (alinhamento) utilizando a biblioteca xESMF para padronizar e converter todos os *grids* para o do modelo observacional GODAS (XESMF, 2025).

2. Padronização dos Períodos:

- a. Segundo a WORLD METEOROLOGICAL ORGANIZATION (2025), o período definido como normalidade climatológica são médias dos dados climatológicos computados pelos seguintes períodos consecutivos de 30 anos: 1 de janeiro de 1981 a 31 de dezembro de 2010, 1 de janeiro de 1991 a 31 de dezembro de 2020, etc. Portanto, seguindo a referência padrão de 30 anos, selecionamos o período de 1981–2010 para o período histórico. Já para o período futuro, segundo o IPCC (2021), o *long term* do cenário de altas emissões SSP5-8.5 refere-se aos anos de 2081–2100, portanto utilizaremos esse período para o referencial futuro das simulações.

Validação da Metodologia:

1. **Propósito:** Com o propósito de validar e testar a eficácia do *workflow* (leitura dos dados, processamento e visualização), selecionamos um evento real e bem documentado para um estudo de caso.

2. Descrição:

O evento em questão é o El Niño de 2023–2024. Utilizamos o software Panoply para a leitura dos dados. Os dados observacionais utilizados, assim como mencionado anteriormente, é o NOAA OISSTv2 High-Resolution (*Optimum Interpolation Sea Surface Temperature*) (REYNOLDS et al., 2007). Ele será utilizado para criar 4 mapas de anomalia da TSM diária. Que serão analisados e comparados aos dados do índice oficial Niño 3.4.

DESENVOLVIMENTO

Nesta seção, descreveremos o processo prático da pesquisa, desde a seleção dos modelos, até a execução dos cálculos e superação de obstáculos técnicos.

1. Modelos

Os modelos baseiam-se nos cenários de emissões de GEE (SSPs), considerando, inclusive, características sociais, econômicas e industriais (JOSÉ RIBAMAR et al., 2024). Devido a esses diversos fatores, a incerteza dos modelos se torna o ponto mais discutido quando se trata de modelagem climática e sua confiabilidade. Segundo Hawkins e Sutton (2009), há três principais fontes de incerteza:

- a. Variabilidade interna:** flutuações naturais do clima, como o El Niño;
- b. Incerteza do modelo:** limitações e diferenças entre os modelos;
- c. Incerteza do cenário:** suposições sobre futuras emissões de GEE.

A variabilidade interna pode ser considerada o segundo maior problema, já que o próprio fenômeno do El Niño é uma variável complexa e o sistema climático é aleatório, mesmo que os GEE fossem constantes, ainda haveria anos naturalmente mais quentes (com El Niño interno do modelo) e mais frios. A incerteza do cenário torna-se um problema dominante em projeções a longo prazo, ao dificultar a projeção da quantidade de GEE emitidos pelas ações antropogênicas, então utilizamos os SSP como base para essa métrica. E a incerteza do modelo é geralmente a maior fonte de incerteza (HAWKINS; SUTTON, 2009).

Os modelos, individualmente, são representações imperfeitas da realidade. O modelo “A” pode ser sensível demais ao CO₂, enquanto o modelo “B” sensível “de menos”. Ou seja, cada modelo tem seu próprio *bias* (viés), sua própria “personalidade”. Não podemos dizer qual está certo, pois todos têm seus erros e acertos. Com isso, Hawkins e Sutton (2009) utilizaram um *multi-model ensemble* (conjunto de multi-modelos) como ferramenta para quantificar as principais fontes de incertezas, destacando que o uso de *multi-model ensemble* permite uma aplicação mais confiável e uma estimativa mais robusta entre as respostas de variabilidade interna e incertezas associadas a cada modelo. Portanto, esse estudo se propõe a utilizar um *multi-model ensemble* com 12 modelos distintos do CMIP6.

Tabela 3: Os 12 Modelos e suas Personalidades

Source ID (p/ TOS)	Institution ID (Instituição/ País)	Ano de Lançamento	Resolução (Atmosfera/ Oceano) (em °)	Personalidade
CanESM5-1	CCCma/EC CC (Canadá)	2022	$\approx 2.8^\circ / \approx 1.0^\circ$	Com refinamento da resolução para $\approx 0.33^\circ$ no Equador; Oceano: ENSO ajustado (no p2); Redução da sensibilidade climática (comparando com ESM5.0); Viés: Gelo marinho superestimado.
CanESM5	CCCma/EC CC (Canadá)	2019	$\approx 2.8^\circ / \approx 1.0^\circ$	Com refinamento da resolução para $\approx 0.33^\circ$ no Equador; Muitos ensembles; Oceanos: Problemas regionais; Sensibilidade climática MUITO ALTA! A maior entre os modelos do CMIP6; Viés importante: simula mais aquecimento histórico do que o observado.
MIROC6	MIROC (Japão)	2017	$\approx 1.4^\circ / \approx 1.0^\circ$	Simula muito bem o ENSO, um dos melhores do CMIP6 nesse quesito; Sensibilidade climática: baixa
ACCESS-ESM1-5	CSIRO (Austrália)	2019	$\approx 1.9^\circ \times 1.25^\circ / \approx 1.0^\circ$	Sensibilidade climática: moderada; Muitos membros; TOS significativo no Hemisfério Norte.
IPSL-CM6A-LR	IPSL (França)	2017	$\approx 2.5^\circ \times 1.3^\circ / \approx 1.0^\circ$	Sensibilidade climática: alta; Tende a aquecer mais que as observações; Utiliza um <i>grid</i> tripolar extremamente sofisticado.
MRI-ESM2-0	MRI (Japão)	2017	$\approx 1.1^\circ / 1.0^\circ \times 0.5^\circ$	Resolução aprimorada em $\approx 0.33^\circ$ na linha do Equador; Melhoria na simulação de nuvens; Exagera no resfriamento histórico; Sensibilidade climática: moderada.
CMCC-CM2-SR5	CMCC (Itália)	2016	$\approx 1.0^\circ / \approx 1.0^\circ$	Resolução aprimorada em $\approx 0.33^\circ$ na linha do Equador;

				Utiliza um <i>grid</i> tripolar extremamente sofisticado; Transporte de calor e AMOC consistentes com reanálises; Sensibilidade climática: moderada.
CAS-ESM2-0	CAS (China)	2019	$\approx 1.4^\circ / \approx 1.0^\circ$	Refinamento meridional de 0.5° na linha do equador; Sensibilidade climática: moderada.
FIO-ESM2-0	FIO-QLNM (China)	2018	$\approx 1.25^\circ \times 0.9^\circ / \approx 1.0^\circ$	Alta resolução na direção da latitude; ENSO bem capturado; TOS diurna superestimada; Sensibilidade climática: moderada.
CESM2-WACCM	NCAR (EUA)	2018	$\approx 1.25^\circ \times 0.9^\circ / \approx 1.0^\circ$	"Whole-atmosphere", melhora a variabilidade de alta latitude e influencia forçantes radiativas; Sensibilidade Climática: alta
BCC-CSM2-MR	BCC (China)	2017	$\approx 1.1^\circ /$ Variável ($\approx 0.33^\circ$ a $\approx 1.0^\circ$)	Grade de resolução variável: Alta resolução nos trópicos, para mais baixa nas altas latitudes; Mar de Weddell quente; ENSO realista; Sensibilidade climática: moderada.
CMCC-ESM2	CMCC (Itália)	2017	$\approx 1.0^\circ / \approx 1.0^\circ$	Resolução aprimorada no Equador ($\approx 0.33^\circ$); Utiliza um <i>grid</i> tripolar extremamente sofisticado; Capta calor profundo extra (TOS histórico); Ártico quente; Base no CMCC-CM2-SR5; Sensibilidade climática: moderada

Fonte: Própria

A tabela (ver Tabela 3), revela as diversas personalidades e configurações distintas de cada modelo. O *ensemble* selecionado é diverso, incluindo modelos de alta e baixa resolução (de $\approx 1.0^\circ$ a $\approx 2.8^\circ$), desenvolvidos por instituições de pesquisa de 8 países diferentes. Desde modelos om grades variáveis (BCC-CSM2-MR) até aqueles com refinamentos equatoriais para otimizar a simulação do ENSO (MRI-ESM2-0). Analisando o *ensemble* em sua totalidade, é


possível não só realizar uma projeção mais consensual, mas também podemos quantificar a incerteza associada a essa projeção.

2. Estudo de caso com o El Niño

Para validar a metodologia e o workflow das simulações principais, fizemos uma análise utilizando dados do El Niño mais recente (2023–2024). Para analisar o evento, foram utilizados dados observacionais da Temperatura da Superfície do Mar (TSM), provenientes do conjunto de dados NOAA Optimum Interpolation Sea Surface Temperature (OISST) Version 2 High-Resolution (REYNOLDS et al., 2007). As anomalias diárias são calculadas a partir da climatologia dos anos de 1971–2000, conforme especificado na documentação do produto fornecida pela Physical Sciences Laboratory da NOAA (NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION, 2014).

A Figura 3 apresenta o mapa das regiões de monitoramento do ENOS no Pacífico Equatorial. Essas regiões costumam ser as mais afetadas pelo evento, fazendo com que os cientistas as observem periodicamente, à procura de novas pistas que indiquem a aparição do El Niño.


Figura 3: Mapa das Regiões de Monitoramento do El Niño-Oscilação Sul (ENOS) no Oceano Pacífico Equatorial.



Fonte: Adaptado de Kozar et al. (2012).

A análise da evolução do El Niño foi organizada em quatro fases: Anterior ao Início, Início, Pico e Fim. O objetivo principal é identificar as principais características tipicamente encontradas durante o evento do El Niño, como a concentração de águas quentes nas principais regiões de monitoramento do ENOS (ver Figura 3) e a ressurgência de águas frias na costa do Peru.

Figura 4: Mapa de Anomalia da TSM Diária do El Niño.



Fonte: Própria (Software Panoply)

No mapa 1 (Antes do El Niño, ver Figura 4), observamos a ressurgência das águas frias na costa do Peru, causada pelos ventos alísios (que sopram de leste para oeste), que evidenciam as águas frias profundas, e movem as águas quentes superficiais de toda a região do Pacífico Equatorial Leste para oeste. Esse é o comportamento esperado das correntes no Oceano Pacífico.

A mudança torna-se claramente visível no mapa 2 (Início do El Niño, ver Figura 4). A região do Pacífico Equatorial Leste agora apresenta uma cor avermelhada, representando o aumento de anomalia da TSM naquela região em relação ao período histórico. Além disso, observa-se que a costa Peruana está avermelhada, com um pico de anomalia da TSM próxima aos 5,0 °C. Isso provavelmente se deve pelo fato de que a anomalia tende a ser ainda maior nas regiões que já eram mais frias do que o período histórico.

Próximo ao pico do El Niño 2023–2024, observamos com clareza as mudanças causadas por esse evento no mapa 3 (Pico do El Niño, ver Figura 4). Todo o Pacífico Equatorial Leste se

mostra com uma anomalia ainda mais elevada do que o observado durante o início. Percebe-se que aquela região tem uma anomalia de aproximadamente 2 °C. O que está conforme o documento oficial sobre a região Niño 3.4 no mês de janeiro de 2024 (CLIMATE PREDICTION CENTER, 2025). Validando quantitativamente os resultados obtidos com o experimento.

Por fim, no mapa 4 (Fim do El Niño, ver Figura 4), é possível observar a ressurgência das águas frias na costa da América do Sul ocorrendo novamente; e um “segmento” de águas frias nas regiões Niño1+2 e 3 (ver Figura 3), revelando a aproximação do encerramento do fenômeno El Niño.

Com isso, observou-se que a metodologia e *workflow* de processamento e visualização de dados, captou todas as principais características do evento, desde o início até seu declínio, com anomalias que correspondem aos índices oficiais. Portanto, com a metodologia validada por um evento real observado, podemos aplicar com ainda mais confiança nas projeções futuras com o *multi-model ensemble* do CMIP6.

3. Principais Métricas

Nesta seção, definiremos e explicaremos todos os cálculos e métricas utilizados no *script* para visualizar e manipular os dados e arquivos NetCDF. A biblioteca que utilizamos para os cálculos é a NumPy (HARRIS et al., 2020), que agiliza e automatiza as fórmulas mais complexas.

- a. **Climatologia Histórica (LTM-Long Term Mean):** Representa a média para um período histórico, servindo como base para todas as comparações. Em nosso caso, o LTM de todos os modelos, segue o padrão de 1981–2010. O cálculo para isso é a média temporal dos dados para o período de referência (WORLD METEOROLOGICAL ORGANIZATION, 2017). A linguagem de programação utilizada já possibilita o cálculo com a função “*.mean*” (representa o cálculo da média selecionando a variável), então não foi necessário adicionar fórmulas.
- b. **Anomalia Projetada (Δ):** A anomalia (delta ou signal) é a mudança projetada pelo modelo, removendo o *bias* sistemático interno do mesmo. É uma abordagem padrão na análise de projeções climáticas (IPCC, 2021).

$$\Delta = \text{Média Projetada} - \text{LTM Observada} \quad (1)$$

A fórmula (1) representa a mudança que o modelo produzirá. Ou seja, uma anomalia de valor positivo representa uma mudança inclinada ao aquecimento em relação ao período de referência. Uma anomalia negativa indica um resfriamento em relação ao mesmo período de referência.

- c. **Bias do Modelo (Viés):** O erro médio de um modelo comparado às observações para o período de referência. Indica a tendência do erro do modelo em relação à realidade.

$$\text{Bias} = \text{LTM do Modelo} - \text{LTM Observado} \quad (2)$$

Ao calcular o *bias* do modelo através da fórmula (2), é possível identificar o viés dele em relação ao modelo de referência (reanálise). (TAYLOR, 2001)

- d. **Raiz do Erro Quadrático Médio (RMSE):** É a magnitude média do erro do modelo. Enquanto o *bias* indica a tendência média do erro de um modelo, ele pode mascarar problemas importantes, pois erros positivos e negativos podem se cancelar na média global. Para obter a magnitude média do erro, utiliza-se a Raiz do Erro Quadrático Médio (RMSE). Portanto, o RMSE representa a “distância” entre o erro do modelo em relação à realidade observada. No *script*, foram utilizadas três variações do RMSE. Obs.: As fórmulas são simplificadas nas linhas de códigos através da biblioteca NumPy.

$$\text{RMSE}_{\text{mapa}} = \sqrt{(\text{LTM}_{\text{mod}} - \text{LTM}_{\text{obs}})^2} \quad (3)$$

Esta fórmula (3) representa o mapa (LTM_mod-LTM_obs), que mostra a magnitude do erro em cada *pixel* do globo. Não é um “número”. (WILLMOTT, 1981)

$$\text{RMSE}_{\text{global}} = \sqrt{[\text{média}((\text{LTM}_{\text{mod}} - \text{LTM}_{\text{obs}})^2)]} \quad (4)$$

A diferença dessa fórmula (4) para a anterior, é que ela “pega” o mapa de erros (LTM_mod-LTM_obs) ao quadrado, e calcula a média simples de todos os *pixels*, e então calcula a raiz quadrada. Formando um “único” número. (WILLMOTT, 1981)

$$RMSE_{ponderado} = \sqrt{\frac{\sum_{i=1}^n w_i (x_i - y_i)^2}{\sum_{i=1}^n w_i}} \quad (5)$$

Essa fórmula (5) é a métrica mais cientificamente rigorosa. Ela reconhece que os *pixels* perto do Equador representam uma área física muito maior do que os *pixels* perto dos polos e ajusta a média de acordo. (TAYLOR, 2001). Esse é o RMSE Global Ponderado e será utilizado como a principal métrica de desempenho nas projeções.

- e. **Média do Ensemble (*Ensemble Mean*):** O consenso do conjunto. É a projeção mais confiável, calculada como a média das anomalias projetadas (*I*) de todos os modelos do *ensemble* (TEBALDI; KNUTTI, 2007). Fórmula utilizada no *script*:

$$Ensemble Mean = Mean(\Delta_{mod1}, \Delta_{mod2}, \dots, \Delta_{mod12}) \quad (6)$$

- f. **Desvio Padrão do Ensemble (*Ensemble Spread*):** É a medida da incerteza/discordância entre os modelos. Um desvio padrão baixo significa que os modelos concordam entre si, portanto, maior confiança na *Ensemble Mean* (6) (TEBALDI; KNUTTI, 2007).

$$Ensemble Spread = \sigma(\Delta_{mod1}, \Delta_{mod2}, \dots, \Delta_{mod12}) \quad (7)$$

Nota-se que este cálculo não está inserido no *script*, sendo realizado automaticamente utilizando função através do site para criação de tabelas e gráficos Rows.

- g. **Coeficiente de Correlação de Pearson (r ou “corr”):** O Coeficiente de Correlação de Pearson é a habilidade em reproduzir os padrões espaciais da climatologia observada de cada modelo, e comparar o LTM do modelo climático com o LTM da reanálise (GODAS). Essa métrica pode variar de -1 (oposto a reanálise) a +1

(idêntico a reanálise), indicando a semelhança na geografia do clima independentemente do *bias*. Ele nos indica se o modelo lê as áreas quentes do Oceano Pacífico, em um evento do El Niño, por exemplo, e compara com a mesma região no modelo de reanálise. Se o modelo apresentar a maior quantidade de *pixels* “vermelhos” nos mesmos locais geográficos que o modelo de reanálise, significa que o modelo tem uma ótima leitura dos eventos físicos geográficos, mesmo que o *bias* do modelo seja “grande” (TAYLOR, 2001). A fórmula do coeficiente é dada por:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (8)$$

Onde x e y representam os valores de TSM do modelo e da reanálise, e $\bar{x}$ e $\bar{y}$ são suas médias espaciais (8) (TAYLOR, 2001). Sendo um cálculo complexo e complicado, utilizamos a função “`np.corrcoef()`[0, 1]”, que calcula automaticamente o Coeficiente de Correlação de Pearson baseando-se nos arquivos NetCDF.

- h. **Cálculo da Resolução Espacial em Graus:** Para calcular as resoluções da Tabela 3, coletamos os dados dos números de pontos na direção da longitude e latitude encontrados no site do WCRP-CMIP (2025), e aplicamos nas fórmulas a seguir:

$$Long (^\circ) = \frac{360^\circ}{N^\circ} \quad (9)$$

$$Lat (^\circ) = \frac{180^\circ}{N^\circ} \quad (10)$$

Essa conversão foi realizada por considerarmos ser mais intuitiva para a compreensão do tema, não interferindo nos resultados das projeções.


No próximo tópico, será aprofundado o conceito de resolução e sua importância para os modelos, desafios e soluções encontrados ao longo da pesquisa.

4. Desafios Técnicos e Soluções

Nesta seção, explicaremos os desafios técnicos e soluções mais importantes do projeto, que, de alguma maneira, interferem no resultado e na visualização dos resultados.

Para compreendermos a raiz do problema (as diferenças de *grid*) explicaremos brevemente o conceito de *grid* no contexto das modelagens climáticas.

Figura 5: Conceito de Resolução/*Grid* nos Modelos Climáticos



Fonte: Própria (Gerado com IA, editado no Canva)

Analisando a figura 5, é possível observar que um modelo de **alta resolução** (com células de grade menores) é, em teoria, melhor para simular fenômenos regionais, já que a precisão é maior, mas exige muito mais poder computacional. Um modelo de **baixa resolução** (com células maiores), é mais rápido, mas pode perder detalhes importantes, como, por exemplo, ao analisar áreas costeiras onde a terra se torna a mesma célula que o oceano (HAARSMA et al., 2016). A figura também mostra como a resolução se converte em quilômetros (km), uma distância que pode variar com a latitude. Os modelos climáticos funcionam com coordenadas angulares (latitude e longitude), essas coordenadas variam

consoante a direção longitudinal. No Equador, por exemplo, 1° de longitude equivalem a ≈ 111 km, e nos polos, 1° pode ser ≈ 1 km ou menos, pois as linhas de longitude convergem. As resoluções da atmosfera costumam ser maiores que as do oceano, pois as atividades oceânicas requerem mais precisão do que a atmosfera.

É possível observar na coluna de resoluções (ver Tabela 3), a variedade de resoluções que cada modelo possui, variando de $\approx 1.0^\circ$ até $\approx 2.8^\circ$. Além das resoluções variadas, os modelos possuem diferentes geometrias (retilíneas e curvilíneas). Essa variedade se torna um problema quando agrupamos os modelos em um *multi-model ensemble*, por impedir a comparação e realização de operações matemáticas diretas entre os modelos.

Para solucionar este problema, inserimos um processo de “regradeamento” (*regridding*) na linha de código. Essa técnica consiste em interpolar os dados de cada modelo de sua grade nativa (*gn*) para uma grade padrão/comum. Para as análises, decidimos selecionar o *grid* do *dataset* de reanálise GODAS, por ser a nossa principal fonte de dados para comparação com o mundo observado. Utilizamos a biblioteca xESMF, com o algoritmo de interpolação bilinear (XESMF, 2025). Além disso, as análises pós *regridding* revelaram desafios adicionais, como a presença de “células degeneradas” em algumas grades de modelo, que nos levaram a utilizar o parâmetro “*ignore_degenerate=true*” para garantir a conclusão do processo. Uma observação interessante a ser feita, que será explorada posteriormente, é a relação entre os modelos que apresentaram esta característica e um menor RMSE Global Ponderado em relação a reanálise. O que pode estar associado a uma maior fidelidade na simulação dos padrões oceânicos observados.

Com o desenvolvimento devidamente explicado, seguiremos para os resultados das projeções da TSM no cenário SSP5-8.5 para o período a longo prazo (2081-2100), utilizando um *multi-model ensemble* de 12 modelos do CMIP6.

RESULTADOS E DISCUSSÕES

Nesta seção, discutiremos e apresentaremos os principais resultados da análise do *multi-model ensemble* do CMIP6. A principal conclusão que podemos aferir, é que o *ensemble* de 12 modelos projeta um aquecimento médio global para a TSM de $3,01 \pm 0,52$ °C para o final do século (2081-2100) sob o cenário de altas emissões SSP5-8.5, em relação ao período de referência histórico (1981–2010). Entretanto, as projeções individuais nos mostram uma gama ampla de resultados, variando de aquecimentos moderados de 2,00 °C (MIROC6) até um

aquecimento extremo de 4,01 °C (CanESM5), destacando a importância da abordagem *multi-model* para quantificar a incerteza da projeção.

Análises Iniciais

A tabela 4 resume as principais métricas de avaliação da projeção para cada um dos 12 modelos selecionados. A tabela apresenta a anomalia média projetada, o *bias* médio global (desempenho histórico), a média do *ensemble* e o desvio padrão, permitindo uma comparação direta entre os modelos do conjunto. Obs.: na coluna do *Bias* Médio Global, valores abaixo de 0 °C estão em azul-claro, e os valores acima de 0 °C em vermelho claro, indicando um *bias* inclinado ao aquecimento ou esfriamento em relação ao modelo de reanálise (GODAS) no período histórico.

Tabela 4: Anomalia da TSM, *Bias*, Média do *Ensemble* e Desvio Padrão

Anomalia Média da TSM e *Bias* Médio Global

Média do Ensemble e Desvio-Padrão. Cores em Azul-escuro representam temperaturas acima da média do ensemble.


Modelo	Anomalia Média (°C)	Bias Médio Global (°C)
CanESM5	4.01	-0.21
CESM2-WACCM	3.56	0.02
IPSL-CM6A-LR	3.36	-0.23
CanESM5-1	3.24	-0.36
CAS-ESM2-0	3.19	-0.04
FIO-ESM-2-0	3.05	-0.35
CMCC-CM2-SR5	3.03	0.24
CMCC-ESM2	2.96	0.16
ACCESS-ESM1-5	2.74	0.6
MRI-ESM2-0	2.60	-0.36
BCC-CSM2-MR	2.36	0.26
MIROC6	2.00	0.38
Média do Ensemble (°C)	3.01	
Desvio-Padrão	0.52	

Fonte: Própria (Rows)

Para visualizar a distribuição dos resultados do *ensemble*, a figura 6 apresenta a anomalia média projetada por cada modelo. A linha pontilhada na horizontal representa a média

do *ensemble* (3,01 °C), enquanto as linhas verticais que atravessam a linha pontilhada representam a incerteza (desvio padrão) dos modelos ($\pm 0,52$ °C) em relação à média do *ensemble*. O gráfico ilustra tanto o consenso entre os modelos, como as diferenças nas projeções individuais.

Figura 6: Distribuição dos Modelos Sobre a Anomalia Média da TSM



Fonte: Própria (IA+Python)

A principal conclusão desta análise inicial é a concordância clara entre todos os 12 modelos no qual o cenário SSP5-8.5 levará a um aquecimento oceânico superior a 2 °C. A incerteza, representada pelo desvio padrão de 0,52 °C, é fruto, principalmente, da sensibilidade climática de cada modelo, um conceito que será explorado com mais detalhes nas análises individuais dos modelos a seguir.


Análises Individuais de 4 Modelos Seleccionados

Para nos aprofundarmos na análise dos resultados do *ensemble*, foram seleccionados quatro modelos que se destacaram nas simulações para um estudo de caso detalhado. Cada modelo foi escolhido por exibir características distintas em termos de sensibilidade climática, desempenho histórico e particularidades na projeção, reforçando mais uma vez a gama de comportamentos dos modelos participantes do *ensemble*.

1. CanESM5

O modelo CanESM5, desenvolvido no Canadá, e utilizado no IPCC AR6 (IPCC, 2021), destaca-se por apresentar a maior anomalia média projetada do *ensemble* (+4,01 °C). Conforme apresentado em sua personalidade (ver Tabela 3), o modelo apresenta a maior Sensibilidade Climática de Equilíbrio (ECS) dentre os modelos do CMIP6 (BI et al., 2022).

Figura 7: Mapa da Anomalia Projetada do Modelo CanESM5



Fonte: Própria (Python)


O mapa revela informações preciosas sobre a projeção do modelo (ver Figura 7). É possível observar um aquecimento global intenso e generalizado. Principalmente no Oceano Ártico, com anomalias que excedem o limite da escala de cores (+10 °C), um valor mais que o dobro de sua média global projetada. Também conhecido como Amplificação Ártica, este padrão de aquecimento polar anormal é um sinal importante para as projeções de mudanças

climáticas. Observa-se também um aquecimento significativo no Oceano Atlântico, embora de menor magnitude.

2. MIROC6

Em contraste, o modelo MIROC6, do Japão, representa o menor aquecimento projetado, com uma anomalia média de +2,00 °C. Apesar de sua baixa sensibilidade climática (BI et al., 2022) o MIROC6 é reconhecido por sua alta fidelidade na simulação de fenômenos de variabilidade interna, como o ENSO, mencionado na Tabela 3. A Figura 8 apresenta a anomalia média de TSM projetada pelo modelo MIROC6.

Figura 8: Mapa da Anomalia Projetada do Modelo MIROC6



Fonte: Própria (Python)


Embora o padrão de aquecimento seja similar ao CanESM5, a magnitude é visivelmente menor. A Amplificação Ártica está presente, porém com anomalias máximas em torno de +7,5 °C, além disso, é possível observar a região sul do Oceano Pacífico, próximo ao Oceano Antártico, com uma anomalia demasiadamente negativa ($\approx -0,5$ °C), indicando um possível resfriamento da TSM naquela região. Comparando diretamente com a Figura 7, observamos a incerteza sendo maior que 2 °C na projeção de aquecimento médio global, sendo primariamente motivada pela sensibilidade climática única de cada modelo. Um fato interessante, é que conforme descrito na Tabela 3, o modelo MIROC6 é um dos melhores em simular o ENSO,

uma variabilidade interna complexa que costuma pronunciar a TSM na região do Pacífico Equatorial.

3. IPSL-CM6A-LR

A avaliação do desempenho histórico dos modelos, também é uma etapa crucial para contextualizar suas projeções. O modelo francês IPSL-CM6A-LR destacou-se por sua alta fidelidade na simulação da climatologia do século XX, apresentando um dos menores RMSE Global Ponderado do *ensemble* (0,89 °C) e uma correlação espacial quase perfeita (0.997) (ver Figura 12). A Figura 9 apresenta o mapa de RMSE Global Ponderado para o IPSL-CM6A-LR. As cores quentes (vermelho) indicam onde o erro do modelo é maior.

Figura 9: Mapa de RMSE Global Ponderado do Modelo IPSL-CM6A-LR



Fonte: Própria (Python)


O mapa de RMSE Global Ponderado (ver Figura 9) revela que os principais erros (superiores a +2 °C) estão geograficamente em regiões de alta variabilidade e complexidade oceanográfica, como a Corrente do Golfo, Kuroshio e a Corrente Circumpolar Antártica (ver Figura 1). É possível observar que os principais erros também se concentram nas regiões costeiras dos continentes, principalmente próximo à costa do Peru. Em contraste, os oceanos abertos tropicais e subtropicais possuem um erro médio consideravelmente baixo, frequentemente inferior a 0,5 °C (branco/amarelo), indicando uma alta capacidade do modelo em produzir padrões climatológicos fiéis às observações nessas regiões.

Uma característica notável no mapa (ver Figura 9), é a presença de um artefato visual, uma linha de dados ausentes (NaN-Not a Number) no Oceano Índico. Essa “linha branca” é resultado da adição do parâmetro na metodologia de *regridding*. O modelo IPSL-CM6A-LR, utiliza uma grade oceânica (*grid*) tripolar (ver Tabela 3) que, embora forneça maior precisão para as simulações do modelo devido a sua complexidade, resulta em “costuras” geométricas onde as células da grade podem se tornar degeneradas. Ao instruir a ferramenta xESMF a ignorar essas células, o resultado do regridding retorna dados ausentes que podem ser visualizados no resultado.

4. CAS-ESM2-0

O modelo CAS-ESM2-0, desenvolvido na China, apresenta um comportamento peculiar e interessante. Ele combina um *bias* médio global quase nulo ($-0,04\text{ }^{\circ}\text{C}$) com uma projeção de aquecimento elevada ($+3,20\text{ }^{\circ}\text{C}$).

Figura 10: Mapa da Anomalia Projetada do Modelo CAS-ESM2-0



Fonte: Própria (Python)

Uma característica notável no padrão de anomalia projetada por este modelo (ver Figura 10) é a quase completa ausência de resfriamento em qualquer parte do globo, com a anomalia mínima sendo exatamente $0,0\text{ }^{\circ}\text{C}$. Apesar disso, o aquecimento é mais uniforme e menos intenso do que em outros modelos, como o CanESM5, com uma Amplificação Ártica mais

modesta. Nota-se que essa característica pode ser um artefato do pós-processamento dos dados ou indicar uma física de modelo com menos variabilidade interna.

Relação entre Desempenho Histórico (*Bias*) e Projeção Futura (*Anomalia*)

Uma questão fundamental na ciência climática é determinar se o desempenho de um modelo na simulação do período histórico pode ser usado como indicador de confiança em sua projeção futura. Para investigar essa relação, realizamos uma análise entre a métrica de desempenho histórico (*bias* médio global) e o resultado da projeção (*anomalia* média) para cada um dos 12 modelos do *ensemble*. Para isso, utilizamos um gráfico de dispersão que nos entrega um panorama comparativo dos modelos.

Figura 11: Relação *Bias* vs *Anomalia* entre os Modelos



Fonte: Própria (IA+Python)

A figura 11 apresenta uma comparação direta entre os modelos. O eixo Y representa a anomalia média projetada, enquanto o eixo X representa o *bias* médio global do modelo. A análise visual do gráfico revela não haver uma correlação linear entre o desempenho histórico


e a sensibilidade climática futura. Modelos com baixo *bias*, como o CAS-ESM2-0 (-0,04 °C), projetaram um aquecimento significativo de +3,20 °C, enquanto outros modelos com *bias* mais pronunciado, como o MIROC6 (+0,38 °C), projetaram o menor aquecimento do *ensemble* (+2,00 °C). Por outro lado, o modelo CanESM5, que projeta o maior aquecimento do *ensemble* (+4,01 °C), possui um *bias* frio relativamente moderado (-0,21 °C).

A ausência da relação entre o erro de um modelo no passado e sua sensibilidade climática futura, sugere que o *bias* de um modelo não interfere diretamente na sua projeção futura, levando a conclusão de que não há restrição emergente do *bias* com a anomalia projetada neste *ensemble*. Concluimos que seu desempenho histórico e a resposta ao forçamento de GEE são liderados por diferentes aspectos da física do modelo. Portanto, a abordagem *multi-model ensemble*, onde a média do *ensemble* representa a projeção mais consensual e o desvio padrão quantifica a incerteza entre os modelos, é considerada a melhor estratégia para analisar as mudanças climáticas projetadas nos cenários SSP.

Relação entre Erro do Modelo e Complexidade da Grade

Para aprofundar ainda mais a avaliação de desempenho dos modelos, foi realizada uma análise comparativa entre duas métricas de erro principais: o RMSE Global Ponderado, que mede a magnitude do erro médio, e o Coeficiente de Correlação de Pearson, que mede a fidelidade dos padrões espaciais. A figura 12 apresenta um gráfico de dispersão, onde a posição ideal dos modelos é apresentar um baixo RMSE e uma alta Correlação (canto superior esquerdo).

Figura 12: Relação entre o RMSE Global Ponderado e o Coeficiente de Correlação de Pearson



Fonte: Própria (IA+Python)

O gráfico (ver Figura 12) revela uma descoberta interessante. Os três modelos que exigiram o uso do parâmetro “*ignore_degenerate=true*” durante o processo de *regridding* (IPSL-CM6A-LR, CMCC-CM2-SR5 e CMCC-ESM2) formam um grupo distinto e de alto desempenho, sendo localizados no canto superior esquerdo do gráfico. Estes modelos apresentam os menores valores de RMSE Global Ponderado (todos abaixo de 0,9 °C) e os maiores Coeficientes de Correlação (todos iguais a 0.997) de todo o *ensemble*.

Conforme discutido anteriormente, a necessidade de utilizar o parâmetro “*ignore_degenerate=true*” é devido aos modelos apresentarem grades complexas e sofisticadas, como a grade tripolar, utilizada nos três modelos (ver Tabela 3). O agrupamento dos modelos no quadrante de melhor desempenho, confirma que a complexidade da grade está diretamente associada a uma maior fidelidade na simulação climatológica oceânica. Modelos com grades avançadas, embora sejam mais desafiadoras quando processadas, demonstram uma capacidade superior em reproduzir processos oceanográficos complexos, como as correntes marítimas (ver Figura 2), resultando em uma maior fidelidade aos dados de reanálise (RMSE

baixo e Correlação alta). Portanto, a presença do artefato (“linha branca”, ver Figura 9) nos mapas, não invalida os resultados, mas atua como um sinal de um modelo geometricamente avançado, cuja sofisticação reflete no excelente desempenho na simulação da climatologia oceânica.

Consoante as duas hipóteses apresentadas no projeto, sendo a primeira delas: os modelos climáticos do CMIP6 apresentam variações significativas na projeção da TSM para o período de 2081–2100, refletindo incertezas associadas ao cenário de altas emissões SSP5-8.5. Os resultados demonstram que os modelos possuem características distintas entre si, que os leva a projeções contrastantes e incertas quando são analisados individualmente. Portanto, podemos aferir que a primeira hipótese foi completamente confirmada, já que a abordagem *multi-model ensemble* não reduz as incertezas produzidas por projeções individuais, mas sim revela e quantifica essa incerteza (desvio padrão de 0,52 °C), revelando uma projeção mais robusta (média do *ensemble*), apesar da incerteza.

Em relação à segunda hipótese: O desempenho histórico dos modelos, medido por métricas como Bias médio global, RMSE e Correlação Espacial, influencia diretamente a confiabilidade das projeções futuras de TSM, sendo possível identificar modelos mais robustos para estudos climáticos de longo prazo. Segundo a análise feita anteriormente sobre a figura 11 e 12, neste *ensemble* de 12 modelos, os dados comparativos entre o *bias* e a anomalia projetada, indicam não existir nenhuma relação entre o desempenho histórico do modelo e sua projeção futura, o que dificultaria a redução de modelos incertos baseando-se nessas métricas. Não obstante, a análise da relação entre o RMSE Global Ponderado e o Coeficiente de Correlação de Pearson, indica que, apesar de três modelos sugerirem a existência dessa relação, acreditamos que esse caso não esteja relacionado com as métricas de desempenho (RMSE e Correlação de Pearson), mas sim com a complexidade das grades de resolução dos modelos em questão. Além disso, o modelo CESM2-WACCM, apesar de apresentar o pior RMSE Global Ponderado do *ensemble*, possui um Coeficiente de Correlação melhor que outros 5 modelos. Enquanto o modelo BCC-CSM2-MR, possuindo o segundo pior Coeficiente de Correlação, está entre os 5 modelos com o melhor RMSE Global Ponderado. Portanto, concluímos que a primeira hipótese foi confirmada, e a segunda hipótese, refutada.

CONSIDERAÇÕES FINAIS

Este estudo teve como objetivo principal analisar a projeção da Anomalia da TSM para o final do século XXI, utilizando um *ensemble* de 12 modelos do CMIP6 sob o cenário de altas emissões SSP5-8.5. A principal conclusão da pesquisa, é a projeção de um aquecimento médio global da TSM de $3,01 \pm 0,52$ °C, em relação ao período histórico de 1981–2010. A análise espacial dessa mudança, revela padrões geograficamente parecidos, com a Amplificação Ártica proeminente, onde o aquecimento pode exceder 10 °C, destacando as regiões polares como as regiões mais vulneráveis às mudanças climáticas nos Oceanos. Além disso, as variações climáticas também intensificam eventos de variabilidade interna, como o ENSO, revisitando a necessidade de estudar maneiras para mitigar essas mudanças.

Ademais, os resultados apresentados reforçam a urgência destacada pela ODS 13, demonstrando que a trajetória de um cenário de altas emissões proporcionará impactos severos e irreversíveis para o Planeta Terra. O professor Paulo Artaxo, afirma que: “O Brasil, com sua localização tropical, é um dos países que vão ser mais afetados pelas mudanças climáticas, e a gente tem que preparar nossa sociedade para isso.” (CURSI et al., 2025), reforçando a urgência da conscientização e propostas de mitigação para as mudanças climáticas.

Para os próximos passos, este projeto se concentra na finalização e preparação dos materiais para a apresentação. Para trabalhos futuros, o *workflow* desenvolvido abre diversas possibilidades de expansão. Uma análise similar pode ser aplicada a outras variáveis oceânicas importantes, como a concentração de gelo marinho e a salinidade, fornecendo uma visão ainda mais precisa sobre as mudanças climáticas no sistema oceânico. Além disso, a análise de cenários mais otimistas, como o SSP1-2.6, pode ser aprofundada, permitindo uma comparação direta entre os diferentes impactos projetados pelas diferentes trajetórias de desenvolvimento socioeconômico no futuro do clima oceânico.

REFERÊNCIAS BIBLIOGRÁFICAS

ASSIS, Érika A. et al. Modelos Acoplados do IPCC (CMIP3-CMIP5) e o Gradiente Meridional de Anomalias de Temperatura da Superfície do Mar (TSM) no Oceano Atlântico Tropical. **Revista Brasileira de Meteorologia**, v. 34, n. 2, p. 217-226, 2019.

BAO, Y. et al. FIO-ESM Version 2.0: Model description and evaluation. **Journal of Geophysical Research: Oceans**, v. 125, n. 6, e2019JC016036, 2020. DOI: <https://doi.org/10.1029/2019JC016036>. Acesso em: 9 set. 2025.

BARDINE, Renan. Correntes Marítimas: o que são, tipos e importância. **Cola da Web**, 2025. Disponível em: <https://www.coladaweb.com/geografia/correntes-maritimas>. Acesso em: 28 set. 2025.

BEHRINGER, D. W.; XUE, Y. Evaluation of the global ocean data assimilation system at NCEP: The Pacific Ocean. In: **EIGHTH SYMPOSIUM ON INTEGRATED OBSERVING AND ASSIMILATION SYSTEMS FOR ATMOSPHERE, OCEANS, AND LAND SURFACE**, 2004, Seattle. Proceedings [...]. Washington, DC: American Meteorological Society, 2004.

BI, Kaifeng et al. ClimateLearn: A Foundation Model for Climate and Weather. **arXiv preprint**, arXiv:2210.11414, 2022. Disponível em: <https://arxiv.labs.arxiv.org/html/2210.11414>. Acesso em: 6 set. 2025.

BOUCHER, O. et al. Presentation and evaluation of the IPSL-CM6A-LR climate model. **Journal of Advances in Modeling Earth Systems**, v. 12, n. 7, e2019MS002010, 2020. DOI: <https://doi.org/10.1029/2019MS002010>. Acesso em: 10 set. 2025.

CHERCHI, A. et al. Global mean climate and main patterns of variability in the CMCC-CM2 coupled model. **Journal of Advances in Modeling Earth Systems**, v. 11, n. 1, e2018MS001369, 2019. DOI: <https://doi.org/10.1029/2018MS001369>. Acesso em: 10 set. 2025.

CIÊNCIA NO MAR. Circulação Oceânica, Interação Oceano-Atmosfera e Variabilidade Climática - Seminários. **YouTube**, 29 out. 2020. Disponível em: https://www.youtube.com/live/4OevFVTUQT8?si=8s_Sfq1Q7FgrljEj. Acesso em: 25 jul. 2025.

COLUSSO, Izabele. Objetivos de Desenvolvimento Sustentável (ODS). **YouTube**, 2023. Disponível em: <https://www.youtube.com/watch?v=FXmgP3BXSEg>. Acesso em: 10 jun. 2025.

CPTEC/INPE. **El Niño Oscilação Sul (ENOS)**. Disponível em: <http://enos.cptec.inpe.br/elnino/pt>. Acesso em: 18 ago. 2025.

CURSI, Victor; MEDEIROS, Luiz; SANTOS, Luciana. Estudo das Mudanças Climáticas a Partir da Leitura dos Relatórios do IPCC. **Revista da Semana do Conhecimento**, v. 8, n. 1, p. 25, 15 abr. 2025. Acesso em: 26 maio 2025.

DMAE UBERLÂNDIA. Documentário: Sustentabilidade, desafio de todos. **YouTube**, 2023. Disponível em: https://youtu.be/4-L_U17LxkA?si=FdwPXapEKejSPbxu. Acesso em: 10 jun. 2025.

DUNNE, J. P. et al. Climate intervention and Earth system dynamics. **Earth System Dynamics**, v. 14, n. 4, p. 1107–1154, 2023. DOI: <https://doi.org/10.5194/esd-14-1107-2023>. Acesso em: 8 set. 2025.

EYRING, V. et al. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. **Geoscientific Model Development**, v. 9, n. 5, p. 1937–1958, 2016. DOI: <https://doi.org/10.5194/gmd-9-1937-2016>. Acesso em: 29 ago. 2025.

FENG, L. et al. The generation of gridded emissions data for CMIP6. **Geoscientific Model Development**, v. 13, n. 2, p. 461–482, 2020. DOI: <https://doi.org/10.5194/gmd-13-461-2020>. Acesso em: 30 ago. 2025.

EARTH SYSTEM GRID FEDERATION – ESGF. **ESGF Node at the Oak Ridge National Laboratory (ORNL)**. Disponível em: <https://esgf-node.ornl.gov/search>. Acesso em: 29 ago. 2025.

FOREST-GIS. **CMIP6: Modelagem Climática e Como Trabalhar com os Dados**. 27 set. 2022. Disponível em: <https://forest-gis.com/2022/09/cmip6-a-nova-geracao-de-modelos-climaticos-chegou.html/>. Acesso em: 26 set. 2025.

GETTELMAN, A. et al. The Whole Atmosphere Community Climate Model Version 6 (WACCM6). **Journal of Geophysical Research: Atmospheres**, v. 124, n. 23, p. 12380–12403, 2019. DOI: <https://doi.org/10.1029/2019JD030943>. Acesso em: 9 set. 2025.

GODOY, Renan Muinos Pardo de et al. Projeções Climáticas de Temperatura do Ar e Precipitação para o Estado de São Paulo Utilizando o Modelo Regional RegCM4. **Anuário do Instituto de Geociências – UFRJ**, v. 42, n. 2, p. 258-269, 2019.

HAARSMA, R. J. et al. High Resolution Model Intercomparison Project (HighResMIP v1.0) for CMIP6. *Geoscientific Model Development*, v. 9, n. 11, p. 4185–4208, nov. 2016. Acesso em: 03 set. 2025.

HARRIS, Charles R. et al. Array programming with NumPy. **Nature**, v. 585, p. 357–362, 2020. DOI: <https://doi.org/10.1038/s41586-020-2649-2>.

HARRISON, S. P. et al. The role of palaeoclimate modelling in climate change assessment. **Environmental Studies**, v. 44, n. 5, p. 351–370, 2023. DOI: <https://doi.org/10.1071/ES23029>. Acesso em: 8 set. 2025.

IHU UNISINOS. **Os fatos e a ciência da mudança climática**. Disponível em: <https://www.ihu.unisinos.br/categorias/621965-os-fatos-e-a-ciencia-da-mudanca-climatica>. Acesso em: 23 set. 2025.

INSTITUTO CATARINENSE DE RECURSOS HUMANOS – ICRH. **Você conhece os Objetivos de Desenvolvimento Sustentável?** Disponível em: <https://icrh.com.br/voce-conhece-os-objetivos-de-desenvolvimentos-sustentaveis/>. Acesso em: 29 set. 2025.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate Change 2021: The Physical Science Basis**. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2021.

KOZAR, Michael & Mann, Michael & Camargo, Suzana & Kossin, James & Evans, Jenni. (2012). Stratified statistical models of North Atlantic basin-wide and regional tropical cyclone counts. **Journal of Geophysical Research (Atmospheres)**. 117. 18103-. 10.1029/2011JD017170. Acesso em: 28 set. 2025

LOVATO, T. et al. CMIP6 simulations with the CMCC Earth System Model (CMCC-ESM2). **Journal of Advances in Modeling Earth Systems**, v. 14, n. 2, e2021MS002814, 2022. DOI: <https://doi.org/10.1029/2021MS002814>. Acesso em: 10 set. 2025.

MARCÍLIO, Ricardo. Entenda o El Niño e a La Niña (célula de Walker). **YouTube**, 16 jun. 2020. Disponível em: <https://youtu.be/jQ-aI-REsxQ?si=SiisksI1vn26WwlyY>. Acesso em: 27 jul. 2025.

NASA. **Ocean Warming – Vital Signs of the Planet**. Disponível em: <https://climate.nasa.gov/vital-signs/ocean-warming/?intent=121>. Acesso em: 13 ago. 2025.

NIJSSE, F. J. M. M. et al. Emergent constraints on transient climate response (TCR) and equilibrium climate sensitivity (ECS) from historical warming in CMIP5 and CMIP6 models. **Earth System Dynamics**, v. 11, n. 3, p. 737–750, 2020. DOI: <https://doi.org/10.5194/esd-11-737-2020>. Acesso em: 15 set. 2025.

NOAA – Climate Prediction Center. **Nino 3.4 Index (detrended)**. Disponível em: https://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/detrend.nino34.ascii.txt. Acesso em: 19 ago. 2025.

- a. NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION – NOAA. **NOAA Optimum Interpolation Sea Surface Temperature (OISST) v2 High Resolution Dataset**. Physical Sciences Laboratory, Boulder, CO, [s.d.]. Disponível em: <https://psl.noaa.gov/data/gridded/data.noaa.oisst.v2.highres.html>. Acesso em: 18 ago. 2025.
- b. NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION – NOAA. **Global Ocean Data Assimilation System (GODAS)**. Physical Sciences Laboratory, Boulder, CO, [s.d.]. Disponível em: <https://psl.noaa.gov/data/gridded/data.godas.html>. Acesso em: 03 set. 2025.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Objetivos de Desenvolvimento Sustentável**. Brasília: ONU Brasil, 2025. Disponível em: <https://brasil.un.org/pt-br/sdgs>. Acesso em: 28 set. 2025.

REYNOLDS, R. W. et al. **NOAA Optimum Interpolation Sea Surface Temperature (OISST) v2 High Resolution Dataset**. NOAA Physical Sciences Laboratory, Boulder, CO,

2007. Disponível em: <https://psl.noaa.gov/data/gridded/data.noaa.oisst.v2.highres.html>. Acesso em: 18 ago. 2025.

SEABORN. **Seaborn: statistical data visualization — seaborn 0.13.2 documentation**. Disponível em: <https://seaborn.pydata.org/index.html>. Acesso em: 28 set. 2025.

SIGMOND, M. et al. Improvements in the Canadian Earth System Model (CanESM) through systematic model analysis: CanESM5.0 and CanESM5.1. **Geoscientific Model Development**, v. 16, n. 18, p. 6553–6582, 2023. DOI: <https://doi.org/10.5194/gmd-16-6553-2023>. Acesso em: 8 set. 2025.

TAYLOR, K. E. et al. **CMIP6 global attributes, DRS, filenames, directory structure, and controlled vocabularies (CVs)**. Version 6.2.8, 9 jun. 2025. Disponível em: https://docs.google.com/document/d/1h0r8RZr_f3-8egBMMh7aqLwy3snpD6_MrDz1q8n5XUk/edit. Acesso em: 29 ago. 2025.

TAYLOR, Karl E. Summarizing multiple aspects of model performance in a single diagram. **Journal of Geophysical Research: Atmospheres**, v. 106, n. D7, p. 7183-7192, abr. 2001.

TEBALDI, Claudia; KNUTTI, Reto. The use of the multi-model ensemble in probabilistic climate projections. **Philosophical Transactions of the Royal Society A**, v. 365, n. 1857, p. 2053-2075, ago. 2007.

W3SCHOOLS. **Python Tutorial**. Disponível em: <https://www.w3schools.com/python/default.asp>. Acesso em: 26 ago. 2025.

WCRP-CMIP. **CMIP6 experiment identifiers**. Disponível em: https://wcrp-cmip.github.io/CMIP6_CVs/docs/CMIP6_experiment_id.html. Acesso em: 15 set. 2025.

WILLMOTT, Cort J. On the validation of models. **Physical Geography**, v. 2, n. 2, p. 184-194, abr. 1981.

WORLD METEOROLOGICAL ORGANIZATION. **WMO Climatological Normals**. [S. l.], 2020. Disponível em: <https://community.wmo.int/en/activity-areas/climate-services/climate-products-and-initiatives/wmo-climatological-normals>. Acesso em: 28 ago. 2025.

- a. WORLD METEOROLOGICAL ORGANIZATION. **WMO Guidelines on the Calculation of Climate Normals**. Geneva: WMO, 2017. (WMO-No. 1203).

- b. WU, T. et al. The Beijing Climate Center Climate System Model (BCC-CSM): the main progress from CMIP5 to CMIP6. **Geoscientific Model Development**, v. 12, n. 4, p. 1573–1600, 2019. DOI: <https://doi.org/10.5194/gmd-12-1573-2019>. Acesso em: 9 set. 2025.

XESMF. **Regrid between curvilinear grids**. In: XESMF 0.7.0 documentation. [S. l.], 2023. Disponível em: https://xesmf.readthedocs.io/en/stable/notebooks/Curvilinear_grid.html. Acesso em: 3 set. 2025.

YUKIMOTO, S. et al. The Meteorological Research Institute Earth System Model Version 2.0, MRI-ESM2.0: Description and basic evaluation of the physical component. **Journal of the Meteorological Society of Japan**, v. 97, n. 5, p. 931–965, 2019. DOI: <https://doi.org/10.2151/jmsj.2019-051>. Acesso em: 8 set. 2025.

ZHOU, T. et al. CAS-ESM2.0 model datasets for the CMIP6 Ocean Model Intercomparison Project Phase 1 (OMIP1). **Advances in Atmospheric Sciences**, v. 37, n. 10, p. 1057–1066, 2020. DOI: <https://doi.org/10.1007/s00376-020-0150-3>. Acesso em: 9 set. 2025.