



UNIVERSIDADE FEDERAL DE ALAGOAS – UFAL
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
CURSO DE PÓS-GRADUAÇÃO EM METEOROLOGIA



MÁRIO HENRIQUE GUILHERME DOS SANTOS VANDERLEI

**ANÁLISE DE MÉTODOS DE CORREÇÃO DE VIÉS APLICADOS A
TEMPERATURA SIMULADA POR UM MODELO REGIONAL PARA A
AMAZÔNIA LEGAL BRASILEIRA**

MACEIÓ – AL
2026

MÁRIO HENRIQUE GUILHERME DOS SANTOS VANDERLEI

**ANÁLISE DE MÉTODOS DE CORREÇÃO DE VIÉS APLICADOS A
TEMPERATURA SIMULADA POR UM MODELO REGIONAL PARA A
AMAZÔNIA LEGAL BRASILEIRA**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Meteorologia da Universidade Federal de Alagoas, como parte dos requisitos para o grau de mestre em meteorologia.

Orientador: Prof. Dr. Fabricio Daniel dos S. Silva
Coorientadora: Profa. Dra. Rafaela Lisboa Costa

MACEIÓ – AL
2026

Catálogo na Fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 – 1767

- V235a Vanderlei, Mário Henrique Guilherme dos Santos.
Análise de métodos de correção de viés aplicados a temperatura simulada por um modelo regional para a Amazônia Legal Brasileira / Mário Henrique Guilherme dos Santos Vanderlei. – 2025.
132 f. : il.
- Orientador: Fabricio Daniel dos S. Silva.
Co-orientadora: Rafaela Lisboa Costa.
Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas. Instituto de Ciências Atmosféricas. Maceió, 2025.
- Bibliografia: f. 118-132.
1. Temperatura. 2. Modelos climáticos. 3. Correlação canônica (Estatística). 4. Análise de regressão. 5. Correção de viés. I. Título.

CDU: 551.52

FOLHA DE APROVAÇÃO
CERTIFICADO DE APRESENTAÇÃO


**N.º de ordem: MET-UFAL-MS-
215.**

**“ANÁLISE DE MÉTODOS DE CORREÇÃO DE VIÉS APLICADOS A TEMPERATURA SIMULADA POR
UM MODELO REGIONAL PARA A AMAZÔNIA LEGAL BRASILEIRA.”**


MARIO HENRIQUE GUILHERME DOS SANTOS VANDERLEI

Dissertação submetida ao colegiado do
Curso de Pós-Graduação em Meteorologia
da Universidade Federal de Alagoas - UFAL,
como parte dos requisitos necessários à
obtenção do grau de Mestre em
Meteorologia.


Aprovado pela Banca Examinadora composta por:

Documento assinado digitalmente
 **FABRÍCIO DANIEL DOS SANTOS SILVA**
Data: 09/02/2026 10:51:13-0300
Verifique em <https://validar.iti.gov.br>


Prof. Dr. Fabrício Daniel dos Santos Silva
(Orientador)

Documento assinado digitalmente
 **RAFAELA LISBOA COSTA**
Data: 09/02/2026 11:02:56-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Rafaela Lisboa Costa
(Coorientadora)

Documento assinado digitalmente
 **HELBER BARROS GOMES**
Data: 09/02/2026 11:08:13-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Helber Barros Gomes
(Membro Interno)

Documento assinado digitalmente
 **CLAUDIA PRISCILA WANZELER DA COSTA**
Data: 09/02/2026 14:12:21-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Claudia Priscila Wanzeler da Costa
(Membro Externo)

FEVEREIRO/2026

RESUMO

Este estudo teve como objetivo avaliar as simulações históricas de temperatura máxima e mínima do ar sobre a Amazônia Legal Brasileira (ALB) geradas pelo modelo climático global MPI-ESM1-2-HR, antes e após a regionalização dinâmica com o modelo RegCM4.7.1, bem como analisar a eficácia de métodos estatísticos multivariados de correção de viés na redução dos erros sistemáticos associados a essas simulações. Foram analisadas simulações contínuas de 32 anos (1981–2012), comparadas a dados observacionais em grade regular de $0,5^\circ \times 0,5^\circ$ sobre a ALB. Seis experimentos foram considerados: (1) MPI, correspondente às saídas brutas do MPI-ESM1-2-HR; (2) REG, referente às simulações regionalizadas com o RegCM4.7.1; e (3-6) quatro experimentos com aplicação dos métodos de Análise de Correlação Canônica Ajustada (ACC) e Regressão por Componentes Principais (RCP), resultando nos experimentos MPI-ACC, MPI-RCP, REG-ACC e REG-RCP. Inicialmente, foi aplicada uma análise de cluster às séries temporais de temperatura, permitindo a identificação de seis grupos termicamente homogêneos na ALB, os quais apresentaram comportamentos distintos quanto à variabilidade térmica e ao desempenho dos modelos. A avaliação dos extremos térmicos, baseada nos índices do ETCCDI, indicou limitações relevantes das simulações sem correção na representação da frequência e intensidade dos extremos, sobretudo associados à temperatura mínima. A avaliação mensal do desempenho, realizada por meio dos Diagramas de Taylor, do coeficiente de correlação, do erro médio absoluto (MAE), da raiz do erro quadrático médio (RMSE) e da eficiência de Kling-Gupta (KGE), revelou desempenho insatisfatório das simulações sem correção, que ocuparam sistematicamente as últimas posições nos rankings. Para a temperatura mínima, o experimento REG-RCP apresentou desempenho superior em todos os grupos homogêneos, alcançando pontuação máxima nos Diagramas de Taylor (10,0), no KGE (10,0) e no RMSE (10,0), além de elevada pontuação no MAE (9,7), resultando em uma classificação final de 9,6, enquanto REG-ACC (8,5) e MPI-RCP (8,3) apresentaram desempenho intermediário. Para a temperatura máxima, resultados consistentes foram observados, com o REG-RCP novamente apresentando o melhor desempenho geral, atingindo pontuações de 9,8 nos Diagramas de Taylor e 10,0 no KGE, MAE e RMSE, culminando em uma classificação final de 9,9. De forma geral, os ganhos proporcionados pelas técnicas de correção de viés foram mais expressivos quando aplicadas às simulações regionalizadas, evidenciando que a combinação entre regionalização dinâmica, análise de cluster e correção estatística multivariada, especialmente por meio da RCP, é fundamental para aprimorar a representação da variabilidade média e dos extremos térmicos na ALB, contribuindo para a redução das incertezas na região.

Palavras-chave: temperatura, modelos, análise de correlações canônicas, regressão por componentes principais, correção de viés.

ABSTRACT

This study aimed to evaluate historical simulations of maximum and minimum air temperature over the Brazilian Legal Amazon (BLA) generated by the global climate model MPI-ESM1-2-HR, before and after dynamic downscaling with the RegCM4.7.1 model, as well as to assess the effectiveness of multivariate statistical bias-correction methods in reducing the systematic errors associated with these simulations. Continuous 32-year simulations (1981-2012) were analyzed and compared against observational data on a regular $0.5^\circ \times 0.5^\circ$ grid over the BLA. Six experiments were considered: (1) MPI, corresponding to the raw MPI-ESM1-2-HR outputs; (2) REG, referring to the dynamically downscaled simulations produced with RegCM4.7.1; and (3-6) four experiments applying Adjusted Canonical Correlation Analysis (ACC) and Principal Component Regression (RCP) to the MPI and REG outputs, resulting in the MPI-ACC, MPI-RCP, REG-ACC, and REG-RCP experiments. Initially, a cluster analysis was applied to the temperature time series, allowing the identification of six thermally homogeneous groups across the BLA, which exhibited distinct behaviors in terms of thermal variability and model performance. The assessment of thermal extremes, based on ETCCDI indices, revealed significant limitations of the uncorrected simulations in representing the frequency and intensity of extremes, particularly those associated with minimum temperature. Monthly performance evaluation using Taylor diagrams, Pearson correlation coefficient, mean absolute error (MAE), root mean square error (RMSE), and Kling-Gupta Efficiency (KGE) indicated poor performance of the uncorrected simulations, which consistently ranked in the lowest positions. For minimum temperature, the REG-RCP experiment showed superior performance across all homogeneous groups, achieving maximum scores in the Taylor diagrams (10.0), KGE (10.0), and RMSE (10.0), as well as a high MAE score (9.7), resulting in a final ranking score of 9.6, whereas REG-ACC (8.5) and MPI-RCP (8.3) exhibited intermediate performance. For maximum temperature, consistent results were observed, with REG-RCP again presenting the best overall performance, attaining scores of 9.8 in the Taylor diagrams and 10.0 in KGE, MAE, and RMSE, culminating in a final ranking score of 9.9. Overall, the improvements provided by the bias-correction techniques were more pronounced when applied to the dynamically downscaled simulations, demonstrating that the combination of dynamic downscaling, cluster analysis, and multivariate statistical bias correction, particularly through RCP, is essential to improve the representation of mean temperature variability and thermal extremes over the BLA, thereby contributing to the reduction of uncertainties in the region.

Keywords: temperature, models, canonical correlation analysis, principal component regression, bias correction.

LISTA DE FIGURAS

Figura 1. Localização geográfica da ALB na América do Sul, com ênfase em sua topografia com as respectivas abreviaturas de cada estado e a respectiva distribuição espacial dos pontos de grau da precipitação observada na ALB.....	18
Figura 2. Domínio e topografia (m) utilizada nas simulações climáticas do REG com resolução horizontal de 25 km. A linha sólida vermelha representa a área da ALB.....	22
Figura 3. Fluxograma do delineamento metodológico dos experimentos realizados.....	23
Figura 4. Climatologia mensal da temperatura mínima do ar (°C) sobre a ALB, referente aos meses de janeiro a junho, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.....	34
Figura 5. Climatologia mensal da temperatura mínima do ar (°C) sobre a ALB, referente aos meses de julho a dezembro, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.....	36
Figura 6. Diferença mensal da temperatura mínima do ar (°C) entre os modelos climáticos (MPI e REG) e os dados observacionais na ALB, para o primeiro semestre (janeiro a junho).....	38
Figura 7. Diferença mensal da temperatura mínima do ar (°C) entre os modelos climáticos (MPI e REG) e os dados observacionais na ALB, para o segundo semestre (julho a dezembro).....	40
Figura 8. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo MPI e os dados observados na ALB, para o primeiro semestre (janeiro a junho).....	43
Figura 9. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo MPI e os dados observados na ALB, para o segundo semestre (julho a dezembro).....	44
Figura 10. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo REG e os dados observados na ALB, para o primeiro semestre (janeiro a junho).....	47

Figura 11. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo REG e os dados observados na ALB, para o segundo semestre (julho a dezembro).....	48
Figura 12. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo MPI no primeiro semestre (janeiro-junho).....	51
Figura 13. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo MPI no segundo semestre (julho-dezembro).....	52
Figura 14. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo REG no primeiro semestre (janeiro-junho).....	54
Figura 15. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo REG no segundo semestre (julho-dezembro).....	55
Figura 16. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo MPI no primeiro semestre (janeiro-junho).....	58
Figura 17. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo MPI no segundo semestre (julho-dezembro).....	59
Figura 18. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo REG no primeiro semestre (janeiro-junho).....	61
Figura 19. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo REG no segundo semestre (julho-dezembro).....	62
Figura 20. Climatologia mensal da temperatura máxima do ar (°C) sobre a ALB, referente aos meses de janeiro a junho, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.....	65
Figura 21. Climatologia mensal da temperatura máxima do ar (°C) sobre a ALB, referente aos meses de julho a dezembro, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.....	66
Figura 22. Diferença mensal da temperatura máxima do ar (°C) entre os modelos climáticos (MPI e REG) e os dados observacionais na ALB, para o primeiro semestre (janeiro a junho).....	68

Figura 23. Diferença mensal da temperatura máxima do ar (°C) entre os modelos climáticos (MPI e REG) e os dados observacionais na ALB, para o segundo semestre (julho a dezembro).....	69
Figura 24. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo MPI e os dados observados na ALB, para o primeiro semestre (janeiro a junho).....	72
Figura 25. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo MPI e os dados observados na ALB, para o segundo semestre (julho a dezembro).....	73
Figura 26. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo REG e os dados observados na ALB, para o primeiro semestre (janeiro a junho).....	76
Figura 27. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo REG e os dados observados na ALB, para o segundo semestre (julho a dezembro).....	77
Figura 28. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo MPI no primeiro semestre (janeiro-junho).....	80
Figura 29. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo MPI no segundo semestre (julho-dezembro).....	81
Figura 30. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo REG no primeiro semestre (janeiro-junho).....	83
Figura 31. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo REG no segundo semestre (julho-dezembro).....	84
Figura 32. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo MPI no primeiro semestre (janeiro-junho).....	87
Figura 33. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo MPI no segundo semestre (julho-dezembro).....	88
Figura 34. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo REG no primeiro semestre (janeiro-junho).....	91

Figura 35. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo REG no segundo semestre (julho-dezembro).....	92
Figura 36a e 36b. Determinação e estruturação dos grupos termicamente homogêneos na ALB. (a) Curva do método do cotovelo (Elbow Method), baseada na soma dos quadrados intra-clusters, utilizada para a definição do número ótimo de agrupamentos. (b) Dendrograma hierárquico obtido a partir da distância euclidiana entre as estações, evidenciando a formação de seis grupos termicamente homogêneos.....	95
Figura 37. Distribuição espacial dos grupos termicamente homogêneos na ALB, obtidos por meio da análise de clusters aplicada às séries de temperatura média.....	95
Figura 38. Ciclo anual da temperatura média nos grupos termicamente homogêneos da ALB.....	96
Figura 39. Diagramas de Taylor para a avaliação do desempenho das simulações de temperatura mínima nos grupos termicamente homogêneos da ALB.....	98
Figura 40. Diagramas de Taylor para a avaliação do desempenho das simulações de temperatura máxima nos grupos termicamente homogêneos da ALB.....	105
Figura 41. Tendências dos índices de extremos climáticos de temperatura no Grupo 1 da ALB, no período de 1981–2012.....	110
Figura 42. Tendências dos índices de extremos climáticos de temperatura no Grupo 2 da ALB, no período de 1981–2012.....	110
Figura 43. Tendências dos índices de extremos climáticos de temperatura no Grupo 3 da ALB, no período de 1981–2012.....	111
Figura 44. Tendências dos índices de extremos climáticos de temperatura no Grupo 4 da ALB, no período de 1981–2012.....	112
Figura 45. Tendências dos índices de extremos climáticos de temperatura no Grupo 5 da ALB, no período de 1981–2012.....	112
Figura 46. Tendências dos índices de extremos climáticos de temperatura no Grupo 6 da ALB, no período de 1981–2012.....	113

LISTA DE TABELAS

Tabela 1. Modelo do CMIP6 usado no estudo e suas principais características.....	21
Tabela 2. Índices climáticos derivados de dados diários de precipitação e temperaturas máximas e mínimas, com definições e unidades.....	30
Tabela 3. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos Diagramas de Taylor (temperatura mínima).....	100
Tabela 4. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no KGE (temperatura mínima).....	101
Tabela 5. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos vieses (temperatura mínima).....	101
Tabela 6. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no MAE (temperatura mínima).....	101
Tabela 7. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no RMSE (temperatura mínima).....	102
Tabela 8. Ranking com a classificação final do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB (temperatura mínima).....	102
Tabela 9. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos Diagramas de Taylor (temperatura máxima).....	106
Tabela 10. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no KGE (temperatura máxima).....	107
Tabela 11. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos vieses (temperatura máxima).....	107
Tabela 12. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no MAE (temperatura máxima).....	108
Tabela 13. Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no RMSE (temperatura máxima).....	108
Tabela 14. Ranking com a classificação final do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB (temperatura máxima).....	108

LISTA DE ABREVIATURAS

IPCC – Painel Intergovernamental de Mudanças Climáticas
ALB – Amazônia Legal Brasileira
IBGE - Instituto Brasileiro de Geografia e Estatística
ACC – Análise de Correlações Canônicas
RCP – Regressão por Componentes Principais
CMIP – Coupled Model Intercomparison Project
INMET – Instituto Nacional de Meteorologia
ANA – Agência Nacional de Água e Saneamento Básico
MSTs – Modelos do Sistema Terrestre
MCRs – Modelos Climáticos Regionais
MCGs – Modelos Climáticos Globais
BDMEP – Banco de Dados Meteorológicos para Ensino e Pesquisa
EL – Escalonamento Linear
QQ – Mapeamento Quantil-Quantil
MPI – Modelo do Instituto Max Planck
RegCM – Modelo Climático Regional
TSM – Temperatura da Superfície do Mar
ZCAS – Zona de Convergência do Atlântico Sul
ZCIT – Zona de Convergência Intertropical
SAMS – Sistema de Monção da América do Sul
ENSO – El Niño Oscilação Sul
CPT – Climate Predictability Tool
MAE – Erro Médio Absoluto
RMSE – Raiz do Erro Quadrático Médio
INPE – Instituto Nacional de Pesquisas Espaciais
MUGDs – Modelos de Vegetação Climática Dinâmicos
CORDEX – Experiência Coordenada de Redução de Escala Climática Regional
WRF - Weather Research and Forecasting model
DD – Downscaling Dinâmico
DE – Downscaling Estatístico
CEM – Correção do Estado Médio

FDC – Função da Densidade Cumulativa

ACP – Análise de Componentes Principais

RLM – Regressão Linear Múltipla

CPs – Componentes Principais

HR – High Resolution (Alta Resolução)

OMA – One Moment Aerosol

AMIP – Atmosphere Model Intercomparison Project

CLM 4.5 – Community Land Model Version 4.5

IRI – International Research Institute for Climate and Society

Sumário

1. INTRODUÇÃO	1
2. OBJETIVOS	5
2.1 Geral	5
2.2 Específicos	5
3. REVISÃO DE LITERATURA	6
3.1 Mudanças Climáticas e a Modelagem do Clima	6
3.1.1 O Sistema Climático e a Importância da Amazônia para o Clima Regional e Global	6
3.1.2. Ferramentas para Projeções Climáticas: Modelos Climáticos	8
3.1.3 Análise de Extremos Climáticos na Amazônia	10
3.2 <i>Downscaling</i> Climático e a Modelagem Regional	11
3.2.1. A Necessidade do Refinamento de Escala (<i>Downscaling</i>).....	11
3.2.2. <i>Downscaling</i> Dinâmico: Os Modelos Climáticos Regionais (MCR).....	12
3.2.3. O Problema do Viés (Bias) em Simulações Climáticas	14
3.3 Métodos de Correção de Viés (<i>Bias Correction</i>)	15
3.3.1. Fundamentos e Objetivos da Correção de Viés.....	15
3.3.2. Categorias de Métodos de Correção de Viés.....	16
4. METODOLOGIA	18
4.1 Área de estudo.....	18
4.2 Dados Observados de Temperatura.....	19
4.3 Modelagem Climática e Delineamento Experimental.....	20
4.3.1 Configuração da Modelagem: do Global ao Regional	20
4.3.1.1 O Modelo de Sistema Terrestre Global: MPI.....	20
4.3.1.2 O <i>Downscaling</i> Dinâmico com o Modelo Climático Regional: RegCM	21
4.3.2 Delineamento dos Experimentos.....	23
4.4 Métodos de Correção de Viés	25
4.4.1 Análise de Correlação Canônica (ACC)	25
4.4.2 Regressão por Componentes Principais (RCP).....	26
4.5 O <i>software Climate Predictability Tool</i> (CPT)	26
4.6 Teste de Desempenho do Método	27
4.7 Análise de Cluster e Diagrama de Taylor	29
4.8 Análise de Extremos Climáticos	30
5. RESULTADOS.....	33
5.1 Climatologia Observada/MPI/REG – Temperatura Mínima.....	33

5.2	Diferenças entre os Dados Observados e os Modelos – Temperatura Mínima.....	38
5.3	Correlação entre os Dados Observados e o Modelo MPI – Temperatura Mínima.....	42
5.4	Correlação entre os Dados Observados e o Modelo REG – Temperatura Mínima.....	46
5.5	Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo MPI – Temperatura Mínima	50
5.6	Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo REG – Temperatura Mínima	54
5.7	Análise do Kling Gupta Efficiency (KGE) para o Modelo MPI – Temperatura Mínima.....	57
5.8	Análise do Kling Gupta Efficiency (KGE) Para o Modelo REG – Temperatura Mínima....	61
5.9	Climatologia Observada/MPI/REG – Temperatura Máxima	64
5.10	Diferenças entre os Dados Observados e os Modelos – Temperatura Máxima	68
5.11	Correlação entre os Dados Observados e o Modelo MPI – Temperatura Máxima	71
5.12	Correlação entre os Dados Observados e o Modelo REG – Temperatura Máxima	75
5.13	Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo MPI – Temperatura Máxima	79
5.14	Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo REG – Temperatura Máxima	83
5.15	Análise do Kling Gupta Efficiency (KGE) para o Modelo MPI – Temperatura Máxima ..	86
5.16	Análise do Kling Gupta Efficiency (KGE) para o Modelo REG – Temperatura Máxima .	90
5.17	Análise de Cluster	94
5.18	Análise Diagrama de Taylor	97
5.18.1	Diagrama de Taylor – Temperatura Mínima.....	97
5.18.2	Diagrama de Taylor – Temperatura Máxima	104
5.19	Análise da Tendência de Eventos Extremos	110
6.	Conclusões	116
7.	Referências Bibliográficas	118

1. INTRODUÇÃO

A Amazônia Legal Brasileira (ALB) é uma região político-administrativa que compreende aproximadamente 5,2 milhões de km², equivalente a cerca de 61% do território nacional (Almeida et al., 2017). Abrange nove estados: Acre, Amapá, Amazonas, Mato Grosso, Pará, Rondônia, Roraima, Tocantins e parte do Maranhão, incorporando áreas do bioma Amazônia, além de porções do Cerrado e do Pantanal (IBGE, 2023; Amaral e Silva et al., 2020).

O clima da ALB é caracterizado por temperaturas médias em torno de 25 °C e precipitação anual de aproximadamente 2300 mm, sendo cerca de metade desse volume associada à evapotranspiração da vegetação (Rocha et al., 2019). Nas últimas décadas, observou-se um aumento médio da temperatura na ordem de 0,03 a 0,05 °C por ano entre 1973 e 2013 (Ishihara et al., 2014), com reflexos diretos na intensificação de secas, incêndios florestais e vulnerabilidades socioambientais (Marengo et al., 2018). Projeções recentes do conjunto de modelos do CMIP6 indicam que tais eventos extremos tendem a se tornar mais frequentes, intensos e duradouros ao longo do século XXI (Parsons, 2020).

A variabilidade térmica na ALB é modulada por diferentes sistemas atmosféricos de grande escala e de escala regional. Dentre eles, destaca-se o Sistema de Monção da América do Sul (SAMS), que regula o ciclo anual de aquecimento e resfriamento da região, influenciando a sazonalidade da temperatura por meio da alternância entre períodos secos e úmidos (García-Franco et al., 2020). Durante a estação seca, a redução da nebulosidade e da precipitação favorece o aumento da radiação solar incidente e do aquecimento superficial, elevando a temperatura máxima do ar, enquanto na estação chuvosa o aumento da cobertura de nuvens atua como mecanismo moderador da temperatura (Albright et al., 2021).

Além disso, a atuação da Zona de Convergência Intertropical (ZCIT) exerce forte influência sobre o balanço de energia na porção norte da ALB, enquanto a Zona de Convergência do Atlântico Sul (ZCAS) contribui para a modulação da temperatura principalmente nas regiões sul e sudeste da Amazônia (Adam et al., 2016; Lemes et al., 2020). Fenômenos de variabilidade climática interanual, como o El Niño - Oscilação Sul (ENOS), também afetam de forma expressiva o regime térmico da região, com eventos de El Niño geralmente associados ao aumento da temperatura do ar e à intensificação de

ondas de calor, enquanto episódios de La Niña tendem a promover condições relativamente mais amenas (Cai et al., 2020). Esses sistemas, em conjunto com mudanças no uso e cobertura da terra, desempenham papel central na variabilidade espacial e temporal da temperatura na ALB.

A compreensão desses processos e a projeção de cenários climáticos futuros dependem fortemente do uso de modelos climáticos numéricos. Nesse contexto, os Modelos de Circulação Global (MCGs) desempenham papel fundamental na representação dos processos atmosféricos de grande escala. Entretanto, devido à sua resolução espacial limitada, entre 100 e 250 km, esses modelos apresentam restrições significativas para análises locais e regionais, especialmente em áreas de elevada complexidade ambiental como a Amazônia (Boé et al., 2007; IBRAM, 2023). Como alternativa, os Modelos Climáticos Regionais (MCRs) surgem como ferramentas capazes de refinar a resolução espacial das simulações, permitindo análises em escalas menores, inferiores a 10 km, e uma melhor representação dos processos físicos regionais (Tapiador et al., 2020).

Apesar desses avanços, tanto MCGs quanto MCRs apresentam vieses sistemáticos em variáveis-chave, como precipitação e temperatura, em função de simplificações físicas, incertezas nas parametrizações e limitações na representação da topografia, do uso da terra e dos processos atmosféricos de pequena escala (Sousa et al., 2023). Esses vieses comprometem a aplicação direta das saídas dos modelos em estudos climáticos regionais, particularmente em análises de extremos climáticos, uma vez que pequenas distorções na climatologia média podem resultar em erros substanciais na frequência, intensidade e persistência de eventos extremos.

Diante desse cenário, a necessidade de dados climáticos mais precisos para estudos hidrológicos, ecológicos e de planejamento energético torna imprescindível a aplicação de técnicas de redução de escala (*downscaling*) e de correção de viés. Essas técnicas buscam ajustar estatisticamente os resultados dos modelos, aproximando-os das observações e reduzindo erros sistemáticos (Srivastava et al., 2015). Entre essas metodologias, destacam-se desde abordagens mais simples, como a correção da média e o escalonamento linear, até métodos mais robustos, como o mapeamento quantílico, capaz de preservar características da distribuição estatística e melhorar a representação de extremos climáticos (Enayati et al., 2020).

Entretanto, a eficácia dessas técnicas depende fortemente das condições locais, especialmente em regiões de elevada complexidade ambiental como a ALB (Teutschbein & Seibert, 2012). Além disso, métodos tradicionais de correção nem sempre são capazes de corrigir adequadamente padrões espaciais e sazonais de variáveis climáticas, em particular da temperatura máxima e mínima, que estão diretamente associadas ao balanço de energia à superfície. Nesse contexto, métodos estatísticos multivariados surgem como alternativas promissoras, pois permitem explorar a variação conjunta entre campos simulados e observados, reduzindo erros sistemáticos, aumentando a coerência espacial e preservando sinais climáticos relevantes.

Dentre essas abordagens, destacam-se a Análise de Correlação Canônica (ACC) e a Regressão por Componentes Principais (RCP). A ACC é uma técnica estatística multivariada que identifica combinações lineares capazes de maximizar a correlação entre dois conjuntos de variáveis, sendo amplamente empregada em estudos de previsão sazonal e em análises de associação com fenômenos de grande escala, como o ENOS (Statheropoulos et al., 1998; Azevedo, 2015). A RCP, por sua vez, deriva da Análise de Componentes Principais (ACP) e atua na redução da dimensionalidade dos dados ao identificar os modos dominantes de variabilidade, utilizando os componentes obtidos como preditores em modelos de regressão. Essa abordagem é particularmente útil diante da forte correlação entre preditores em dados climáticos e tem sido amplamente aplicada em estudos de correção de viés climático (Song et al., 2019; Jackson, 2005).

Nesse contexto, o presente estudo propôs avaliar simulações de temperatura máxima e mínima obtidas pelo modelo climático global MPI-ESM1-2-HR (MPI) e regionalizadas pelo modelo RegCM4.7.1 (REG), aplicando métodos avançados de correção de viés baseados em ACC e RCP. A avaliação do desempenho dos modelos, antes e após a aplicação dessas técnicas, foi conduzida com base em métricas estatísticas amplamente utilizadas na climatologia, incluindo o coeficiente de correlação de Pearson (r), o viés médio, o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Eficiência de Kling-Gupta (KGE), que integra simultaneamente informações de correlação, variabilidade e viés, sendo particularmente adequado para avaliações hidrológicas e climáticas de forma robusta.

Além da avaliação estatística tradicional, o estudo incorporou a análise de extremos climáticos, por meio de índices padronizados recomendados pelo Expert Team

on Climate Change Detection and Indices (ETCCDI), permitindo investigar de forma explícita alterações na frequência, intensidade e persistência de extremos térmicos, possibilitando avaliar não apenas a capacidade dos modelos em reproduzir a climatologia média, mas também sua habilidade em capturar mudanças nos extremos associados à temperatura mínima e máxima.

Partindo da hipótese de que as simulações de temperatura máxima e mínima geradas pelos modelos MPI e REG apresentaram vieses sistemáticos sobre a ALB, comprometendo sua aplicação direta em estudos climáticos regionais e análises de extremos, assume-se, que a aplicação de métodos multivariados de correção de viés, como a ACC e a RCP, é capaz de reduzir significativamente esses erros, aumentar a coerência espacial, melhorar o desempenho estatístico, inclusive segundo o KGE, e aprimorar a representação da climatologia mensal e dos extremos térmicos, fortalecendo a confiabilidade das simulações climáticas para aplicações científicas e de planejamento.

2. OBJETIVOS

2.1 Geral

Avaliar o desempenho das simulações históricas de temperatura máxima e mínima geradas pelo modelo climático global MPI e por sua regionalização com o modelo REG para a ALB, no período de 1981 a 2012, bem como analisar a eficácia dos métodos multivariados de correção de viés, ACC e RCP, na redução dos erros sistemáticos associados a essas simulações.

2.2 Específicos

- **Avaliar** a capacidade do modelo MPI em representar a variabilidade espacial da temperatura máxima e mínima na ALB, por meio da comparação com dados observacionais em grade regular.

- **Analisar** o desempenho das simulações regionalizadas pelo modelo REG, investigando as melhorias proporcionadas pelo refinamento espacial e dinâmico em relação ao modelo global.

- **Identificar** e quantificar os vieses sistemáticos presentes nas simulações de temperatura máxima e mínima dos modelos MPI e REG, utilizando métricas estatísticas clássicas e integradas.

- **Aplicar** os métodos de correção de viés baseados na ACC e na RCP às saídas dos modelos, com o objetivo de reduzir erros sistemáticos, aumentar a coerência espacial e melhorar a representação da variabilidade temporal da temperatura.

- **Comparar** o desempenho dos modelos antes e após a correção de viés por meio de métricas estatísticas, como o coeficiente de correlação de Pearson, o viés médio, o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Eficiência de Kling-Gupta (KGE), destacando os ganhos obtidos com a aplicação das técnicas multivariadas.

- **Avaliar** a capacidade dos modelos, antes e após a correção de viés, em reproduzir índices de extremos climáticos.

3. REVISÃO DE LITERATURA

3.1 Mudanças Climáticas e a Modelagem do Clima

3.1.1 O Sistema Climático e a Importância da Amazônia para o Clima Regional e Global

A ALB, com cerca de 5,2 milhões de km², representa a maior região contínua de floresta tropical do planeta e abrange nove estados brasileiros, incorporando áreas dos biomas Amazônia, Cerrado e Pantanal (IBGE, 2025; FAS, 2024). Essa vasta região abriga um dos ecossistemas com maior diversidade biológica do mundo, desempenhando papel fundamental na regulação do clima regional e global, especialmente por meio dos ciclos hidrológicos e da retenção de carbono (Baccini et al., 2012; Houghton, 2013).

O clima da região é predominantemente equatorial úmido, com precipitações anuais que variam entre 1500 e 3000 mm, sustentadas em parte pela intensa evapotranspiração da floresta (Philip et al., 2020). A interação entre cobertura vegetal, hidrografia e atmosfera estabelece um sistema ambiental altamente acoplado, cuja estabilidade climática depende do balanço entre fluxos de energia e água (Marengo et al., 2017).

Nas últimas décadas, evidências observacionais indicam mudanças climáticas aceleradas na Amazônia, com aumento da temperatura média e intensificação de eventos extremos, como secas prolongadas, que afetam os estoques de biomassa, o ciclo hidrológico e a funcionalidade do ecossistema (Lewis et al., 2011). A seca de 2015–2016, considerada uma das mais severas já registradas, evidenciou a vulnerabilidade da região frente à variabilidade climática e ao aquecimento global (Marengo et al., 2018).

A intensificação das pressões antrópicas, especialmente associadas ao desmatamento, tem contribuído para alterações significativas nos regimes térmico e pluviométrico da região, impactando a biodiversidade, os serviços ecossistêmicos e a saúde das populações locais (Nepstad et al., 2008; Barona et al., 2010). A remoção da cobertura florestal favorece o aumento da temperatura da superfície e a redução da umidade do ar, elevando o risco de incêndios florestais e reforçando mecanismos de retroalimentação positiva do aquecimento regional (Silva Junior et al., 2021). Dados

recentes indicam que a Amazônia perdeu aproximadamente 17% de sua cobertura florestal original até 2021, com efeitos negativos já observáveis no clima regional (INPE, 2022).

A floresta amazônica exerce papel central na regulação do clima regional e global, sobretudo por sua influência nos ciclos biogeoquímicos e na manutenção do balanço energético à superfície. Estima-se que cerca de 50% da precipitação da região seja proveniente da evapotranspiração local, ressaltando a importância do ciclo da água para a estabilidade climática da bacia amazônica (Rocha et al., 2019). Além disso, a umidade transportada a partir da Amazônia contribui para a formação de chuvas em outras regiões da América do Sul, incluindo o Centro-Oeste, o Sudeste do Brasil e o norte da Argentina, influenciando padrões climáticos em escala continental (Machado-Silva et al., 2020).

A Amazônia também atua como um dos principais sumidouros de carbono do planeta, sendo responsável pela absorção de parcela significativa das emissões antropogênicas globais (Baccini et al., 2017). Contudo, estudos recentes indicam uma redução progressiva dessa capacidade em função do aumento da frequência e intensidade de secas, incêndios florestais, degradação florestal e desmatamento (Brienen et al., 2015; Artemperatura máxima, 2023). Estimativas apontam que os distúrbios florestais responderam por cerca de 44% das perdas de carbono florestal na Amazônia brasileira entre 2003 e 2019, enquanto o desmatamento formal contribuiu com aproximadamente 56% dessas perdas (Gatti et al., 2021).

Além do dióxido de carbono, outros gases de efeito estufa e aerossóis, como metano (CH_4), óxido nitroso (N_2O) e partículas de carbono negro, desempenham papel relevante no balanço radiativo regional, podendo alterar o efeito líquido da bacia amazônica sobre o clima global e regional (Artaxo et al., 2013). Evidências sugerem que o sistema amazônico se aproxima de um ponto crítico, no qual o aumento do desmatamento, associado ao aquecimento global e à intensificação das secas, pode desencadear mudanças irreversíveis no ecossistema, com conversão de áreas florestais em formações mais abertas e secas (Lovejoy & Nobre, 2018).

Observações indicam que a temperatura média na Amazônia aumentou cerca de 0,6 a 0,7 °C nas últimas quatro décadas, com 2016 aparecendo como o ano mais quente desde meados do século XX (Marengo et al., 2018). O aumento das concentrações

atmosféricas de CO₂ pode induzir a redução da abertura dos estômatos das plantas, reduzindo a transpiração e potencialmente intensificando o aquecimento local por meio da alteração dos fluxos de calor latente e sensível (Lemes et al., 2022).

3.1.2. Ferramentas para Projeções Climáticas: Modelos Climáticos

A projeção de cenários climáticos futuros constitui um dos pilares da ciência climática moderna e baseia-se no uso de modelos climáticos numéricos. Os primeiros avanços na modelagem do clima ocorreram a partir de modelos conceituais simples, como os modelos de balanço de energia de dimensão zero, que estabeleceram os princípios fundamentais do efeito estufa (Manabe & Wetherald, 1967). Com o avanço teórico e computacional, foram desenvolvidos os Modelos de Circulação Global (MCGs), que passaram a resolver numericamente as equações da dinâmica atmosférica e oceânica, permitindo a simulação das interações em larga escala entre atmosfera, oceanos e superfície terrestre (Edwards, 2010).

Apesar de sua complexidade, os MCGs apresentam uma limitação fundamental associada à sua resolução espacial relativamente grosseira, com grades que tipicamente variam entre 100 e 250 km (Boé et al., 2007; Flato et al., 2013). Essa limitação dificulta a representação explícita de processos de mesoescala, como a convecção profunda, efeitos topográficos detalhados e circulações locais, restringindo sua aplicação direta em estudos regionais e de impacto local. Estudos de intercomparação entre modelos climáticos e dados observacionais indicam que tais limitações se refletem em vieses sistemáticos persistentes na simulação da temperatura máxima e mínima, mesmo em modelos globais de alta complexidade, evidenciando dificuldades na representação adequada do balanço de energia à superfície e dos processos físicos associados aos ciclos diurno e noturno da temperatura (Zhu et al., 2020; Sun et al., 2015).

Com o objetivo de representar de forma mais abrangente os processos que controlam o sistema climático, surgiram os Modelos do Sistema Terrestre (MSTs), que representam o estado da arte da modelagem climática global (Döscher et al., 2022). Esses modelos incorporam, além dos processos físicos tradicionais, componentes biogeoquímicos, permitindo a simulação das interações entre clima, biosfera, química atmosférica e ciclos biogeoquímicos (IPCC, 2021). Entre esses ciclos, destaca-se o ciclo

do carbono, cuja representação envolve a simulação da absorção de CO₂ pelos oceanos e ecossistemas terrestres, bem como a resposta da vegetação às mudanças climáticas e às variações na concentração atmosférica de CO₂ (Cox et al., 2000; Friedlingstein et al., 2020; Sitch et al., 2008). Outros ciclos, como o do nitrogênio, também são incorporados, adicionando maior realismo às interações entre biosfera e clima (Thornton et al., 2009).

Os MSTs mais recentes incluem ainda a representação interativa de aerossóis e da criosfera, permitindo simular seus efeitos diretos e indiretos sobre o balanço radiativo e o sistema climático global, embora esses processos ainda representem importantes fontes de incerteza nas projeções climáticas (Bellouin et al., 2020; Vizcaíno et al., 2009; IPCC, 2021). Apesar do avanço conceitual e físico desses modelos, a limitação associada à resolução espacial permanece, especialmente para aplicações em escala regional, o que restringe a representação detalhada de gradientes térmicos e padrões espaciais de temperatura.

Nesse contexto, a redução de escala dinâmica por meio dos Modelos Climáticos Regionais (MCRs) torna-se fundamental. Os MCRs utilizam as condições de contorno fornecidas por MCGs ou MSTs para realizar simulações em alta resolução espacial, geralmente entre 10 e 50 km, sobre regiões específicas de interesse (Matte et al., 2017). Esse processo de aninhamento, amplamente adotado em iniciativas como o CORDEX, permite uma melhor representação dos processos regionais e da variabilidade espacial das variáveis climáticas, mantendo a consistência física com os cenários de grande escala (Gutowski et al., 2020).

Entretanto, um desafio comum a MCGs, MSTs e MCRs é a presença de vieses sistemáticos quando suas simulações são comparadas a dados observados (Chokkavarapu & Mandla, 2019; Maraun, 2016). Esses vieses estão associados a limitações nas parametrizações de processos subgrade, simplificações na representação do uso e cobertura do solo e dificuldades em simular adequadamente as interações entre circulação atmosférica e topografia (Arakawa, 2004). No caso específico da temperatura, estudos de intercomparação indicam que erros na simulação da temperatura máxima estão frequentemente relacionados à representação do balanço radiativo diurno, enquanto vieses na temperatura mínima tendem a estar associados a processos noturnos, como a turbulência e o acoplamento superfície-atmosfera, reforçando a necessidade de análises

específicas para temperatura máxima e temperatura mínima (Anwar & Mostafa., 2023; Lorenz et al., 2014).

Para lidar com essas limitações, a correção estatística de viés tornou-se uma etapa essencial no uso de dados modelados, especialmente antes de sua aplicação em análises de impacto climático (Teutschbein & Seibert, 2012). Nesse contexto, os Experimentos de Intercomparação de Modelos Acoplados, como o CMIP6, foram estabelecidos para padronizar o desenvolvimento, a avaliação e a comparação entre modelos climáticos, incorporando diferentes cenários socioeconômicos e trajetórias de concentração de gases de efeito estufa (Eyring et al., 2016). Apesar dos avanços, estudos recentes indicam a persistência de vieses relevantes nas simulações do CMIP6, reforçando a necessidade de avaliações regionais detalhadas e da aplicação de técnicas de correção de viés (Monteverde et al., 2022).

As incertezas associadas às projeções climáticas decorrem, principalmente, de três fontes: os cenários futuros de emissões e uso do solo, as diferenças estruturais entre modelos e a variabilidade natural do sistema climático (Hawkins & Sutton, 2009). Em projeções de curto prazo, até aproximadamente 2040, a variabilidade natural e as diferenças entre modelos tendem a dominar as incertezas, enquanto em projeções de longo prazo, até 2100, a escolha do cenário de emissões torna-se o fator predominante (Lehner et al., 2020).

3.1.3 Análise de Extremos Climáticos na Amazônia

A análise de extremos climáticos na Amazônia é fundamental para compreender as variações e impactos dos eventos extremos, como ondas de calor, secas severas, e chuvas intensas, que têm aumentado em frequência e intensidade nas últimas décadas (Lucas et al., 2021; Luiz-Silva et al., 2025). Esses eventos extremos influenciam diretamente a saúde dos ecossistemas, a segurança hídrica, a agricultura, e a qualidade de vida das populações locais, além de representarem desafios críticos para a adaptação às mudanças climáticas (Espinoza et al., 2024; Silva et al., 2023).

Estudos recentes demonstram que a região amazônica apresenta uma tendência de aumento tanto na temperatura máxima diária quanto nos episódios de chuvas intensas, condicionada por alterações globais e regionais do sistema climático (Costa et al., 2022;

Terassi et al., 2023). Por exemplo, a ocorrência de secas hidrológicas severas nas últimas duas décadas evidenciou a sensibilidade da Amazônia a condições extremas que afetam a disponibilidade hídrica e aumentam o risco de incêndios florestais (Jimenez-Muñoz et al., 2016; Panisset et al., 2018).

A modelagem climática desses extremos na Amazônia ainda representa um desafio, devido à complexidade da interação entre vegetação, hidrografia e o sistema atmosférico (Brito et al., 2023). A alta variabilidade espacial e temporal dos eventos extremos exige o uso de modelos com alta resolução regional e a aplicação de técnicas específicas para identificar, caracterizar e projetar esses eventos (Duffy et al., 2015).

Além disso, a correção de viés nos modelos climáticos deve considerar especialmente os extremos, pois técnicas convencionais podem não preservar adequadamente os eventos climáticos extremos, fundamentais para análises de risco e planejamento ambiental (Trentini et al., 2022; Maraun et al., 2017). Métodos como o mapeamento quantílico, que ajusta a distribuição completa dos dados, têm se mostrado eficazes para manter a representatividade dos extremos (Holthuijzen et al., 2021).

Estratégias recentes, como o uso de abordagens multivariadas e técnicas baseadas em aprendizado de máquina, também têm demonstrado avanços na preservação e correção de extremos em simulações climáticas (Zhang et al., 2024).

3.2 *Downscaling* Climático e a Modelagem Regional

3.2.1. A Necessidade do Refinamento de Escala (*Downscaling*)

A resolução espacial relativamente grosseira dos Modelos de Circulação Global (MCGs) limita sua aplicação em estudos climáticos regionais e de impacto, que frequentemente requerem variáveis meteorológicas em resoluções espaciais inferiores a 10 km. Em contraste, a resolução típica dos MCGs situa-se entre 100 e 250 km, o que dificulta a representação adequada de processos regionais e locais (Richter et al., 2015). Nesse contexto, o *downscaling*, ou redução de escala, torna-se uma etapa fundamental para a obtenção de informações climáticas em alta resolução a partir das saídas dos modelos globais.

O *downscaling* pode ser realizado por meio de duas abordagens principais. A primeira consiste no *downscaling* dinâmico, que se baseia em modelos físicos e busca aumentar a resolução espacial das simulações climáticas por meio do aninhamento de um Modelo Climático Regional (MCR) a um MCG ou a um Modelo do Sistema Terrestre (Tapiador et al., 2020). Essa abordagem permite a simulação explícita de processos atmosféricos regionais, mantendo a consistência física com as condições de grande escala.

A segunda abordagem corresponde ao *downscaling* estatístico, que se fundamenta no estabelecimento de relações empíricas entre variáveis de grande escala, denominadas predictoras, e variáveis locais, ou predictandas, na região de interesse (Sachindra et al., 2016). Para a construção dessas relações são utilizadas diversas técnicas estatísticas, incluindo regressão linear, Análise de Correlação Canônica (ACC) e redes neurais artificiais (Karamouz et al., 2010). Entre as principais vantagens do *downscaling* estatístico destacam-se a relativa simplicidade de implementação e a capacidade de gerar informações climáticas em escala local a partir das saídas dos modelos globais.

Entretanto, o *downscaling* estatístico apresenta limitações importantes, uma vez que muitos métodos assumem estacionariedade das relações estatísticas ao longo do tempo e não consideram explicitamente os princípios físicos que regem o sistema atmosférico (Abatzoglou & Brown, 2011). Além disso, variáveis climáticas são frequentemente tratadas de forma independente, o que pode resultar em inconsistências físicas, como o desacoplamento entre temperatura e umidade relativa. A precisão desses métodos também tende a diminuir nas extremidades da distribuição, levando à subestimação de eventos extremos (Fowler et al., 2007).

3.2.2. *Downscaling* Dinâmico: Os Modelos Climáticos Regionais (MCR)

Os Modelos Climáticos Regionais constituem a principal ferramenta para a aplicação do *downscaling* dinâmico, permitindo o refinamento da resolução espacial das simulações climáticas para escalas regionais, geralmente inferiores a 10 km, e fornecendo resultados fisicamente consistentes em escalas subcontinentais (Wilby et al., 2004; Goodess et al., 2005). Ao operar em domínios limitados e com maior detalhamento espacial, os MCRs possibilitam uma melhor representação de processos regionais, como

interações solo-atmosfera, efeitos topográficos e gradientes térmicos, que não são adequadamente resolvidos por modelos globais.

No contexto deste estudo, as simulações de temperatura para a ALB são aprimoradas a partir do modelo climático global MPI, regionalizado por meio do modelo REG. O REG é um MCR amplamente utilizado em estudos climáticos regionais, com aplicações em diferentes regiões do globo e reconhecida capacidade de representar padrões espaciais de temperatura e precipitação. Avaliações sobre a América do Sul indicam que o REG apresenta ganhos substanciais na representação da variabilidade espacial do clima quando comparado aos modelos globais, embora seu desempenho seja sensível às parametrizações físicas adotadas, especialmente aquelas relacionadas aos processos de superfície e ao balanço de energia (Teodoro et al., 2021; Pareja-Quispe et al., 2021).

Diversos estudos têm avaliado o desempenho do REG em diferentes contextos climáticos. Na China, por exemplo, demonstrou capacidade satisfatória na simulação da temperatura e da precipitação, embora apresente limitações regionais específicas (Tong et al., 2020; Gao et al., 2020). Na Península Arábica, Almazroui (2012) mostrou que o REG, aninhado ao modelo global ECHAM5, apresentou desempenho superior ao do próprio MCG, fornecendo padrões espaciais mais realistas, especialmente em regiões de topografia complexa.

Na Amazônia, estudos aplicando o REG evidenciam que a escolha das parametrizações físicas exerce influência significativa sobre o balanço de energia à superfície e, conseqüentemente, sobre a simulação da temperatura e da umidade relativa. Investigações regionais mostram que diferentes configurações físicas do modelo podem resultar em variações expressivas na magnitude e na distribuição espacial da temperatura próxima à superfície, destacando a forte interação entre vegetação, solo e atmosfera, característica do bioma amazônico. Resultados semelhantes foram observados por Anwar et al. (2021), que demonstraram que diferentes esquemas hidrológicos no RegCM4 afetam de forma significativa os fluxos de calor e a variabilidade térmica, reforçando a importância de uma configuração adequada do modelo regional para capturar as particularidades climáticas da região. Outras aplicações relevantes incluem o uso do RegCM3 para analisar a sazonalidade da precipitação na Amazônia (Ferreira et al., 2012)

e do RegCM4 para projeções futuras da precipitação sazonal na ALB (De Souza et al., 2016).

No presente trabalho, o REG foi empregado para regionalizar as saídas do MPI, utilizando um domínio específico para a ALB e uma resolução horizontal de 25 km. Essa configuração visa aprimorar o detalhamento espacial das simulações de temperatura máxima e mínima, permitindo análises mais robustas dos padrões térmicos regionais e de sua variabilidade sazonal. Entretanto, estudos prévios, reconhecem que a regionalização dinâmica, embora essencial, não elimina completamente os vieses sistemáticos associados à representação do balanço de energia e das interações solo-atmosfera, o que reforça a necessidade da aplicação de métodos estatísticos adicionais de correção de viés, conforme adotado neste estudo (Mbienda et al., 2023; Reboita et al., 2014).

3.2.3. Implicações do Viés (Bias) em Simulações Climáticas

Um dos principais desafios da modelagem climática consiste na presença persistente de vieses, ou erros sistemáticos, nas simulações, mesmo quando estas apresentam boa correlação com dados observados (Maraun, 2016). Esses vieses podem ter origem em limitações na representação da física de processos atmosféricos, na parametrização de processos subgrade, na representação do uso e cobertura do solo e na complexidade da interação entre circulação atmosférica e topografia.

A presença de vieses compromete a qualidade das simulações climáticas, podendo resultar em representações imprecisas de padrões espaço-temporais e de eventos extremos. Dados de reanálise, por exemplo, tendem a subestimar determinados extremos devido à resolução espacial limitada, enquanto simulações de mesoescala, como as produzidas pelo modelo WRF, frequentemente superestimam a precipitação convectiva em regiões montanhosas (Maraun et al., 2017). Dessa forma, as saídas dos modelos climáticos, em especial dos Modelos Climáticos Regionais (MCRs), não são recomendadas para uso direto como dados de entrada em modelos de impacto, uma vez que apresentam vieses sistemáticos em relação às observações. Tais vieses podem estar associados a erros na representação das médias climatológicas, da variabilidade temporal e espacial, bem como da frequência e intensidade de eventos extremos. Como os modelos de impacto são altamente sensíveis às condições climáticas de entrada, a utilização direta

dessas simulações pode resultar em propagação e amplificação dos erros, comprometendo a confiabilidade dos resultados (Sørland et al., 2018).

A correção de viés é, portanto, considerada uma etapa essencial para aumentar a confiabilidade das simulações climáticas. Contudo, sua aplicação em estudos de mudanças climáticas envolve a hipótese de estacionariedade, segundo a qual as relações estatísticas estabelecidas para o clima presente permanecem válidas sob condições climáticas futuras, aspecto que ainda constitui um ponto de debate na literatura científica (Palmer & Weisheimer, 2011).

3.3 Métodos de Correção de Viés (*Bias Correction*)

3.3.1. Fundamentos e Objetivos da Correção de Viés

A aplicação de técnicas de correção de viés é fundamental para mitigar os erros sistemáticos presentes nas simulações climáticas, contribuindo para a redução do viés médio e da raiz do erro quadrático médio (RMSE) quando comparadas a dados observados (Pierce et al., 2015). O objetivo central dessas técnicas consiste em ajustar estatisticamente as saídas dos modelos climáticos de modo que reproduzam, de forma mais fiel, as estatísticas observadas de uma determinada variável climática (Terink et al., 2010).

De maneira geral, a correção de viés busca reduzir discrepâncias sistemáticas entre os dados simulados e observados, promovendo maior aderência entre as distribuições de probabilidade das séries corrigidas e das observações (Mendez et al., 2020; Luo et al., 2025). Além da redução do erro médio, esse processo tende a melhorar a distribuição dos resíduos, tornando-a mais simétrica e próxima de uma distribuição normal, o que aumenta a confiabilidade das simulações corrigidas (Crank et al., 2020).

Esses aprimoramentos são particularmente relevantes para estudos de impacto climático em áreas como hidrologia, ecologia e planejamento energético. No entanto, a eficácia das técnicas de correção de viés pode variar significativamente em função das características regionais, da variável analisada e da complexidade do terreno (Hoffmann & Rath, 2012). Ademais, a aplicação dessas técnicas pode alterar a forma da distribuição

de probabilidade das variáveis corrigidas, o que exige cautela na interpretação dos resultados.

3.3.2. Categorias de Métodos de Correção de Viés

Os métodos de correção de viés diferem amplamente em termos de complexidade e abrangência, variando desde ajustes estatísticos simples até técnicas multivariadas mais avançadas. Entre as abordagens mais diretas destacam-se a Correção do Estado Médio (CEM), que ajusta apenas a média das séries simuladas, e o Escalonamento Linear (EL), que corrige simultaneamente a média e a variância dos dados. O EL é frequentemente considerado uma das técnicas mais simples e amplamente utilizadas, especialmente em análises com resolução mensal, nas quais seu desempenho pode ser comparável ao de métodos mais complexos (Ines & Hansen, 2006).

Entre os métodos mais sofisticados, o Mapeamento Quantil-Quantil (*Quantile Mapping* - QQ) é amplamente empregado por sua capacidade de corrigir toda a distribuição probabilística das variáveis climáticas, sendo particularmente eficaz para dados diários ou subdiários e para a preservação de extremos. Essa técnica baseia-se no ajuste da Função de Distribuição Acumulada (FDA) das simulações à FDA das observações, a partir da construção de uma função de correção (Cannon et al., 2015). Apesar de sua ampla aceitação, o QQ apresenta limitações relevantes, como a incapacidade de corrigir adequadamente a autocorrelação temporal das séries e a aplicação independente a cada variável, o que pode resultar em inconsistências físicas quando os vieses entre variáveis são interdependentes (Enayati et al., 2020).

Outras abordagens incluem a Transformação de Potência, o Escalonamento Baseado em Distribuição e métodos baseados em cópulas, que permitem o acoplamento estatístico entre diferentes variáveis climáticas, como temperatura e precipitação, em distribuições conjuntas. Contudo, a escolha do método mais adequado depende do objetivo do estudo, da variável analisada e da escala temporal considerada.

No presente trabalho, o foco recai sobre a aplicação e avaliação de dois métodos multivariados de correção de viés aplicados à temperatura: a ACC e a RCP.

A ACC é uma técnica estatística multivariada que busca identificar combinações lineares entre dois conjuntos de variáveis de modo a maximizar a correlação entre eles. O método permite a construção de variáveis canônicas, que são combinações lineares ortogonais das variáveis originais, capazes de representar de forma eficiente a covariabilidade entre campos simulados e observados (Klami et al., 2013). Na climatologia, a ACC é amplamente utilizada em estudos de previsão sazonal e em análises associadas a fenômenos de grande escala, como o ENOS. Um passo comum na aplicação da ACC envolve o pré-processamento dos dados por meio da Análise de Funções Ortogonais Empíricas (AFOE), com o objetivo de reduzir ruídos e extrair os padrões dominantes de variabilidade.

A RCP, por sua vez, baseia-se na combinação da Análise de Componentes Principais (ACP) com a regressão linear múltipla. A ACP é utilizada inicialmente para reduzir a dimensionalidade do conjunto de preditores, transformando variáveis potencialmente correlacionadas em um conjunto menor de componentes principais não correlacionados, que retêm a maior parte da variabilidade dos dados originais (Loganathan & Mahindrakar, 2021). Em seguida, esses componentes principais são empregados como variáveis explicativas em um modelo de regressão para estimar a variável de interesse (Liu et al., 2003).

No contexto deste estudo, a RCP mostra-se particularmente adequada para a correção de viés de simulações de temperatura provenientes de modelos climáticos, como o MPI e suas regionalizações pelo REG, uma vez que a temperatura apresenta, em geral, uma distribuição aproximadamente normal (Ling et al., 2021). A aplicação da RCP permite ajustar não apenas a média, mas também a variância das séries simuladas, contribuindo para a redução de vieses sistemáticos, como o viés frio frequentemente observado em períodos noturnos e de madrugada. Além disso, a ACP auxilia na filtragem de ruídos de pequena escala e na identificação de padrões de baixa frequência nos dados climáticos (Jolliffe, 2002).

De modo geral, embora os modelos climáticos globais e regionais apresentem avanços significativos na representação do clima amazônico, persistem desafios relacionados à precisão das simulações e à presença de vieses sistemáticos. Nesse cenário, a aplicação de métodos multivariados de correção de viés, como a ACC e a RCP, constitui uma abordagem promissora para aprimorar a qualidade das simulações de temperatura

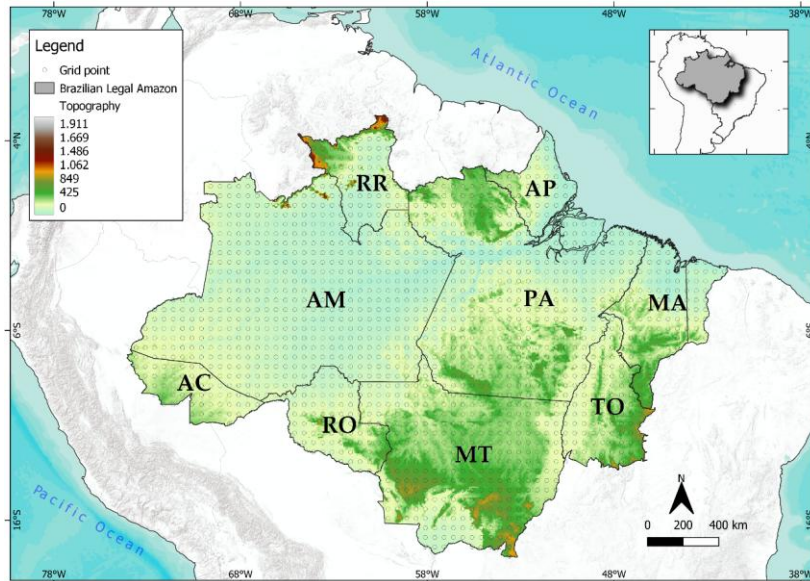
regionalizadas para a ALB, aumentando a robustez das análises climáticas e subsidiando estudos futuros de impacto climático na região.

4. METODOLOGIA

4.1 Área de estudo

A ALB é uma região político-administrativa estabelecida por lei, abrangendo aproximadamente 5,2 milhões de km², o que representa cerca de 58% a 61% do território brasileiro (IBGE, 2015). Esta vasta área inclui os estados do Acre, Amapá, Amazonas, Mato Grosso, Pará, Rondônia, Roraima, Tocantins e uma porção oeste do Maranhão (Figura 1). A ALB possui uma grande diversidade de ecossistemas, predominantemente coberta por florestas (cerca de 63%), mas também inclui formações não-florestais como savanas e campos, além de partes dos biomas Cerrado e Pantanal (Valente et al., 2013). Sua geomorfologia é diversa, com planaltos, planícies e depressões, sendo aproximadamente 74% do território formado por terreno irregular. O clima é majoritariamente tropical, com uma temperatura média de cerca de 25°C e baixa variação sazonal (Alvares et al., 2013). A precipitação média na região é de aproximadamente 2300 mm/ano, com cerca de 50% dessa precipitação proveniente da evapotranspiração da própria bacia amazônica (Martin et al., 2021).

Figura 1. Localização geográfica da ALB na América do Sul, com ênfase em sua topografia com as respectivas abreviaturas de cada estado e a respectiva distribuição espacial dos pontos de grau da precipitação observada na ALB.



Fonte: Silva et al (2025).

A sazonalidade da precipitação e a transição entre as estações úmida e seca estão intrinsecamente ligadas ao SAMS (Custódio et al., 2024). Fenômenos de grande escala como a ZCIT, a ZCAS e oscilações na Temperatura da Superfície do Mar (TSM) nos oceanos Atlântico e Pacífico, como o El Niño e La Niña, influenciam a variabilidade da precipitação, com o El Niño geralmente associado à redução de chuvas e o La Niña ao aumento (Filho et al., 2021; Córdova et al., 2022).

A Floresta Amazônica é crucial para a regulação climática regional e global, o estoque de carbono e a manutenção da biodiversidade (Albert et al., 2023; Soto-Navarro et al., 2020). A ALB é um ponto crítico de mudança climática, com o aquecimento e os déficits de chuva já contribuindo para secas e estresse da vegetação, e projeções indicando secas mais longas e intensas (Boulton et al., 2021; Artemperatura máxima et al., 2021). A região tem sofrido impactos significativos decorrentes de atividades antrópicas, principalmente da expansão da agricultura e da pecuária, resultando em elevadas taxas de desmatamento e no aumento das temperaturas máximas (Nobre et al., 2016). Essas atividades alteram a cobertura vegetal, afetando os fluxos de energia, os padrões de circulação atmosférica e os regimes de chuva e temperatura (Almada et al., 2024).

4.2 Dados Observados de Temperatura

Para a avaliação do desempenho das simulações climáticas na ALB, foram utilizados dados observados de temperatura máxima e mínima, provenientes da base

gradeada desenvolvida por Xavier et al. (2022). Essa base de dados consiste em uma das mais completas compilações de variáveis meteorológicas de superfície para o Brasil, construída a partir de registros de diferentes redes observacionais federais, estaduais, municipais e de instituições independentes, submetidos a rigorosos procedimentos de controle de qualidade.

A base de Xavier et al. (2022) fornece dados em grade regular com resolução espacial de $0,1^\circ \times 0,1^\circ$, cobrindo o período de 1961 a 2024. No presente estudo, foram utilizadas exclusivamente as variáveis de temperatura máxima e mínima diária, no período de 1981 a 2012, de modo a garantir compatibilidade temporal com as simulações dos modelos climáticos analisados.

Para permitir a comparação direta com as saídas dos modelos MPI e REG, os dados observacionais foram interpolados para uma grade comum com resolução espacial de $0,5^\circ \times 0,5^\circ$, adotada como referência observacional final. Essa etapa assegurou a consistência espacial entre os dados observados e modelados, minimizando efeitos associados a diferenças de resolução na avaliação estatística do desempenho dos modelos.

4.3 Modelagem Climática e Delineamento Experimental

Neste estudo, foi empregada uma abordagem de modelagem climática de forma integrada, em que simulações em escala global serviram de base para a produção de projeções regionais com maior detalhamento espacial. As projeções regionalizadas foram, em seguida, analisadas e submetidas a técnicas de correção de viés, visando à mitigação de erros sistemáticos e ao aprimoramento da representação das temperaturas máxima e mínima na área da ALB.

4.3.1 Configuração da Modelagem: do Global ao Regional

4.3.1.1 O Modelo de Sistema Terrestre Global: MPI

A base da modelagem climática deste estudo foi o *Max Planck Institute Earth System Model 1.2*, na sua versão de Alta Resolução (MPI-ESM1-2-HR). Desenvolvido no Instituto Max Planck de Meteorologia (MPI-M), na Alemanha, este modelo é um dos pilares do 6º Projeto de Intercomparação de Modelos Acoplados (CMIP6), que

fundamenta os relatórios do Painel Intergovernamental sobre Mudanças Climáticas (IPCC).

Como um MST, o MPI simula não apenas os componentes físicos do clima (atmosfera, oceanos, gelo e solo), mas também os ciclos biogeoquímicos, como o ciclo do carbono. Essa capacidade o torna particularmente relevante para estudos em ecossistemas complexos como a Amazônia. Sua configuração "HR" (Alta Resolução), com uma grade de aproximadamente 100 km (Hertwig et al., 2015; Mauritsen et al., 2018), permite uma representação dos padrões climáticos globais, sendo uma base sólida para o *downscaling* regional.

Neste trabalho, o MPI foi utilizado para fornecer as simulações históricas de larga escala, que serviram como condições de contorno para o processo de *downscaling* dinâmico.

A tabela 1 apresenta as informações desse modelo, como o membro do conjunto, país de origem, componente do modelo atmosférico e resolução atmosférica. Os membros do conjunto são divididos em quatro índices que representam os atributos globais específicos de cada modelo: "r" para realização, "i" para inicialização, "p" para física e "f" para forçamento. O nome do conjunto "r1i1p1f1" sugere que os membros do conjunto apresentam as mesmas condições iniciais e físicas, com o forçamento "f1" derivado de simulações de *One-Moment Aerosol (OMA)* do *Atmospheric Model Intercomparison Project (AMIP)*.

Tabela 1. Modelo do CMIP6 usado no estudo e suas principais características.

Modelo CMIP6	Membro do conjunto	País de Origem	Componente do modelo atmosférico	Resolução atmosférica (Lat × Long)	Referência
MPI-ESM1-2-HR	r1i1p1f1	Alemanha	ECHAM6.3	0.9° × 0.9°	Jungclaus, Bittner and Wieners (2019)

4.3.1.2 O Downscaling Dinâmico com o Modelo Climático Regional: RegCM

Com o objetivo de obter maior detalhamento espacial das simulações climáticas sobre a ALB, foi empregado o método de *downscaling* dinâmico por meio do REG, em sua versão 4.7.1. O REG é um modelo climático regional de código aberto, desenvolvido

e mantido pelo Centro Internacional de Física Teórica Abdus Salam (ICTP), amplamente utilizado em estudos de climatologia regional.

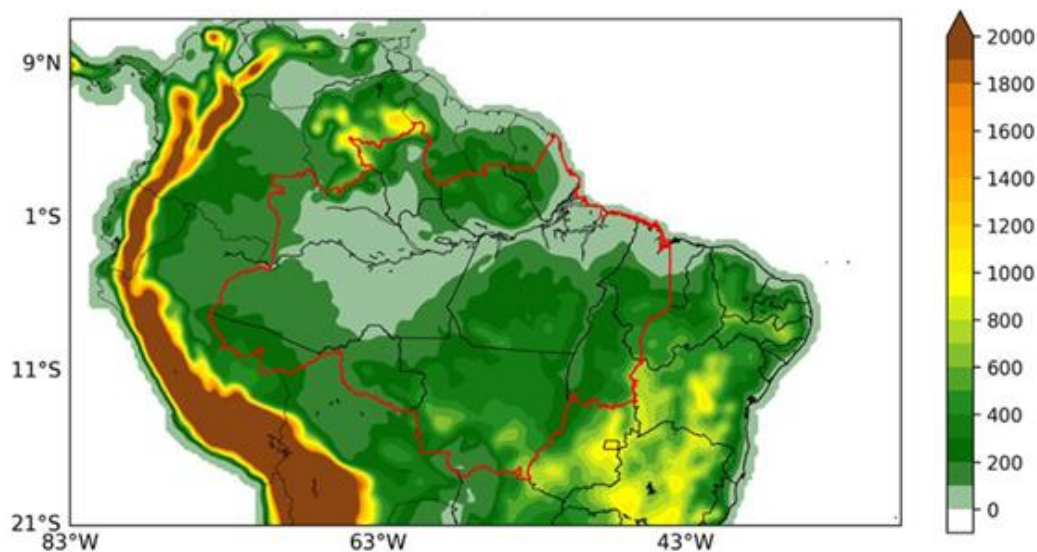
O REG utiliza as simulações de larga escala do modelo global MPI como condições de contorno laterais e de superfície, resolvendo explicitamente as equações da dinâmica e da física da atmosfera dentro de um domínio regional limitado. No presente estudo, as simulações foram realizadas com resolução horizontal de 25 km, 23 níveis verticais e topo do modelo em 50 hPa. Esse refinamento espacial possibilita uma melhor representação de processos relevantes para o clima amazônico, como os efeitos da topografia, do uso e cobertura da terra e a variabilidade associada a sistemas convectivos de pequena escala, que não são adequadamente capturados por modelos globais.

O primeiro ano da simulação, correspondente a 1980, foi considerado como período de estabilização do modelo (*spin-up*) e, portanto, excluído das análises seguintes. Para a representação dos processos na interface solo-planta-atmosfera, foi utilizado o modelo de superfície acoplado *Community Land Model* versão 4.5 (CLM4.5).

As simulações foram conduzidas utilizando a projeção Mercator Normal, com passo de tempo de 30 minutos e uma malha computacional composta por 145 pontos na direção meridional (Y) e 240 pontos na direção zonal (X). A parametrização da convecção cúmulus foi realizada por meio do esquema de *Tiedtke* (Tiedtke, 1993) sobre as áreas continentais e do esquema de Kain-Fritsch (Kain-Fritsch, 1990; Kain, 2004) sobre as áreas oceânicas. Para os processos convectivos de sub-grade foi utilizado o esquema de umidade explícita (SUBEX; Pal et al., 2000), enquanto a representação da camada limite atmosférica baseou-se no esquema de *Holtzlag* (Holtzlag, 1990).

O domínio das simulações abrange parte da América do Sul e do oceano Atlântico Sul, cobrindo integralmente a ALB, conforme ilustrado na Figura 2.

Figura 2. Domínio e topografia (m) utilizada nas simulações climáticas do REG com resolução horizontal de 25 km. A linha sólida vermelha representa a área da ALB.



Fonte: Silva et al (2025).

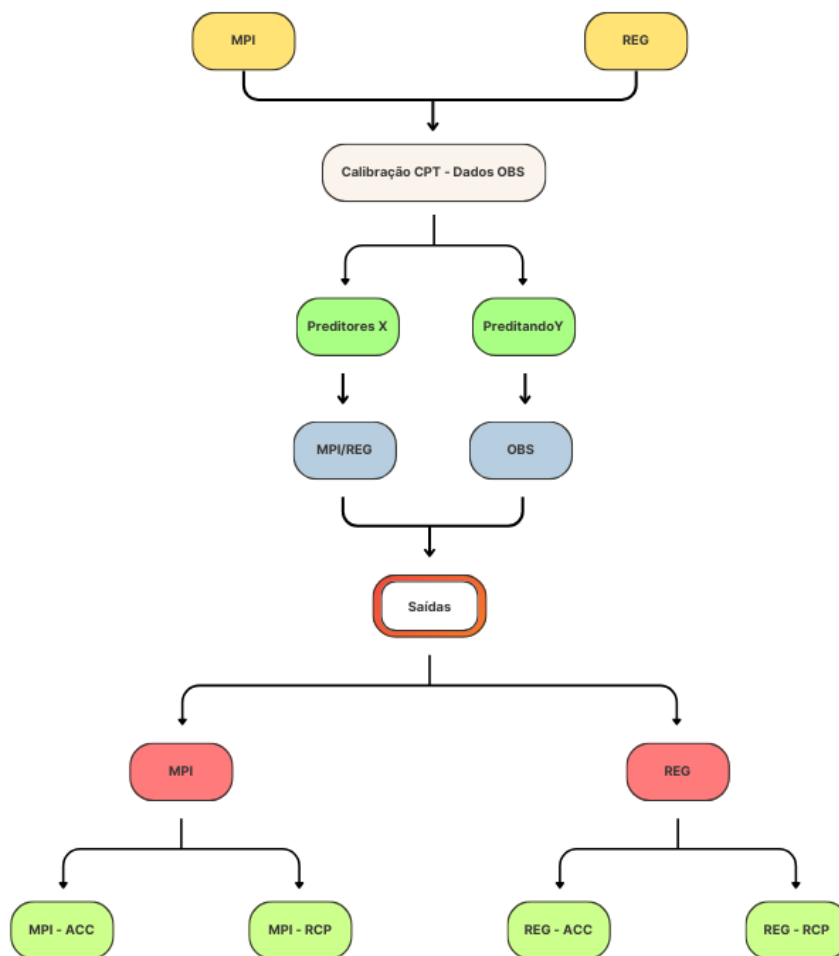
4.3.2 Delineamento dos Experimentos

O delineamento metodológico dos experimentos adotados neste estudo é apresentado de forma esquemática no fluxograma a seguir (figura 3). Inicialmente, foram consideradas as simulações climáticas provenientes do modelo global MPI e do modelo regional REG, bem como os dados observacionais do Xavier utilizados como referência. Essas informações serviram de base para o processo de calibração no Climate Predictability Tool (CPT), no qual se estabeleceram as relações estatísticas entre os campos preditores (X), oriundos dos modelos, e os campos preeditandos (Y), representados pelos dados observados.

A partir dessa calibração, foram aplicadas as técnicas estatísticas multivariadas de ACC e RCP, gerando diferentes experimentos de correção de viés para as simulações do MPI e do REG. Como resultado desse procedimento, obtiveram-se quatro conjuntos corrigidos: MPI-ACC, MPI-RCP, REG-ACC e REG-RCP. O fluxograma sintetiza essa metodologia, apresentando de forma objetiva as etapas seguidas desde os dados de entrada até a obtenção das saídas finais utilizadas nas análises.

Figura 3. Fluxograma do delineamento metodológico dos experimentos realizados.

Delineamento dos Experimentos



Fonte: Autor (2025).

Foram realizadas simulações para o período histórico de 1981 a 2012. Seis experimentos foram configurados para avaliar o desempenho das simulações de temperatura e a eficácia dos métodos de correção de viés:

- MPI: Análise das saídas brutas do modelo global MPI.
- REG: Análise das saídas regionalizadas pelo REG.
- MPI-ACC e REG-ACC: Aplicação do método de correção de viés por ACC às saídas do MPI e do REG, respectivamente.
- MPI-RCP e REG-RCP: Aplicação do método de correção de viés por RCP às saídas do MPI e do REG, respectivamente.

4.4 Métodos de Correção de Viés

Para aprimorar a precisão das projeções de temperatura e reduzir os desvios sistemáticos das simulações dos modelos MPI e REG, foram empregados dois métodos estatísticos multivariados: a ACC e a RCP.

4.4.1 Análise de Correlação Canônica (ACC)

A ACC, ou *Canonical Correlation Analysis* (CCA), é uma técnica estatística multivariada, introduzida por Hotelling (1936), que explora a inter-relação entre dois conjuntos distintos de variáveis. Sua principal finalidade é identificar e quantificar as associações lineares entre um conjunto de preditores e um de preditandos, encontrando pares de combinações lineares, um de cada conjunto, que sejam maximamente correlacionados. Essas combinações são conhecidas como variáveis canônicas, e suas respectivas correlações, como correlações canônicas (Zhuang et al., 2020).

O mecanismo do método considera um conjunto de variáveis predictoras (X), como as saídas do modelo climático (temperatura, pressão, umidade), e um conjunto de variáveis preditandas (Y), como os dados observados de temperatura. A ACC deriva então pares de vetores de peso (a e b) que criam as variáveis canônicas ($U = a'X$ e $V = b'Y$). O primeiro par de vetores de peso é otimizado para que a correlação entre a primeira variável canônica dos preditores (U_1) e a dos preditandos (V_1) seja a maior possível, estabelecendo o modo de covariabilidade mais dominante. Subsequentemente, outros pares de variáveis canônicas são calculados, com a restrição de que cada novo modo deve ser ortogonal (não correlacionado) a todos os anteriores, resultando em um conjunto de modos que descrevem as relações acopladas dominantes entre os campos do modelo e os campos observados (Yang et al., 2021).

No contexto deste trabalho, a ACC foi utilizada como um método de *downscaling* estatístico e correção de viés. Durante o período histórico de 1981 a 2012, o modelo é "treinado" para estabelecer as relações estatísticas estáveis entre os preditores (saídas do modelo MPI ou REG) e os preditandos (dados observados de temperatura na ALB). Uma vez que esses modos canônicos são estabelecidos, o modelo estatístico construído pela ACC foi aplicado às projeções futuras do modelo climático para gerar séries de temperatura corrigidas.

4.4.2 Regressão por Componentes Principais (RCP)

A RCP, ou *Principal Component Regression* (PCR), é uma técnica estatística empregada para construir um modelo de regressão estável e robusto, especialmente em cenários onde as variáveis preditoras são altamente correlacionadas entre si, um problema conhecido como multicolinearidade, comum em dados climáticos. O método opera através de um processo de duas etapas sequenciais que combina a ACP com a RLM (Agarwal et al., 2021).

Primeiramente, a ACP é aplicada exclusivamente ao conjunto de variáveis preditoras, que neste caso correspondem às saídas do modelo climático. Esta análise decompõe a matriz de preditores em um novo conjunto de variáveis chamadas Componentes Principais (CPs). Essas CPs possuem duas propriedades fundamentais: são ortogonais entre si, o que significa que não possuem correlação linear, e são ordenados hierarquicamente pela quantidade de variância dos dados originais que elas explicam. A primeira componente (CP1) captura a maior variabilidade possível, a CP2 a segunda maior, e assim sucessivamente. Para reduzir a dimensionalidade do problema e filtrar ruídos, apenas as primeiras CPs que explicam uma fração significativa da variância total (e.g., 90%) são retidas (Green & Romanov, 2025).

A segunda etapa consiste em ajustar um modelo de RLM. Neste modelo, as Componentes Principais selecionadas atuam como as novas variáveis preditoras, enquanto a variável resposta é a observação que se deseja prever, ou seja, os dados de temperatura observada. Como as CPs são, por construção, não correlacionados, o problema da multicolinearidade é efetivamente eliminado, resultando em estimativas de coeficientes de regressão mais estáveis e confiáveis (Wu et al., 2021).

4.5 O software *Climate Predictability Tool* (CPT)

Para operacionalizar a correção de viés de forma sistemática e robusta, foi utilizado o software CPT. Desenvolvido pelo *International Research Institute for Climate and Society* (IRI) da Universidade de Columbia, o CPT é uma ferramenta desenhada para facilitar a calibração, o *downscaling* estatístico e a validação de previsões climáticas. Sua escolha para este trabalho se justifica por sua capacidade de integrar em um único ambiente todo o fluxo de análise, desde o processamento dos dados até a avaliação de desempenho, aplicando de forma rigorosa métodos multivariados como a ACC e a RCP.

O processo metodológico dentro da ferramenta iniciou-se com a preparação e o carregamento dos conjuntos de dados. Foram definidos dois arquivos de entrada principais: o arquivo de preditores (X), contendo as saídas dos modelos climáticos MPI ou REG), e o arquivo de preditandos (Y), correspondente à base de dados observacional de temperatura em grade ($0,5^{\circ} \times 0,5^{\circ}$) para a ALB. Uma vez carregados, foi definido o período histórico de 1981 a 2012 como a janela temporal para o treinamento do modelo estatístico, momento em que o CPT aprende as relações entre as variáveis do modelo e as observações. Para garantir a robustez e evitar uma superestimação do desempenho, foi configurado um esquema de validação cruzada (*cross-validation*), no qual o modelo é treinado e testado em subconjuntos independentes dos dados (Silva et al., 2025).

A etapa central consistiu na construção do modelo estatístico, selecionando-se na interface do *software* o método desejado, seja a ACC ou a RCP. Um parâmetro crucial nesta fase foi a definição do número de modos (modos canônicos para a ACC ou componentes principais para a RCP) a serem retidos, uma decisão fundamental para capturar o sinal climático relevante e evitar o sobreajuste (*overfitting*) ao ruído. Com o modelo estatístico treinado e validado (por meio de uma validação cruzada), o CPT aplicou a toda a série temporal dos preditores (as saídas do modelo climático bruto), gerando como produto final uma nova série temporal de temperatura, agora estatisticamente corrigida para melhor representar as características dos dados observados.

Por fim, a avaliação da eficácia do processo foi realizada de forma integrada pela própria ferramenta. Utilizando os resultados da validação cruzada, o CPT calculou, para cada ponto da grade, as métricas de desempenho definidas para este estudo, a correlação de Pearson (r), o erro médio absoluto (MAE) e a raiz do erro quadrático médio (RMSE).

4.6 Teste de Desempenho do Método

Neste estudo foi utilizado alguns métodos estatísticos descritos por Hofstra et al., (2008) e Xavier et al., (2016) para comparar os dados dos modelos *versus* as observações, assim como o desempenho dos modelos após a calibração com ACC e RCP. Sejam eles:

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n \sqrt{(X_i - \bar{X})^2 (Y_i - \bar{Y})^2}} \quad (1);$$

$$bias = \bar{Y} - \bar{X} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i| \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (4);$$

Onde \bar{X} e \bar{Y} são valores médios e X e Y são valores observados e estimados respectivamente, e n é o número de observações analisadas. R é a coeficiente de correlação; $RMSE$ é a raiz do erro quadrático médio; MAE é o erro médio absoluto e $bias$ é a diferença entre as médias estimadas e observadas respectivamente. Em outras palavras, $RMSE$ e MAE medem o desvio (sendo $RMSE$ mais suscetível às diferenças) e $bias$ indica se o modelo subestima ou superestima os valores observados (Xavier et al., 2022).

Adicionalmente às métricas tradicionais, foi utilizado o Coeficiente de Eficiência de Kling-Gupta (KGE) como métrica integrada de avaliação do desempenho das simulações climáticas. O KGE foi proposto por Gupta et al. (2009) com o objetivo de fornecer uma avaliação mais robusta da similaridade entre séries simuladas e observadas, ao combinar simultaneamente informações de correlação linear, viés médio e variabilidade relativa.

O coeficiente é definido como:

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (5)$$

onde r representa o coeficiente de correlação de Pearson entre as séries simuladas e observadas, β é a razão entre as médias (indicando viés sistemático) e α é a razão entre os desvios padrão (representando a variabilidade relativa). Valores de KGE próximos de 1 indicam excelente desempenho do modelo, enquanto valores negativos indicam desempenho insatisfatório.

A utilização do KGE permite uma avaliação consolidada e integrada do desempenho dos modelos MPI e REG, antes e após a aplicação dos métodos de correção de viés, sendo particularmente adequada para comparar diferentes abordagens de regionalização e calibração estatística em estudos climáticos.

4.7 Análise de Cluster e Diagrama de Taylor

Com o objetivo de identificar padrões espaciais homogêneos do comportamento térmico e sintetizar o desempenho dos modelos climáticos sobre a ALB, foram aplicadas a análise de cluster e a técnica do Diagrama de Taylor. A utilização combinada dessas ferramentas permite reduzir a complexidade associada à elevada variabilidade espacial da região de estudo, além de possibilitar uma avaliação integrada da similaridade entre as simulações numéricas e os dados observacionais (Izzaddin et al., 2024).

A análise de cluster foi conduzida com base na similaridade entre as séries temporais de temperatura máxima e mínima, permitindo o agrupamento de áreas da ALB com comportamento térmico semelhante. A medida de dissimilaridade entre os elementos foi obtida por meio da distância euclidiana, amplamente utilizada em estudos climatológicos, expressa pela Equação (6):

$$d_e = [\sum_{j=1}^n (P_{p,j} - P_{k,j})^2]^{0,5} \quad (6)$$

em que d_e representa a distância euclidiana entre duas estações ou pontos amostrais p e k ; P_{pj} e P_{kj} correspondem aos valores da j -ésima variável (neste estudo, temperatura máxima ou mínima) associados a cada elemento, e n denota o número total de variáveis consideradas. Valores menores de d_e indicam maior similaridade entre os elementos analisados.

Para o processo de aglomeração, foi adotado o método hierárquico de Ward, o qual busca minimizar a variabilidade interna dos grupos formados, unindo aqueles cuja fusão resulta no menor incremento da soma dos quadrados intra-grupo. A função de ligação do método de Ward é definida pela soma dos quadrados das distâncias entre cada elemento e o centroide do respectivo grupo (Amhimmid et al., 2025), conforme apresentado na Equação (7):

$$W = \sum_{g=1}^G \sum_{i=1}^{n_g} \|x_i - \bar{x}_g\|^2 = \sum_{g=1}^G \sum_{i=1}^{n_g} \sum_{k=1}^K (X_{i,k} - \bar{X}_{g,k})^2 \quad (7)$$

em que W representa a função de Ward, associada à soma dos quadrados intra-grupo, G é o número total de grupos formados em cada etapa do processo de clusterização, n_g corresponde ao número de elementos pertencentes ao grupo g , x_{ik} é o valor da k -ésima variável do i -ésimo elemento do grupo, e $\bar{x}_{g,k}$ denota o valor médio (centroide) da variável k no grupo g . Esse critério assegura a formação de grupos climaticamente homogêneos e estatisticamente consistentes.

Os *clusters* obtidos foram posteriormente utilizados como unidades espaciais de análise, permitindo uma interpretação mais robusta dos resultados ao reduzir a influência de variabilidades locais pontuais e facilitar a comparação entre os diferentes conjuntos de simulações climáticas.

Para cada grupo climático definido pela análise de cluster, o desempenho das simulações foi avaliado por meio do Diagrama de Taylor. Essa ferramenta gráfica sintetiza, em um único plano, informações relativas ao coeficiente de correlação linear, ao desvio padrão e ao erro quadrático médio centrado entre as séries simuladas e observadas, possibilitando uma comparação direta entre os diferentes experimentos analisados (MPI, REG, MPI-ACC, REG-ACC, MPI-RCP e REG-RCP).

A relação entre o erro quadrático médio centrado (SDE^2), o desvio padrão das simulações (σ_s), o desvio padrão das observações (σ_x) e o coeficiente de correlação linear (r) (Iacobucci et al., 2015), é dada pela Equação (8):

$$SDE^2 = \sigma_s^2 + \sigma_x^2 - 2\sigma_s\sigma_x r \quad (8)$$

A aplicação conjunta da análise de cluster e do Diagrama de Taylor possibilita avaliar não apenas o desempenho médio dos modelos climáticos sobre a ALB, mas também sua capacidade de representar adequadamente diferentes regimes térmicos regionais, fornecendo uma visão mais abrangente e regionalmente consistente da qualidade das simulações.

4.8 Análise de Extremos Climáticos

A avaliação da capacidade dos modelos climáticos em representar eventos extremos foi realizada por meio da análise de índices padronizados de extremos climáticos, conforme as recomendações *do Expert Team on Climate Change Detection and Indices* (ETCCDI). Essa abordagem permite investigar alterações na frequência, intensidade e persistência de extremos térmicos, complementando a análise baseada na climatologia média da temperatura máxima e mínima (Kim et al., 2020).

Os índices de extremos associados à temperatura foram calculados utilizando o *software R*, por meio do pacote *Climdex*. No presente estudo, foram utilizados os seguintes índices na tabela 2 a seguir:

Tabela 2: Índices climáticos derivados de dados diários de temperaturas máximas e mínimas, com definições e unidades.

Índice	Nome	Descrição
SU25	Dias de verão	Número anual de dias em que a temperatura máxima diária (TX) excede 25 °C.
TR20	Noites tropicais	Número anual de dias em que a temperatura mínima diária (TN) é superior a 20 °C.
TXx	Máxima das temperaturas máximas	Maior valor anual da temperatura máxima diária.
TXn	Mínima das temperaturas máximas	Menor valor anual da temperatura máxima diária.
TNx	Máxima das temperaturas mínimas	Maior valor anual da temperatura mínima diária.
TNn	Mínima das temperaturas mínimas	Menor valor anual da temperatura mínima diária.
TX10p	Dias frios (TX)	Percentual de dias em que a temperatura máxima diária é inferior ao percentil 10 da climatologia de referência.
TX90p	Dias quentes (TX)	Percentual de dias em que a temperatura máxima diária é superior ao percentil 90 da climatologia de referência.
TN10p	Noites frias (TN)	Percentual de dias em que a temperatura mínima diária é inferior ao percentil 10 da climatologia de referência.
TN90p	Noites quentes (TN)	Percentual de dias em que a temperatura mínima diária é superior ao percentil 90 da climatologia de referência.

WSDI	Índice de duração de ondas de calor	Número de dias pertencentes a períodos com pelo menos seis dias consecutivos em que TX excede o percentil 90.
CSDI	Índice de duração de períodos frios	Número de dias pertencentes a períodos com pelo menos seis dias consecutivos em que TN é inferior ao percentil 10.
DTR	Amplitude térmica diária	Diferença média entre a temperatura máxima e mínima diárias (TX - TN).

Os índices foram calculados para os dados observados e para as simulações com melhor desempenho após as correções, permitindo avaliar o impacto da regionalização dinâmica e dos métodos de correção de viés na representação dos extremos térmicos sobre a ALB.

5. RESULTADOS

A análise foi conduzida de forma comparativa entre as diferentes configurações dos modelos, considerando inicialmente as saídas brutas do MPI e do REG e, posteriormente, as simulações corrigidas pelos métodos ACC e RCP. Dessa forma, buscou-se identificar e quantificar os vieses sistemáticos presentes nas simulações mensais de temperatura máxima e mínima, avaliar os ganhos proporcionados pela regionalização dinâmica (REG) e verificar a eficácia das técnicas de correção de viés na redução dos erros e na melhoria da representação espacial e temporal das simulações.

Os resultados são apresentados com foco na variabilidade mensal, uma vez que o ciclo anual da temperatura na ALB reflete a atuação combinada de processos locais e de grande escala, incluindo o balanço de energia à superfície, a sazonalidade da radiação solar, a evapotranspiração da floresta e a influência de sistemas atmosféricos de grande escala, como o SAMS e a ZCIT (Marengo et al., 2017; Carvalho et al., 2020). A análise mensal permitiu capturar, com maior detalhe, as transições ao longo do ano e avaliar de forma mais precisa a capacidade dos modelos em reproduzir os padrões observados.

5.1 Climatologia Observada/MPI/REG – Temperatura Mínima

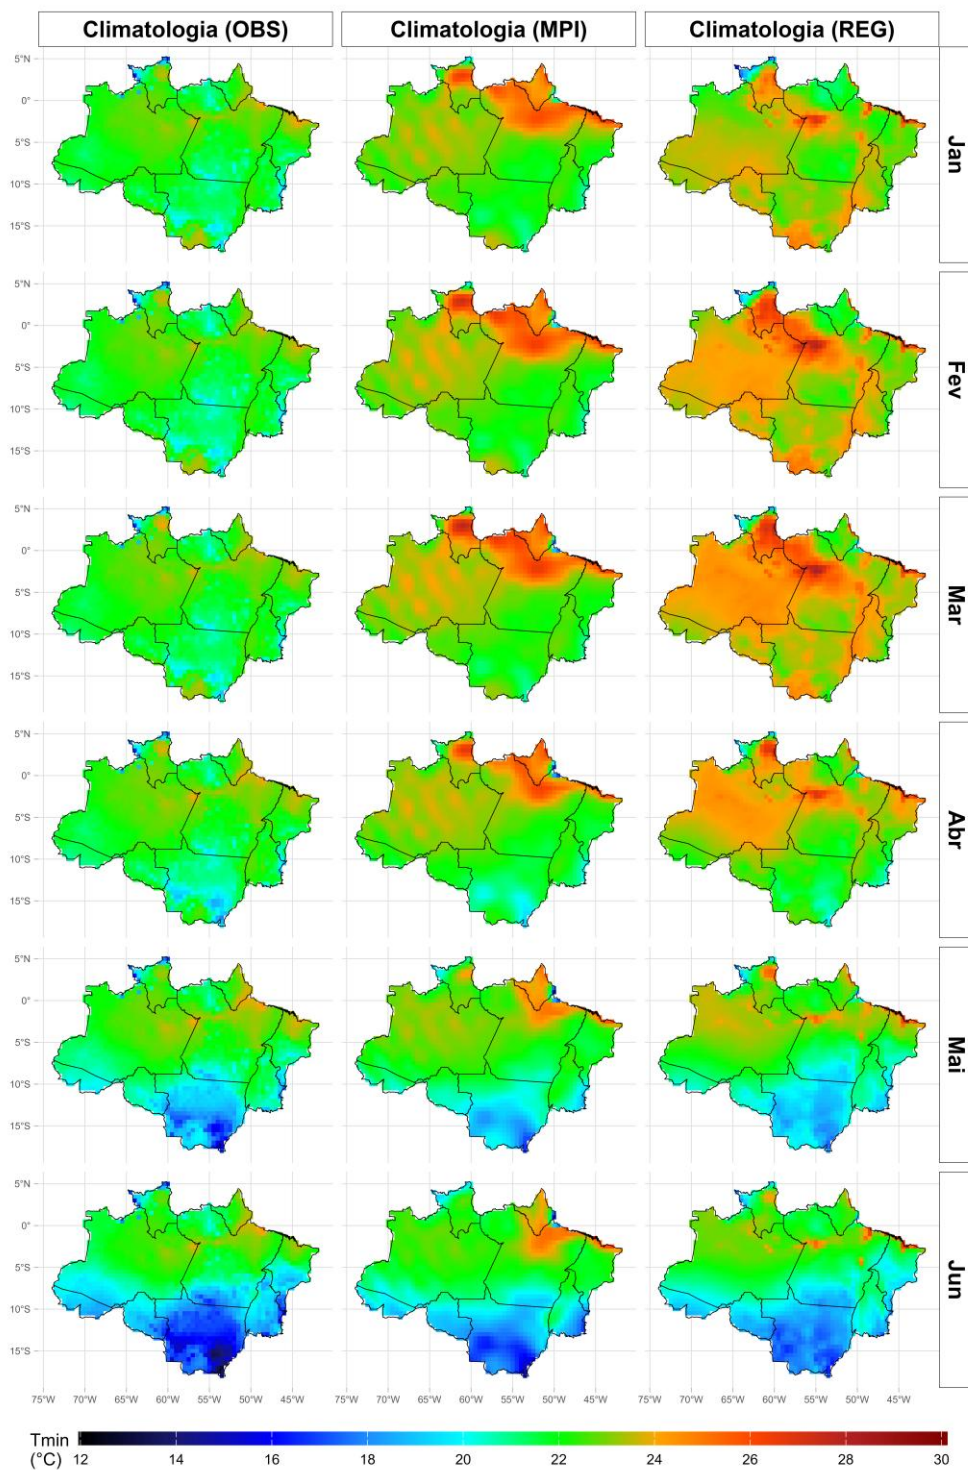
No primeiro semestre do ano (figura 4), correspondente aos meses de janeiro a junho, a climatologia observada da temperatura mínima (OBS) sobre a ALB apresenta valores relativamente elevados, em relação aos meses subsequentes, e espacialmente homogêneos, especialmente entre janeiro e abril. Esse comportamento está associado à elevada disponibilidade de umidade na atmosfera e no solo, à intensa atividade convectiva e à forte atuação da reciclagem de umidade promovida pela floresta amazônica, fatores que reduzem o resfriamento radiativo noturno e mantêm as temperaturas mínimas em patamares mais altos (Levine et al., 2019).

Nesse período, os dados observados mostraram uma diminuição da temperatura mínima a partir de maio, sobretudo nas regiões mais ao sul da ALB, sinalizando a transição para o inverno. Essa redução pode estar relacionada ao enfraquecimento gradual da convecção profunda e ao aumento da eficiência do resfriamento noturno, ainda que a região permaneça sob condições predominantemente úmidas (Espinoza et al., 2018).

As simulações do modelo global MPI reproduziram, de forma geral, o padrão sazonal do primeiro semestre, porém apresentaram uma tendência sistemática de superestimação da temperatura mínima, especialmente nas regiões norte e nordeste da ALB. Essa superestimação foi mais evidente nos meses de verão (janeiro a março), sugerindo limitações do modelo global em representar adequadamente o balanço de energia à superfície e os processos de resfriamento noturno em ambientes tropicais florestados, particularmente sob condições de elevada umidade (Herdies et al., 2023; Reboita et al., 2024).

Em contraste, as simulações regionalizadas pelo REG apresentaram, no primeiro semestre, um desempenho inferior ao do modelo global, com superestimações mais pronunciadas da temperatura mínima e padrões espaciais menos consistentes com as observações em diversas áreas da ALB. Esse comportamento pode indicar que, sob condições de elevada umidade, forte convecção e acoplamento intenso entre a superfície e a atmosfera, o refinamento da resolução espacial nem sempre resulta em melhorias na simulação da temperatura mínima. Esse resultado pode estar associado a limitações nas parametrizações físicas do modelo regional, especialmente aquelas relacionadas à camada limite atmosférica, à representação da nebulosidade e aos fluxos turbulentos noturnos. Em ambientes tropicais úmidos, pequenas incertezas nesses processos podem amplificar erros no balanço de energia à superfície, levando a uma redução excessiva do resfriamento noturno e, conseqüentemente, a uma superestimação da temperatura mínima (Xie et al., 2018; Kähnert et al., 2022). Estudos anteriores já indicaram que modelos regionais podem apresentar desempenho inferior ao de modelos globais em determinadas condições climáticas, particularmente durante períodos dominados por processos convectivos de grande escala e elevada cobertura de nuvens (Ban et al., 2020; Lucas-Picher et al., 2021).

Figura 4. Climatologia mensal da temperatura mínima do ar (°C) sobre a ALB, referente aos meses de janeiro a junho, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.



Fonte: Autor (2025)

No segundo semestre (figura 5), a climatologia observada da temperatura mínima apresentou maior variabilidade espacial e temporal, com valores mais baixos concentrados principalmente no sul da ALB durante os meses de inverno austral. Esse comportamento está associado à redução da nebulosidade, à menor umidade atmosférica


e à maior frequência de incursões de ar frio provenientes de latitudes médias, conhecidas como friagens amazônicas (Marengo et al., 1997; Camarinha-Neto et al., 2021).

Nesse período, as limitações do modelo global MPI tornaram-se mais evidentes. O modelo apresentou dificuldade em reproduzir os valores mais baixos de temperatura mínima observados no sul da ALB, subestimando a intensidade das friagens e suavizando os gradientes térmicos regionais, enquanto manteve a superestimação dos valores no norte da ALB. Essa deficiência está relacionada à resolução espacial grosseira do modelo global, que limita a representação de processos de mesoescala e da interação entre circulação atmosférica e superfície durante eventos de resfriamento intenso (Silva et al., 2014; Silva et al., 2022).

Por outro lado, o REG demonstrou melhor desempenho no segundo semestre, com uma representação mais realista dos gradientes espaciais da temperatura mínima e maior sensibilidade às áreas de menor temperatura mínima no sul e sudoeste da ALB. O modelo regional conseguiu capturar, de forma mais adequada, os efeitos das friagens e das transições sazonais, evidenciando a importância do *downscaling* dinâmico em períodos caracterizados por maior variabilidade térmica e maior influência de processos locais e regionais (Gibson et al., 2024).

Apesar dessas melhorias, o REG ainda apresentou vieses residuais, com superestimações pontuais da temperatura mínima em algumas regiões, especialmente no norte da ALB durante a transição para o período chuvoso.

Figura 5. Climatologia mensal da temperatura mínima do ar (°C) sobre a ALB, referente aos meses de julho a dezembro, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.



Fonte: Autor (2025)

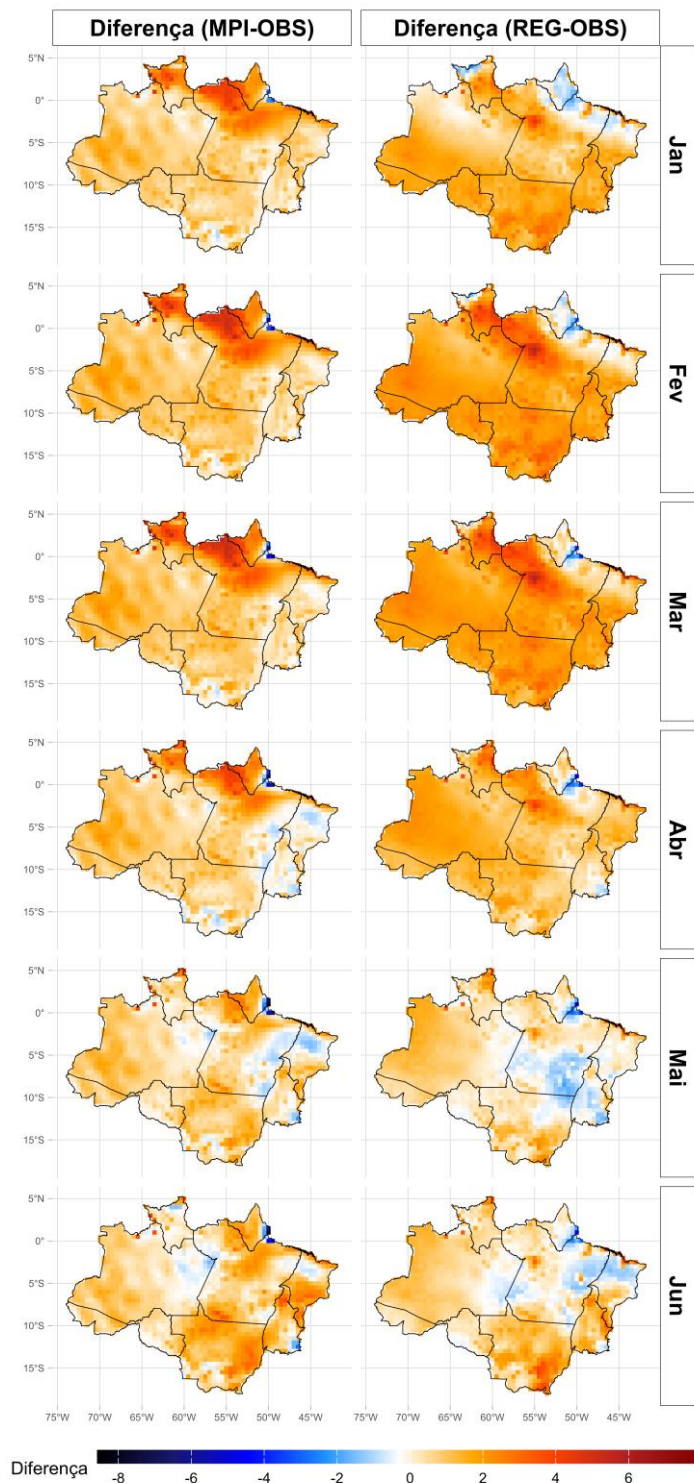
5.2 Viés da Temperatura Mínima

No primeiro semestre (Figura 6), observou-se que o MPI apresentou, de modo geral, viés positivo em grande parte da ALB, caracterizando uma superestimativa sistemática das temperaturas, quando comparado aos dados observacionais. Esse comportamento é mais evidente entre os meses de janeiro e abril, com valores positivos mais intensos concentrados, principalmente, nas porções central e sul da região, atingindo magnitudes superiores a +4 °C em áreas pontuais.

Durante os meses de maio e junho, embora o padrão de superestimativa permaneça dominante no MPI, notou-se uma redução gradual da intensidade do viés. Em contrapartida, surgiram regiões localizadas com viés negativo em setores do nordeste da região, indicando uma maior dificuldade do modelo global em representar adequadamente a variabilidade térmica mínima associada à transição entre a estação chuvosa e o período de menor nebulosidade.

O modelo REG, por sua vez, demonstrou um desempenho relativamente distinto no primeiro semestre. Embora que também apresente viés positivo predominante, a magnitude das diferenças foi maior, com os meses de maio e junho se assemelhando ao MPI espacialmente e em relação a intensidade.

Figura 6. Diferença mensal da temperatura mínima do ar (°C) entre os modelos climáticos (MPI e REG) e os dados observacionais na ALB, para o primeiro semestre (janeiro a junho).



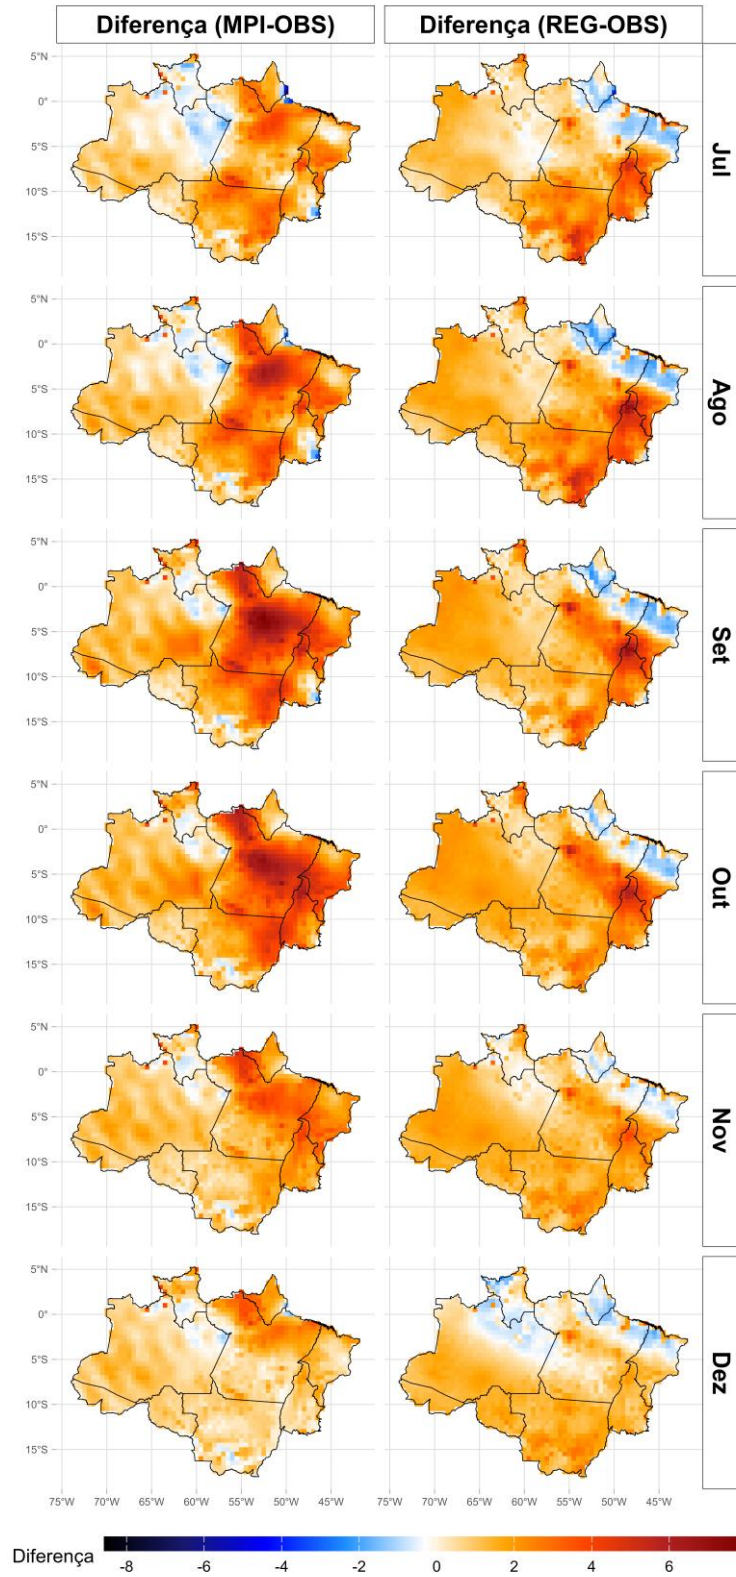
Fonte: Autor (2025).

No segundo semestre (Figura 7), o padrão de viés positivo da temperatura mínima tornou-se mais intenso e espacialmente consistente, sobretudo no modelo MPI. Entre julho e outubro, período associado à estação seca em grande parte da ALB, as diferenças positivas se ampliaram significativamente, com áreas extensas apresentando valores superiores a +4 °C, especialmente no centro, sul e leste da região.

Esse comportamento indica que o modelo global possui dificuldades acentuadas em representar os processos de resfriamento noturno durante períodos de menor nebulosidade e umidade atmosférica, condições típicas da estação seca. A redução da cobertura de nuvens favorece maior perda radiativa noturna nos dados observacionais, enquanto o MPI tende a manter temperaturas mínimas artificialmente elevadas, resultando em superestimativas sistemáticas (Howell et al., 2021).

O modelo regional REG apresentou um desempenho relativamente superior ao do MPI no segundo semestre. Embora ainda se observe viés positivo predominante, as diferenças foram, em média, menos intensas e mais heterogêneas, com áreas de viés próximo de zero ou até negativo, principalmente no norte e nordeste da ALB durante os meses de novembro e dezembro. Esse resultado sugere que a regionalização contribui para uma melhor representação dos gradientes espaciais e dos controles locais da temperatura mínima, como relevo, uso e cobertura da terra e circulação de mesoescala.

Figura 7. Diferença mensal da temperatura mínima do ar (°C) entre os modelos climáticos (MPI e REG) e os dados observacionais na ALB, para o segundo semestre (julho a dezembro).



Fonte: Autor (2025)

5.3 Correlação entre os Dados Observados e o Modelo MPI – Temperatura Mínima

Durante o primeiro semestre (Figura 8), as correlações apresentaram valores predominantemente baixos a moderados, com extensas áreas exibindo correlações fracas e, pontualmente, valores próximos de zero ou negativos, sobretudo no setor oeste da ALB, indicando, novamente, limitações do modelo global em reproduzir adequadamente a variabilidade espacial da temperatura mínima, no período que coincide com a estação mais chuvosa da região (Casimiro et al., 2012; Paca et al., 2020).

A aplicação da ACC ao MPI resultou em uma melhora substancial das correlações em todos os meses do primeiro semestre, com predominância de valores positivos moderados a altos (acima de 0,4) em grande parte da ALB. Esse ganho evidenciou a eficiência da ACC em capturar padrões espaciais dominantes e reduzir erros sistemáticos associados à média e à variabilidade do modelo, conforme já documentado em estudos de pós-processamento climático (Barnston & Tippett., 2017; Silva et al., 2025).

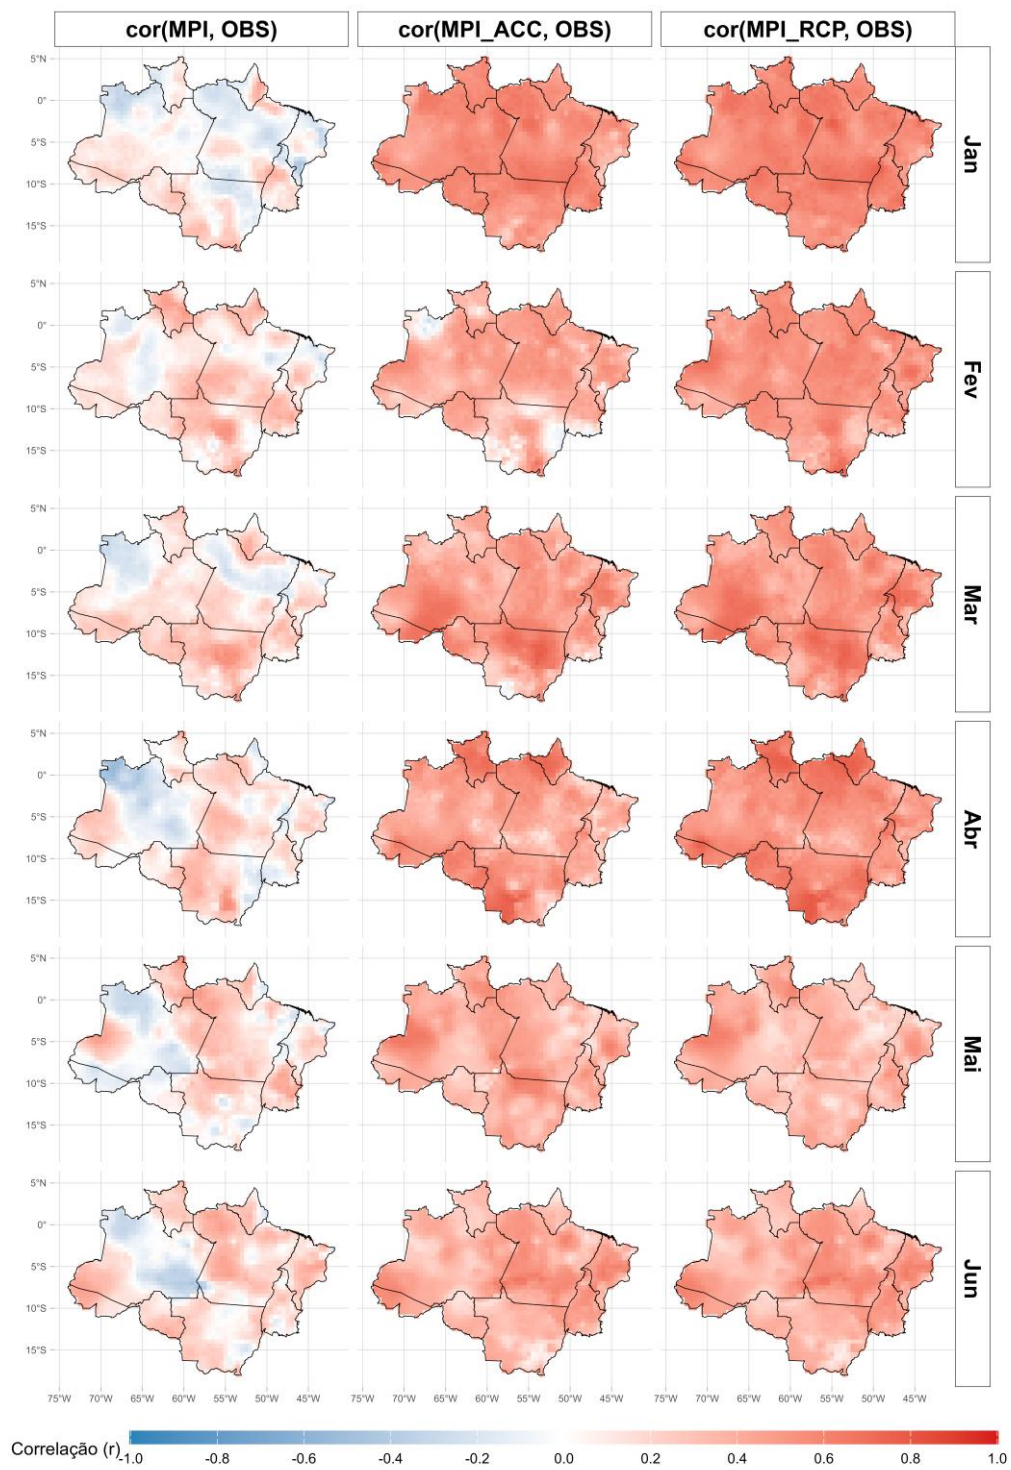
Resultados semelhantes foram observados com a aplicação da RCP, que também promoveu um aumento consistente das correlações em relação ao MPI bruto. Em vários meses, as regiões corrigidas por RCP apresentaram padrões espaciais mais homogêneos e correlações comparáveis ou superiores às obtidas com ACC. Isso sugere que a RCP é particularmente eficaz na representação da relação estatística entre preditores de grande escala e a temperatura mínima observada.

No segundo semestre (Figura 9), mesmo o MPI, sem correção, apresentou correlações mais elevadas e espacialmente consistentes, em comparação ao primeiro semestre. Esse comportamento está associado ao regime mais seco da Amazônia, quando a temperatura mínima passa a ser mais controlada por forçantes de grande escala e pela redução da nebulosidade noturna, favorecendo um melhor desempenho dos modelos globais (Baker et al., 2021). Ainda assim, persistem áreas com correlação apenas moderada, indicando limitações do modelo.

Com a aplicação da ACC e da RCP no segundo semestre, as correlações tornaram-se altas e espacialmente homogêneas em praticamente toda a ALB, frequentemente superando valores de 0,6-0,8. Esse resultado demonstrou que os métodos

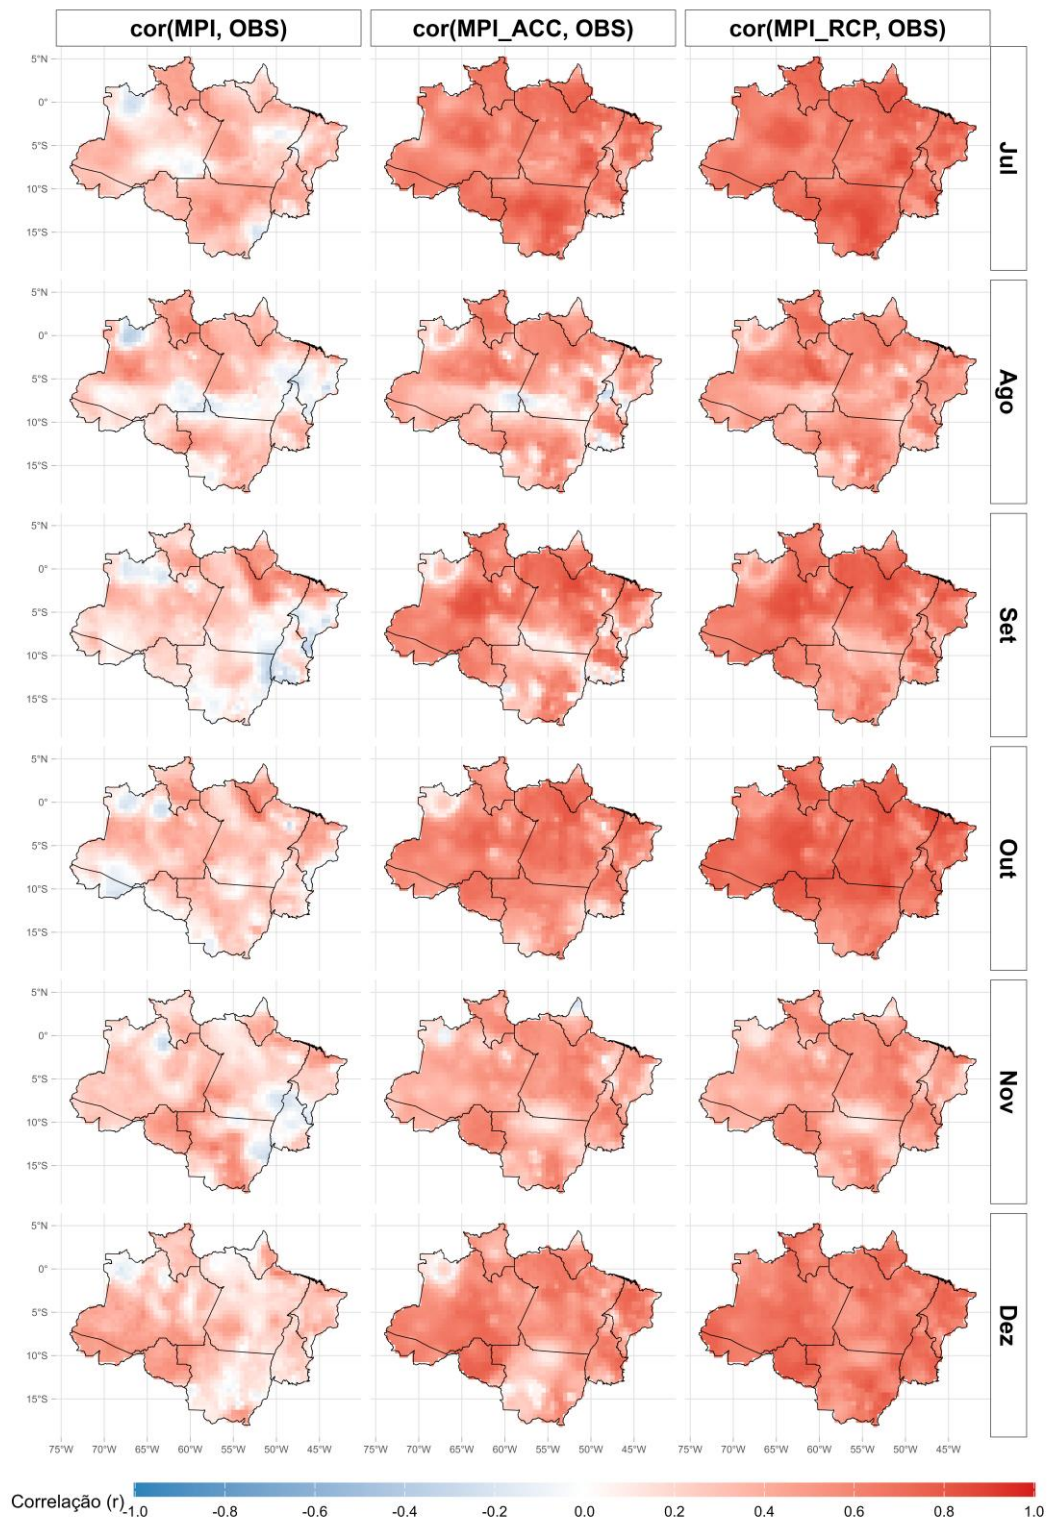
de correção de viés não apenas corrigem deficiências do modelo nos meses mais úmidos, mas também refinam a representação da variabilidade térmica nos meses secos, consolidando ganhos robustos ao longo de todo o ano.

Figura 8. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo MPI e os dados observados na ALB, para o primeiro semestre (janeiro a junho).



Fonte: Autor (2025).

Figura 9. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo MPI e os dados observados na ALB, para o segundo semestre (julho a dezembro).



Fonte: Autor (2025)

5.4 Correlação entre os Dados Observados e o Modelo REG – Temperatura Mínima

No primeiro semestre do ano (Figura 10), as correlações entre a temperatura mínima simulada pelo REG e os dados observados evidenciaram um desempenho espacialmente heterogêneo, quando consideradas as saídas brutas do modelo regional. Observou-se que, em grande parte da ALB, os coeficientes de correlação apresentaram valores predominantemente fracos a moderados, com extensas áreas exibindo correlações próximas de zero ou mesmo negativas.

Esses padrões indicaram dificuldades do REG em representar adequadamente a variabilidade temporal da temperatura mínima durante o período mais úmido do ano, quando a atuação da convecção profunda, da nebulosidade persistente e dos processos de reciclagem de umidade desempenham papel central no balanço de energia à superfície.

Com a aplicação da correção de viés por ACC (REG-ACC), verificou-se uma melhora substancial nos coeficientes de correlação ao longo de toda a região, com predominância de valores positivos moderados (0,4-0,6). Essa melhoria foi particularmente evidente nos meses de janeiro, março e junho, indicando que o método ACC é eficaz em ajustar a variabilidade temporal da Temperatura mínima.

Resultados semelhantes foram observados com a aplicação da RCP (REG-RCP), que também promove um aumento significativo das correlações espaciais. Em geral, o REG-RCP apresentou campos mais homogêneos e ligeiramente superiores aos do REG-ACC em alguns meses, sugerindo maior robustez do método na redução de ruídos associados aos erros sistemáticos do modelo regional.

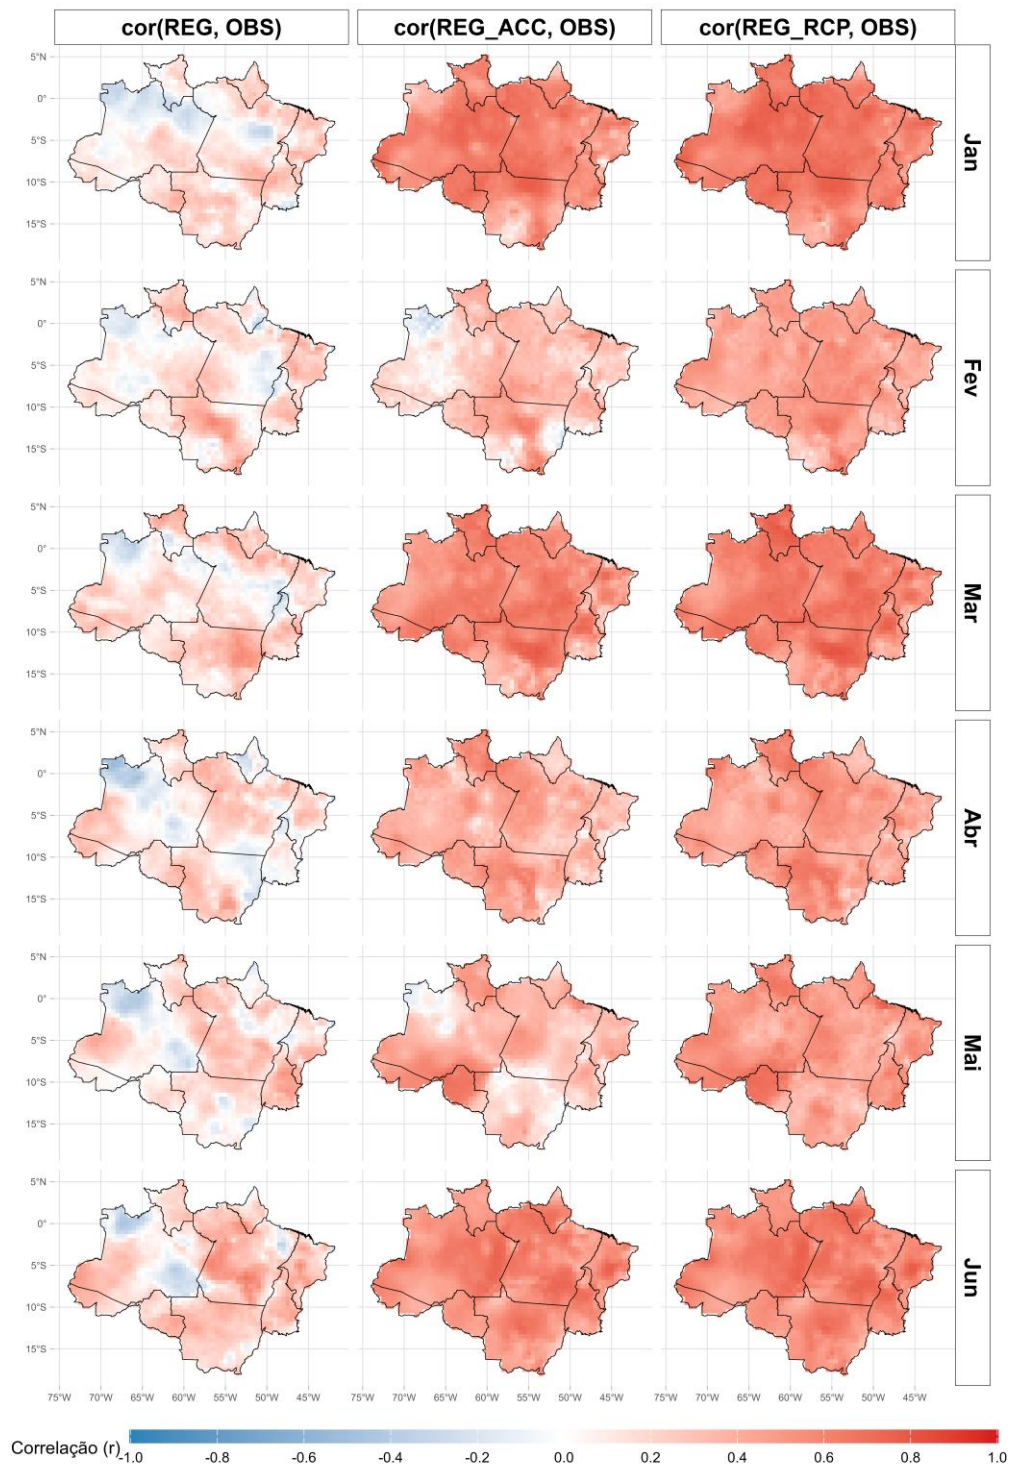
No segundo semestre (figura 11), observou-se, novamente, um comportamento distinto em relação ao primeiro semestre. As correlações entre a temperatura mínima simulada pelo REG e as observações apresentaram, de forma geral, valores mais elevados mesmo nas saídas brutas do modelo regional, especialmente entre julho e setembro, aumento associado à transição para o período mais seco da Amazônia.

Ainda assim, persistiram áreas com correlações fracas ou próximas de zero, principalmente nas porções oeste e central da ALB, indicando que o REG continuou apresentando limitações na representação da temperatura mínima em regiões de floresta densa e forte acoplamento biosfera-atmosfera. Tais limitações já foram discutidas na

literatura, que apontaram dificuldades dos modelos regionais em simular adequadamente o resfriamento noturno em áreas tropicais florestadas (Ge et al., 2021).

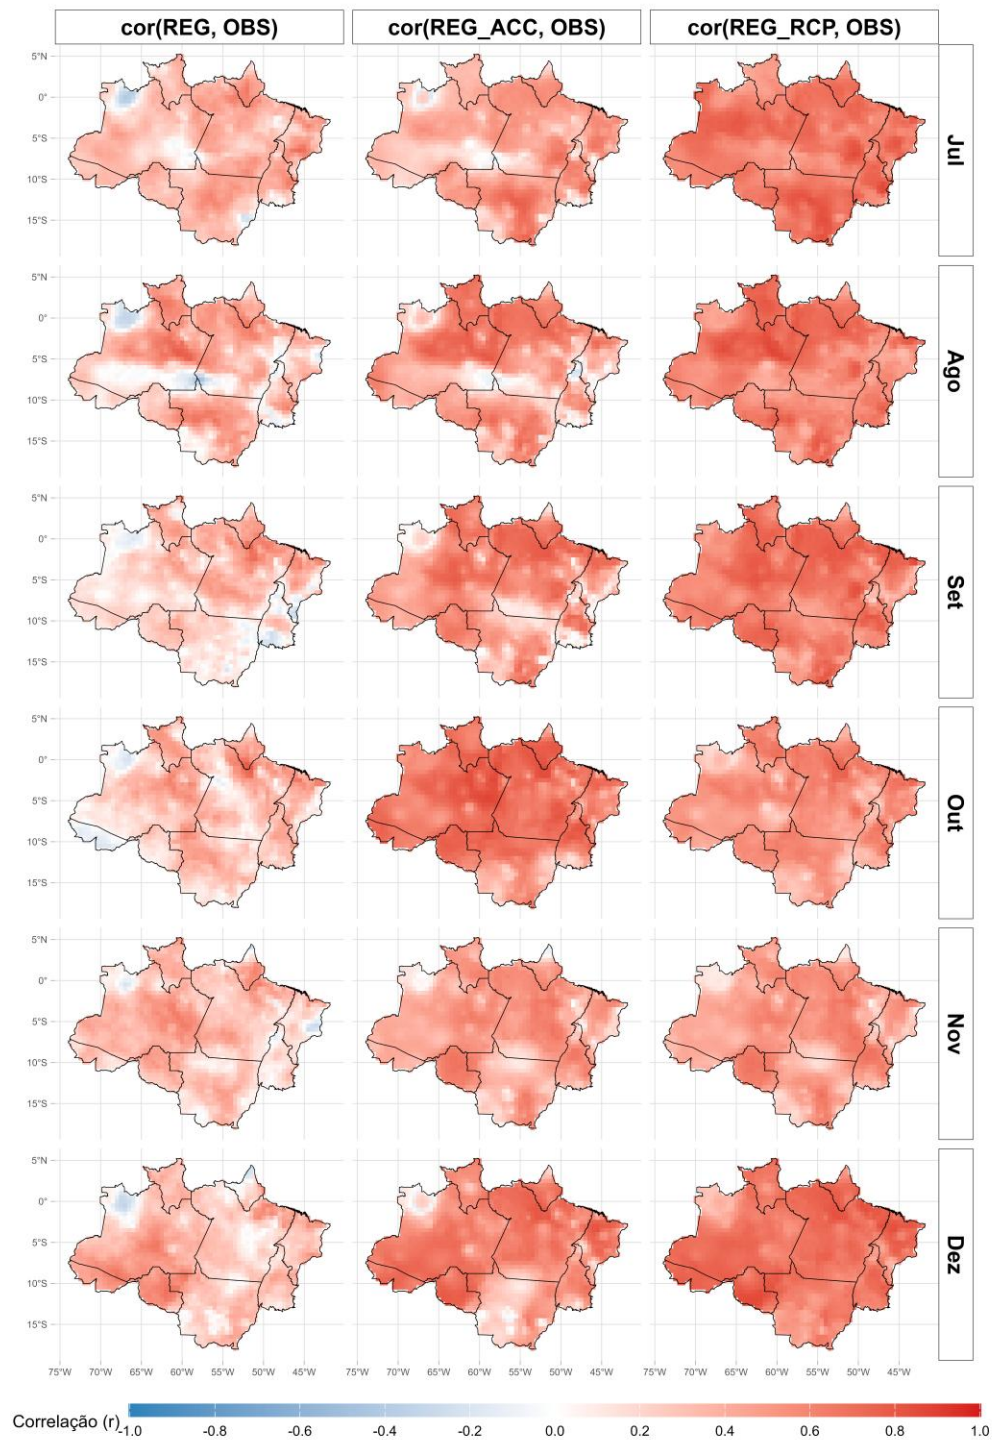
A aplicação das correções REG-ACC e REG-RCP no segundo semestre resultaram em melhorias ainda mais consistentes do que aquelas observadas no primeiro semestre. Os campos de correlação tornaram-se amplamente positivos, com valores frequentemente superiores a 0,6 em grande parte da região, especialmente entre agosto e outubro. Notou-se que o REG-RCP apresentou os melhores resultados, com padrões mais contínuos e menores contrastes espaciais, indicando uma correção mais eficiente da variabilidade temporal da Temperatura mínima.

Figura 10. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo REG e os dados observados na ALB, para o primeiro semestre (janeiro a junho).



Fonte: Autor (2025).

Figura 11. Distribuição espacial da correlação de Pearson (r) entre a temperatura mínima mensal simulada pelo modelo REG e os dados observados na ALB, para o segundo semestre (julho a dezembro).



Fonte: Autor (2025).

5.5 Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo MPI – Temperatura Mínima

No primeiro semestre (figura 12), o modelo MPI sem correção apresentou valores elevados de RMSE, especialmente sobre o norte e nordeste da ALB, com máximos recorrentes entre janeiro e março. Os erros atingiram valores superiores a 3 °C, indicando dificuldades do modelo global em representar adequadamente os processos noturnos de resfriamento da superfície, fortemente controlados pela nebulosidade, umidade do solo e estabilidade da camada limite atmosférica.

Durante os meses de abril a junho, observou-se uma leve redução dos erros, embora persistam núcleos de RMSE moderado nas regiões mais ao norte. Esse comportamento sugere que, mesmo durante a transição para a estação menos chuvosa, o MPI mantém limitações estruturais na simulação da temperatura mínima, sobretudo em áreas de floresta densa e elevada umidade.

A aplicação das técnicas de correção estatística (MPI-ACC e MPI-RCP) resultou em uma redução expressiva e espacialmente consistente do RMSE em toda a ALB, com exceção de março para o MPI-ACC, assim como foi no MAE. Os valores passaram a se concentrar majoritariamente abaixo de 2 °C, com campos muito mais homogêneos. Ambos os métodos apresentam desempenho semelhante, embora a RCP mostre ligeira vantagem, com menores resíduos residuais em áreas onde o MPI bruto apresentava maiores erros.

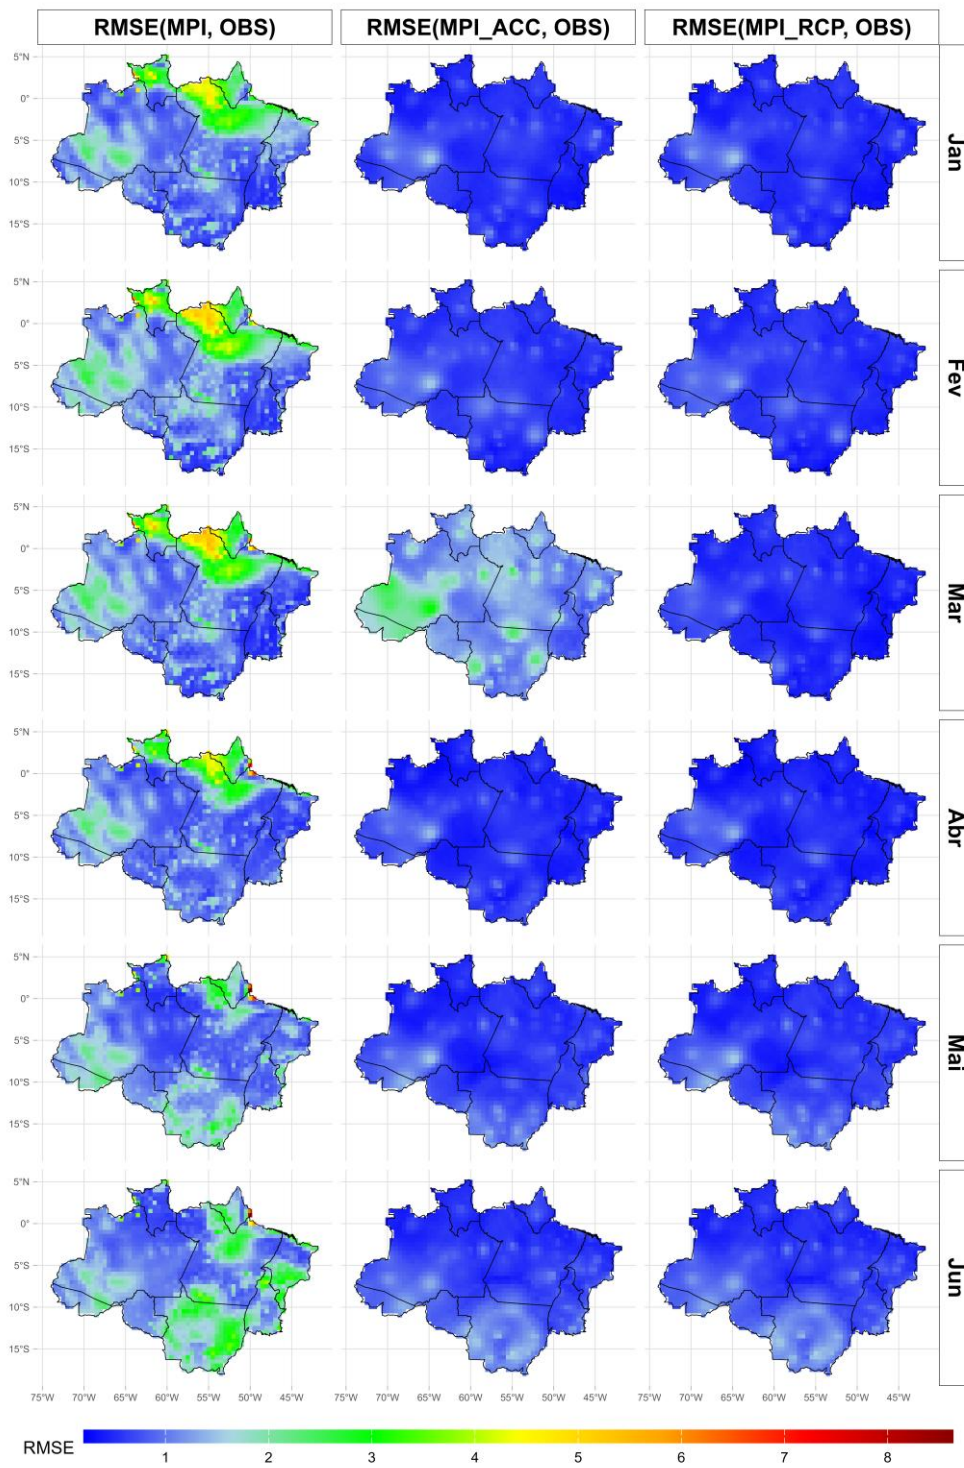
No segundo semestre (figura 13), o MPI bruto apresentou uma intensificação dos erros de RMSE, sobretudo entre agosto e outubro, período associado à estação seca e às transições sazonais na ALB. Nesses meses, os valores máximos de RMSE ultrapassaram 4-5 °C, principalmente no norte e nordeste da região, refletindo a dificuldade do modelo em representar o resfriamento noturno sob condições de céu mais limpo, menor umidade e maior amplitude térmica diária.

Mesmo nos meses finais do ano (novembro e dezembro), observou-se a persistência de erros moderados, indicando que o retorno gradual das chuvas não é suficiente para eliminar completamente os vieses do MPI na temperatura mínima. Por outro lado, as versões MPI-ACC e MPI-RCP mantiveram desempenho robusto ao longo de todo o segundo semestre, com RMSE consistentemente baixos e especialmente

homogêneos. A correção por RCP, em particular, apresentou os menores valores de erro, sugerindo maior capacidade de capturar os principais modos de variabilidade associados à temperatura mínima durante a estação seca.

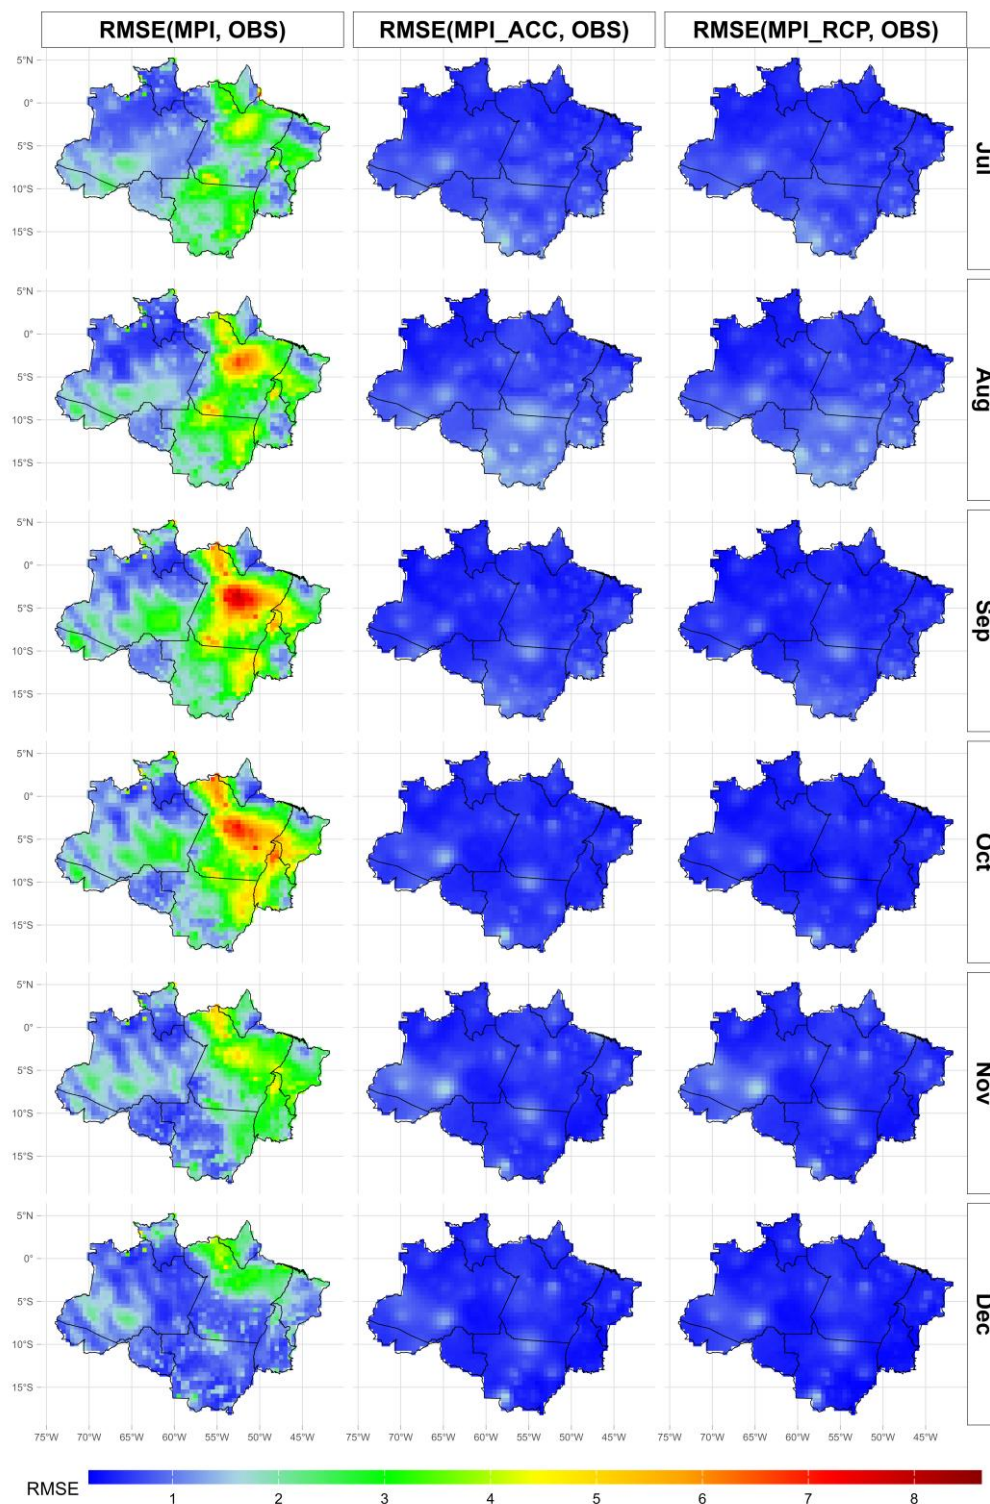
A mesma análise foi realizada utilizando o MAE, sendo encontrados resultados muito similares aos obtidos com o RMSE.

Figura 12. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo MPI no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 13. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo MPI no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.6 Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo REG – Temperatura Mínima

No primeiro semestre (figura 14), os mapas de RMSE da temperatura mínima para o modelo regional (REG), apresentados na comparação direta com as observações, evidenciaram erros moderados a elevados em grande parte do domínio, com valores mais expressivos concentrados principalmente na porção centro-norte e leste da área de estudo. Esses padrões indicaram dificuldades do modelo regional em representar, adequadamente, a variabilidade espacial da temperatura mínima durante os meses associados ao período chuvoso e de maior influência de processos convectivos e de nebulosidade persistente.

Observou-se que os maiores valores de RMSE ocorreram, sobretudo, entre fevereiro e abril, período em que a atuação da ZCIT e sistemas convectivos de mesoescala tendem a intensificar a cobertura de nuvens e a variabilidade térmica noturna.


Após a aplicação dos métodos de ACC e RCP, notou-se a diminuição do RMSE em toda a área de estudo, com ambos os métodos apresentando uma configuração semelhante, espacialmente falando, e eficaz.

No segundo semestre (figura 15), observou-se um deslocamento dos valores de RMSE na região estudada, na saída bruta do modelo regional em comparação ao primeiro semestre, particularmente nos meses de julho a setembro. Ainda assim, persistem áreas com erros relativamente mais elevados, sobretudo na porção leste e nordeste do domínio, onde a influência de brisas marítimas, nebulosidade costeira e gradientes térmicos associados à topografia costeira dificultam a representação precisa da temperatura mínima. Esses fatores contribuem para discrepâncias entre o modelo e as observações, principalmente nos meses de transição entre a estação seca e o início da estação chuvosa, como outubro e novembro (Jiang et al., 2024).

Após a aplicação das correções estatísticas (ACC e RCP), os mapas revelaram novamente uma redução expressiva do RMSE em toda a região. Os campos corrigidos apresentaram padrões espacialmente mais homogêneos e valores consistentemente baixos, indicando que os métodos são eficazes também no período seco e de transição sazonal.

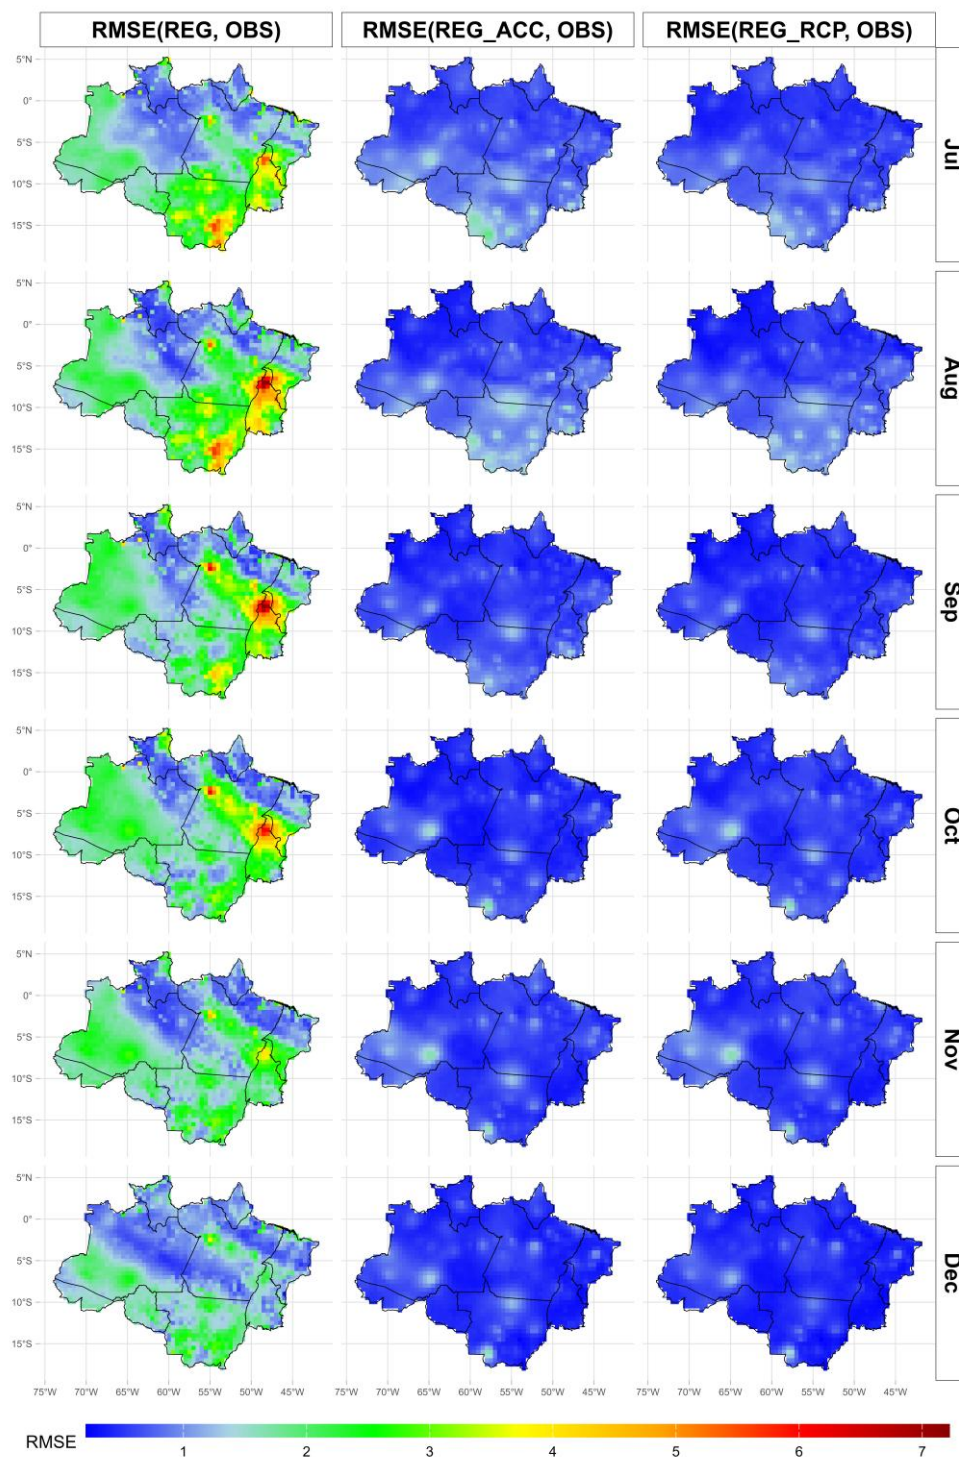
A análise também foi realizada utilizando o MAE, novamente, encontrando resultados semelhantes aos do RMSE.

Figura 14. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo REG no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 15. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura mínima para o modelo REG no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.7 Análise do Kling Gupta Efficiency (KGE) para o Modelo MPI – Temperatura Mínima

No primeiro semestre (figura 16), o desempenho do modelo global MPI, em sua forma bruta, é predominantemente classificado como intermediário a ruim em grande parte da área de estudo. Observou-se uma maior ocorrência das classes ruim e muito ruim, especialmente sobre setores do interior e porções centrais do domínio, indicando limitações do modelo em representar adequadamente tanto a variabilidade quanto a magnitude da temperatura mínima observada nesse período.

Com a aplicação do método de correção de viés por ACC, notou-se uma melhora consistente no desempenho do modelo, com expansão das áreas classificadas como intermediárias e redução significativa das regiões classificadas como ruins. Esse resultado indicou que a ACC foi eficaz em ajustar a estrutura estatística da temperatura mínima simulada, sobretudo no que diz respeito à correlação temporal e à variabilidade espacial.

Por sua vez, o método de RCP também promoveu melhorias relevantes, embora de forma espacialmente mais heterogênea. Em alguns meses do semestre, surgiram áreas classificadas como muito bom, especialmente em setores específicos do domínio, sugerindo que o RCP consegue capturar padrões dominantes da variabilidade térmica mínima.

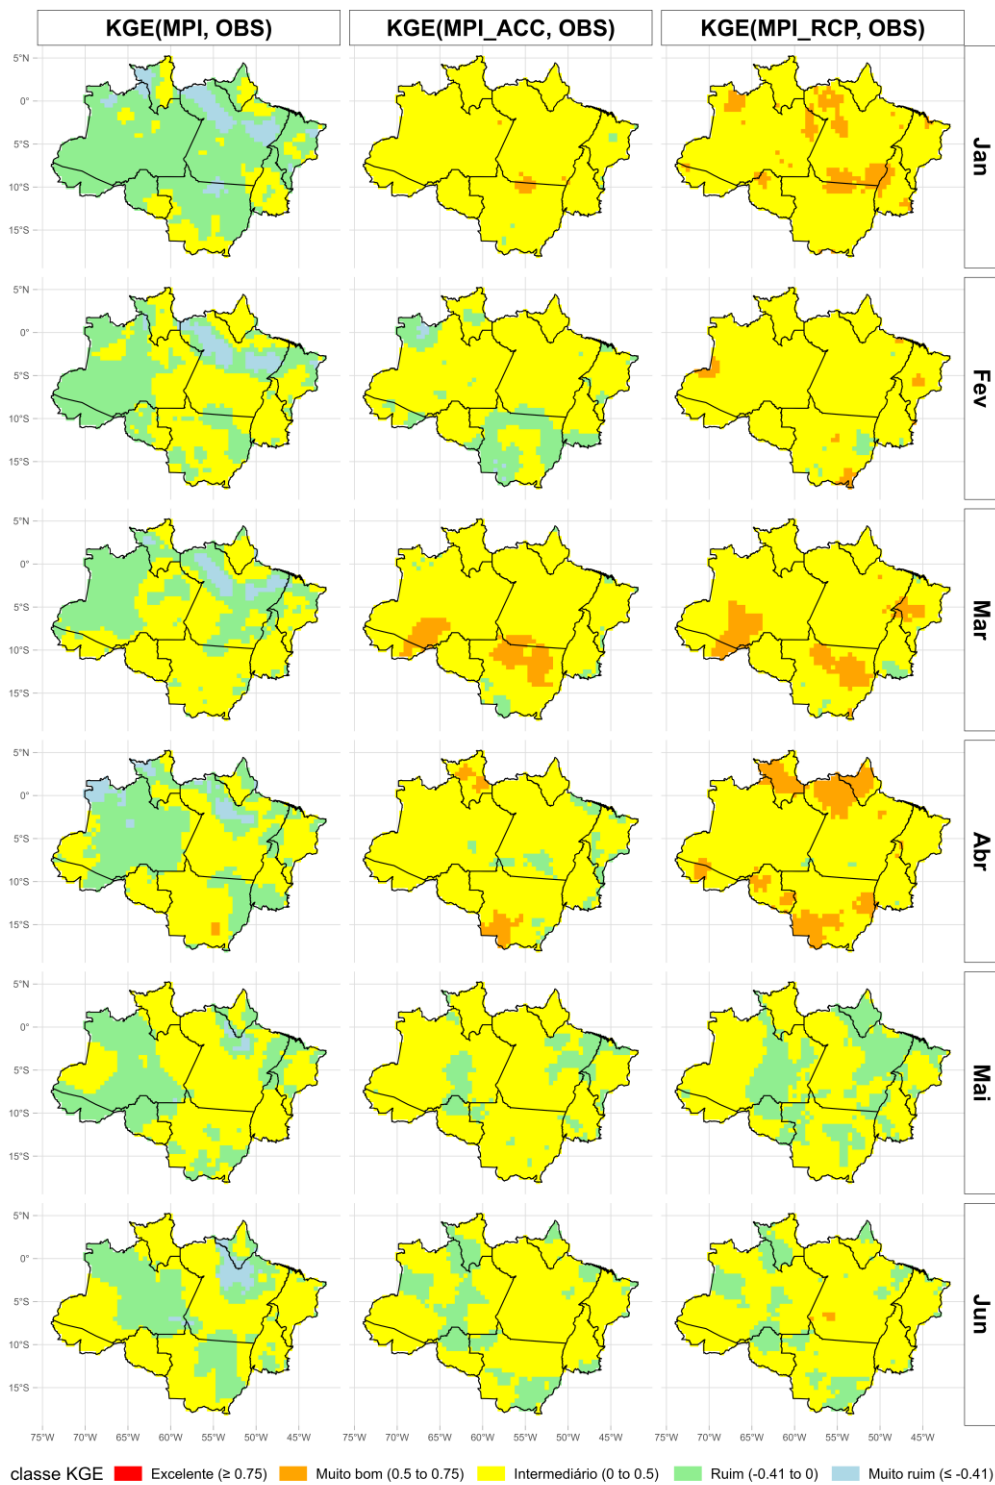
No segundo semestre (figura 17), o desempenho do modelo bruto apresentou uma melhora em comparação ao primeiro semestre, com predomínio da classe intermediária em grande parte da região. Ainda assim, persistiram áreas classificadas como ruim.

A aplicação da correção por ACC resultou em uma melhoria expressiva e generalizada do desempenho do modelo ao longo do semestre. Observou-se a expansão das classes intermediária e muito bom, com redução quase total das áreas classificadas como ruim. Esse comportamento indicou que, durante o segundo semestre, quando as condições atmosféricas tendem a ser mais estáveis e com menor variabilidade convectiva, a ACC apresentou maior eficiência em ajustar simultaneamente correlação, viés e variabilidade, refletindo em valores mais elevados do KGE.

No caso da correção por RCP, foi apresentado um desempenho superior ao observado tanto nos dados brutos do MPI quanto na correção por ACC, evidenciando


uma melhora consistente nos valores do KGE ao longo dos meses analisados. A aplicação da RCP resultou em uma expansão significativa das áreas classificadas como muito bom. Além disso, observou-se o surgimento de áreas enquadradas na classe excelente, particularmente nos meses de julho, setembro e outubro, concentradas em porções centrais e ao norte da ALB. Em contraste, as classes ruim e muito ruim, mais frequentes no MPI sem correção, tornaram-se pontuais ou praticamente inexistentes após a aplicação da RCP.

Figura 16. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo MPI no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 17. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo MPI no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.8 Análise do Kling Gupta Efficiency (KGE) Para o Modelo REG – Temperatura Mínima

No primeiro semestre (figura 18), o REG sem correção apresentou, de modo geral, desempenho classificado entre intermediário e ruim sobre grande parte da ALB. Observou-se predominância de valores de KGE entre 0 e 0,5, com áreas pontuais classificadas como “ruim” e “muito ruim”, especialmente em setores do oeste e noroeste da região. Esse padrão indicou limitações do modelo regional em reproduzir adequadamente a variabilidade e os valores médios da temperatura mínima durante o período mais úmido do ano.

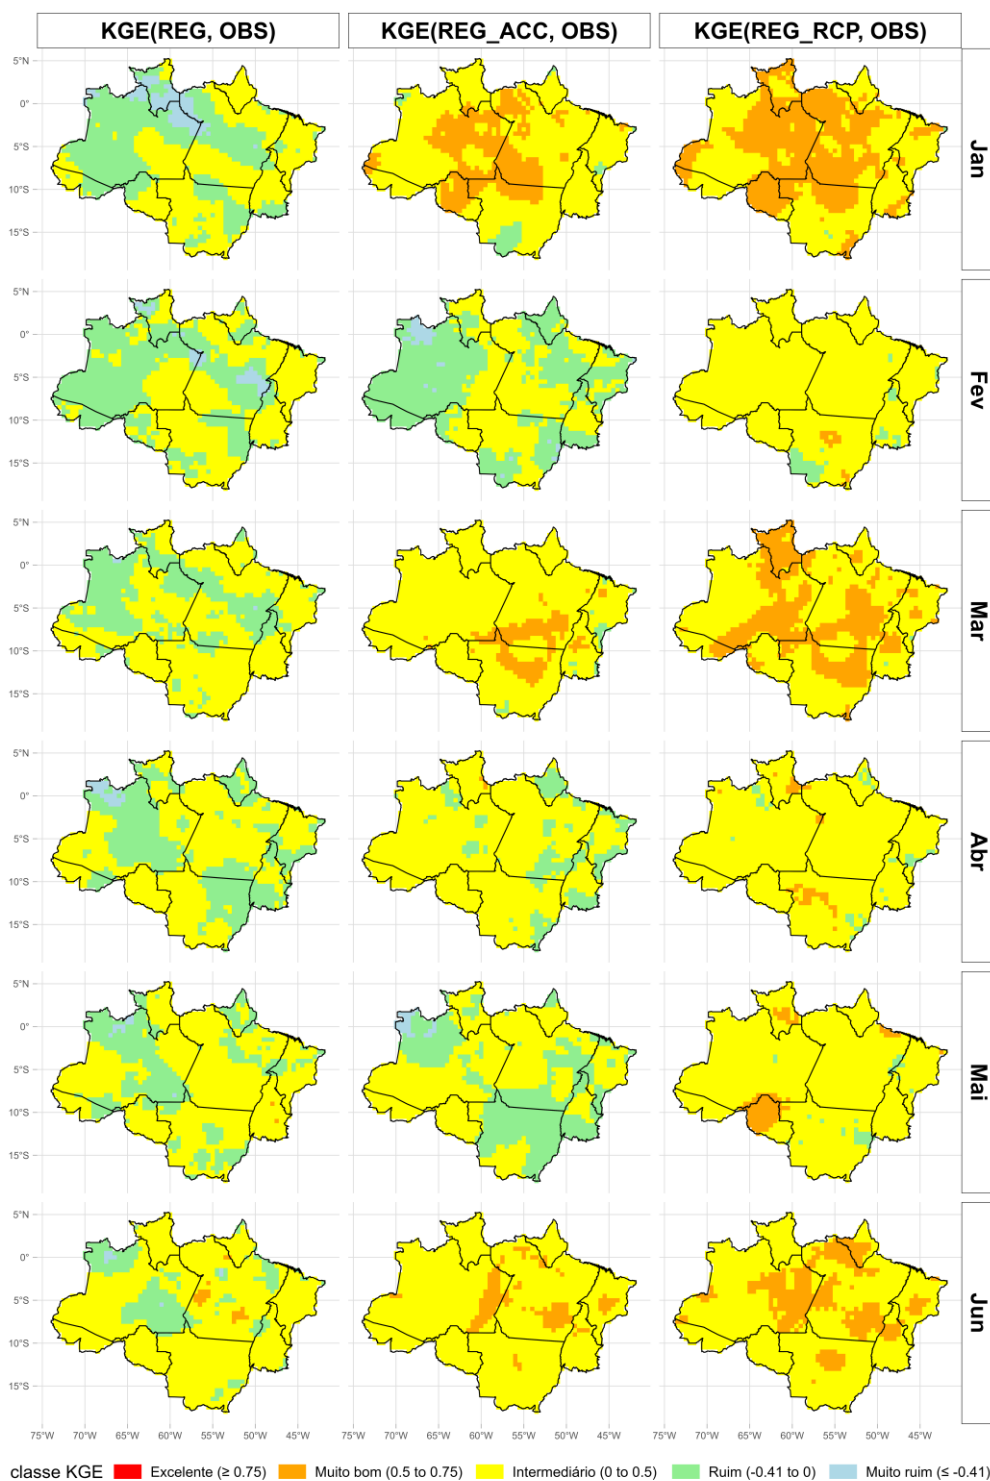
A aplicação da correção por ACC promoveu melhora no desempenho do modelo, com expansão das áreas classificadas como “intermediárias” e o surgimento das regiões com desempenho muito bom. Por sua vez, a correção via RCP apresentou ganho adicional em relação ao REG-ACC, com aumento das áreas classificadas como “intermediário” e expansão de regiões com desempenho “muito bom”.

No segundo semestre (figura 19), observou-se uma melhoria geral no desempenho do REG em relação ao primeiro semestre. O modelo sem correção apresentou aumento da frequência de valores de KGE classificados como “intermediário”, com redução das áreas com desempenho ruim, especialmente durante os meses de transição para a estação seca.

A aplicação da correção por ACC resultou em ganhos mais consistentes no segundo semestre, quando comparado ao primeiro. As áreas com KGE intermediário tornaram-se dominantes, e surgiram extensas regiões classificadas como “muito bom”, principalmente no centro da ALB. Isso indica que as relações estatísticas utilizadas pelo método ACC tornaram-se mais eficazes em períodos de menor variabilidade atmosférica.

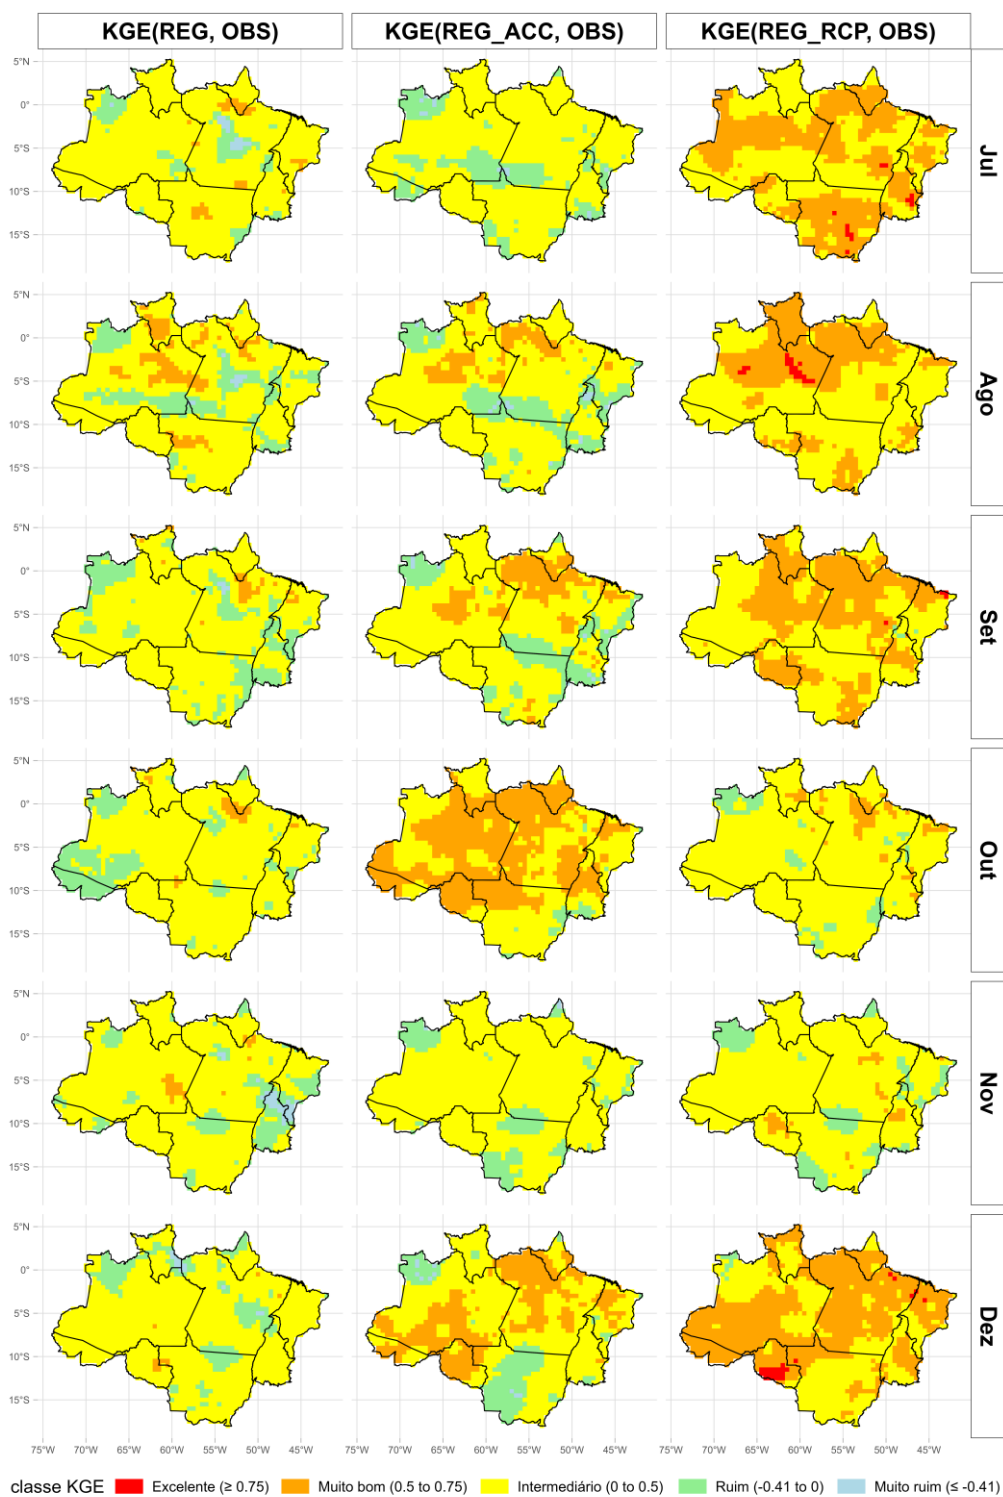
O melhor desempenho foi observado novamente com a correção por RCP, que apresentou a maior extensão espacial de classes “muito bom” e, pontualmente, “excelente”. Esse resultado evidenciou que o método de regressão por componentes principais é particularmente eficiente para ajustar as simulações de temperatura mínima do REG durante o segundo semestre, quando os padrões térmicos são mais controlados por forçantes de grande escala e menos afetados por processos convectivos complexos.

Figura 18. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo REG no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 19. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura mínima para o modelo REG no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.9 Climatologia Observada/MPI/REG – Temperatura Máxima

No primeiro semestre (Figura 20), a climatologia observada (OBS) indicou valores relativamente homogêneos de temperatura máxima sobre a ALB, com temperatura máxima entre 30 e 34°C, e gradientes espaciais associados principalmente à latitude, cobertura vegetal e nebulosidade persistente durante a estação chuvosa. Os menores valores concentraram-se no norte e no sul da ALB, refletindo um aumento da nebulosidade, maior atividade convectiva e maior disponibilidade de umidade associada ao Sistema de Monção da América do Sul (SAMS) (Marengo et al., 2012).

O modelo global MPI apresentou, de forma consistente, um viés frio em todo o primeiro semestre, com subestimação da temperatura máxima em praticamente toda a ALB. Tal viés frio já foi amplamente documentado em modelos globais sobre a Amazônia e está associado, entre outros fatores, à superestimação da nebulosidade, à representação inadequada da convecção profunda e a deficiências no balanço de energia à superfície (Silva et al., 2025; Meng et al., 2018).

O REG, por sua vez, apresentou um contraste em relação ao MPI no primeiro semestre, como evidenciado na figura 6. Observou-se um viés quente, sobretudo no norte e oeste da ALB, com a temperatura máxima frequentemente acima de 36-40°C entre janeiro e março. Esse aquecimento excessivo sugere limitações na representação dos processos de superfície e da convecção no REG durante o período úmido, possivelmente relacionadas a uma subestimação da nebulosidade convectiva, excesso de radiação solar incidente à superfície e deficiências no acoplamento solo-vegetação-atmosfera (Kendon et al., 2017; Dirmeyer et al., 2018).

Esse resultado indicou que, no primeiro semestre, a regionalização não foi capaz de corrigir os vieses do modelo global e, em alguns casos, amplificou erros térmicos.

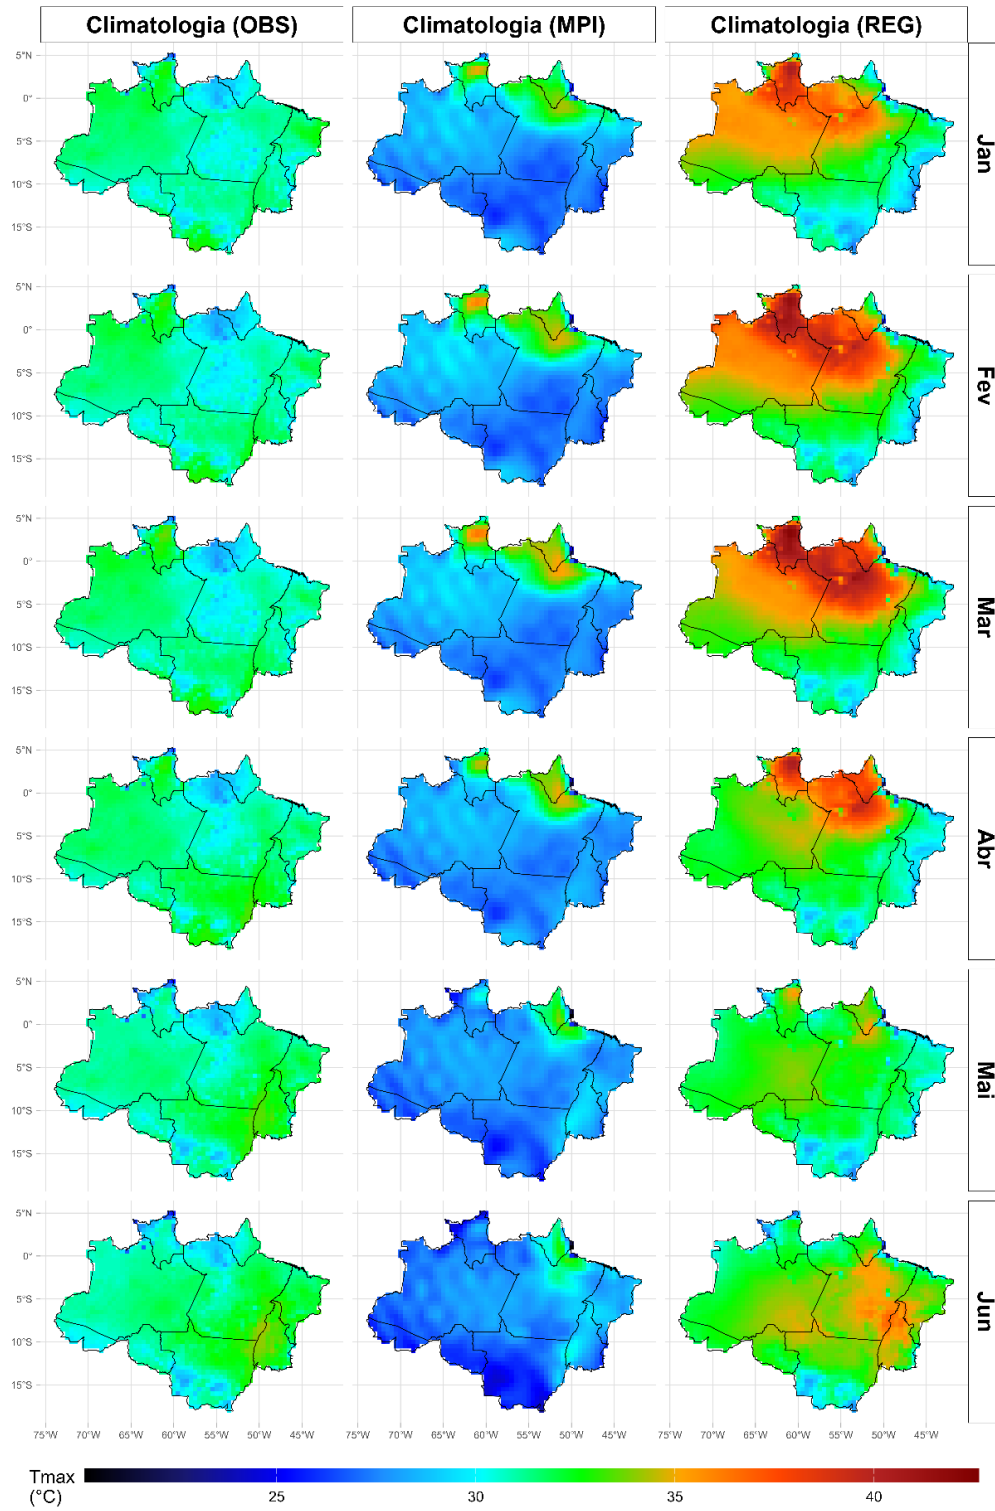
No segundo semestre (Figura 21), a climatologia observada revelou um aumento progressivo da temperatura máxima, especialmente entre agosto e outubro, período associado à estação seca na maior parte da ALB. Os maiores valores concentraram-se no leste e sudeste da região, onde a redução da nebulosidade, a diminuição da umidade do solo e o aumento da radiação solar favorecem temperaturas máximas mais elevadas (Marengo et al., 2022; Junior et al., 2025).

O MPI continuou apresentando viés frio ao longo do segundo semestre, embora de forma menos intensa do que no primeiro. Ainda assim, o modelo subestimou os picos de temperatura máxima observados entre agosto e outubro, especialmente no sul e leste da Amazônia, período crítico associado ao estresse térmico e à intensificação de queimadas (Xu et al., 2020). Esse comportamento reforça a limitação do modelo global em representar adequadamente o aquecimento durante a estação seca.

O REG, por outro lado, apresentou um comportamento distinto no segundo semestre. Observou-se que o modelo regional reproduz melhor os padrões espaciais e a magnitude da temperatura máxima, especialmente entre agosto e outubro, quando os máximos térmicos são mais pronunciados. Embora ainda haja áreas com viés quente, o REG consegue capturar de forma mais realista os gradientes espaciais e a intensificação do aquecimento associada à redução da umidade e à maior insolação.


Esse melhor desempenho relativo do REG no segundo semestre está de acordo com a literatura, que indica que modelos regionais tendem a representar melhor a temperatura máxima durante períodos secos, quando os processos locais, como uso do solo, topografia e balanço de energia superficial, desempenham papel mais dominante (Sangelantoni et al., 2023; Ma et al., 2022).

Figura 20. Climatologia mensal da temperatura máxima do ar (°C) sobre a ALB, referente aos meses de janeiro a junho, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.



Fonte: Autor (2025)

Figura 21. Climatologia mensal da temperatura máxima do ar (°C) sobre a ALB, referente aos meses de julho a dezembro, obtida a partir de dados observados (OBS), do modelo climático global MPI e do modelo climático regional REG, para o período de 1981-2012.



Fonte: Autor (2025)

5.10 Viés da Temperatura Máxima

O MPI apresentou, de forma consistente, viés negativo predominante em grande parte da ALB (figura 22), com diferenças negativas mais intensas especialmente no centro-sul da região, indicando uma subestimação da temperatura máxima em relação às observações. Esse padrão foi particularmente evidente entre janeiro e abril, período associado à estação chuvosa em grande parte da Amazônia. A dificuldade do modelo global em representar adequadamente processos de menor escalas, como a variabilidade da cobertura de nuvens e os fluxos turbulentos na camada limite, contribui para esse viés frio, conforme discutido na literatura (Reboita et al., 2024; Silva et al., 2025).

Em contraste, o REG apresentou viés positivo predominante ao longo do primeiro semestre, com superestimação da temperatura máxima especialmente no norte e noroeste da ALB, enquanto valores próximos de zero ou levemente negativos ocorrem em áreas mais ao sul e sudeste da região. Esse comportamento sugere que o REG, apesar de capturar melhor os gradientes espaciais devido à sua maior resolução, tende a superaquecer a superfície, possivelmente em função da representação dos processos de superfície, do balanço de energia e da parametrização da convecção (Silva et al., 2023).

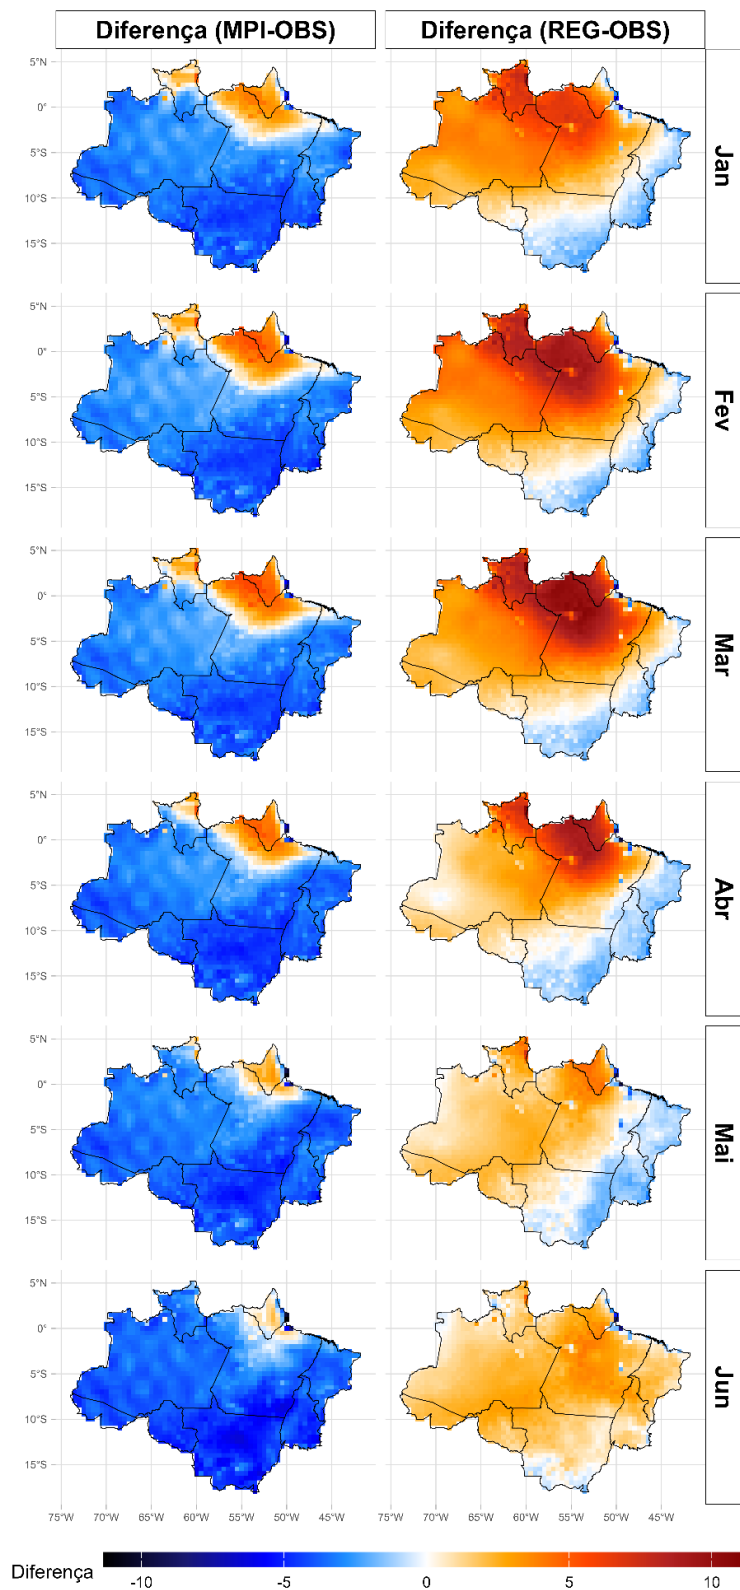
De modo geral, no primeiro semestre, os resultados indicaram que o MPI subestimou sistematicamente a temperatura máxima, enquanto o REG apresentou tendência oposta, com superestimação mais pronunciada.

O MPI manteve o viés frio ao longo de praticamente todo o segundo semestre (figura 23), com diferenças negativas mais intensas entre julho e agosto, especialmente no centro-sul da ALB. Esse padrão sugere que o modelo global continua subestimando os extremos de temperatura máxima durante a estação seca, quando a menor nebulosidade favorece maior aquecimento da superfície.

Por outro lado, o REG continuou apresentando viés positivo mais intenso no segundo semestre, com superestimações que se intensificam principalmente entre agosto e outubro, meses típicos da estação seca. As maiores diferenças positivas concentraram-se no norte, nordeste e leste da ALB, indicando que o modelo regional tende a amplificar o aquecimento máximo nesse período.

Apesar disso, nota-se que o REG apresentou padrões espaciais mais consistentes com a climatologia regional, quando comparado ao MPI, ainda que com magnitude de viés superior em algumas áreas.

Figura 22. Diferença mensal da temperatura máxima do ar ($^{\circ}\text{C}$) entre os modelos climáticos (MPI e REG) e os dados observacionais na ALB, para o primeiro semestre (janeiro a junho).



Fonte: Autor (2025).

5.11 Correlação entre os Dados Observados e o Modelo MPI – Temperatura Máxima

As correlações entre a temperatura máxima observada e as simulações do MPI durante o primeiro semestre (Figura 24) evidenciaram limitações relevantes do modelo em sua configuração original. As saídas brutas do MPI apresentaram, correlações fracas a moderadas, com ampla variabilidade espacial ao longo da ALB. Em vários meses observaram-se áreas extensas com correlações próximas de zero e até negativas, notadamente nos setores norte e nordeste da região.

A aplicação do método de ACC resultou em uma melhora significativa das correlações espaciais no primeiro semestre. Apresentaram um padrão mais homogêneo, com predominância de correlações positivas moderadas a altas em praticamente toda a ALB. A ACC demonstrou elevada capacidade de reduzir discrepâncias sistemáticas do modelo global, ajustando a variabilidade espacial da temperatura máxima simulada àquela observada.

De forma semelhante, o método de RCP também promoveu ganhos substanciais em relação às saídas brutas do MPI. As correlações tornaram-se majoritariamente positivas e espacialmente consistentes, mostrando um ganho até superior em relação a ACC.

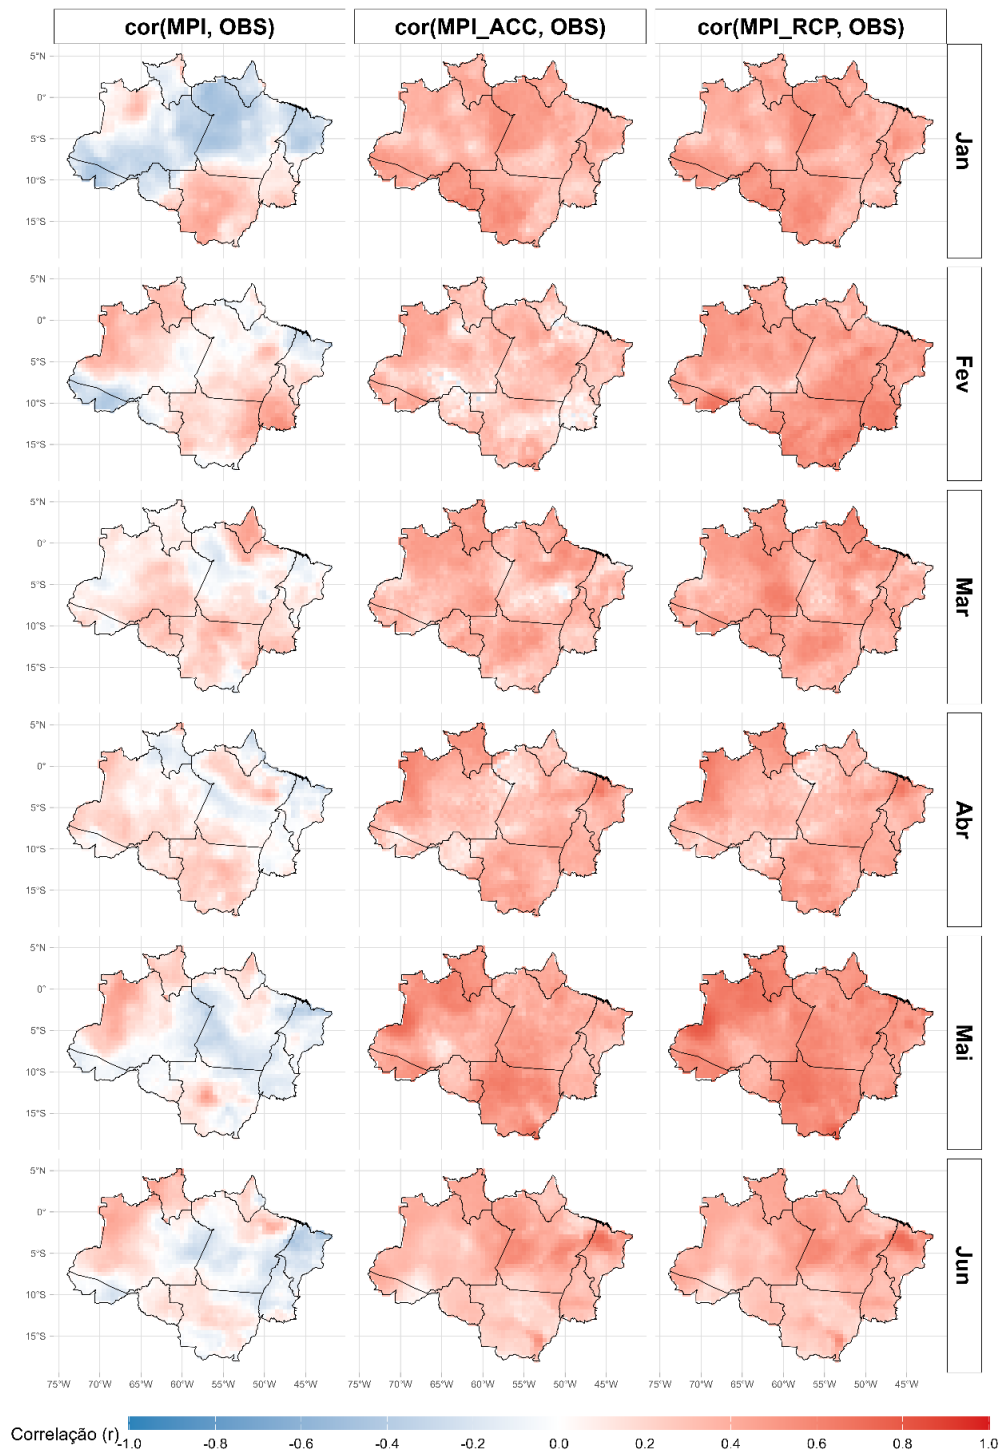
No segundo semestre (Figura 25), observou-se uma melhoria geral no desempenho do MPI, inclusive nas saídas brutas do modelo. As correlações tornaram-se predominantemente positivas e mais homogêneas espacialmente, principalmente entre julho e outubro.

Apesar dessa melhora natural do modelo global, a aplicação dos métodos de correção de viés continuou promovendo ganhos adicionais. As correlações obtidas com a ACC mantiveram-se elevadas e espacialmente consistentes ao longo de todo o segundo semestre, indicando uma forte correspondência entre as séries simuladas e observadas. Em vários meses, as correlações atingiram valores elevados em praticamente toda a ALB, evidenciando a robustez do método mesmo em condições climáticas distintas daquelas do primeiro semestre.

O método de RCP também apresentou excelente desempenho no segundo semestre, com correlações semelhantes ou, em alguns casos, superiores às obtidas pela


ACC. Notou-se que, nesse período, as diferenças entre os dois métodos tornaram-se menos pronunciadas, sugerindo que a menor complexidade atmosférica favorece a eficácia de tais técnicas.

Figura 24. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo MPI e os dados observados na ALB, para o primeiro semestre (janeiro a junho).



Fonte: Autor (2025)

Figura 25. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo MPI e os dados observados na ALB, para o segundo semestre (julho a dezembro).



Fonte: Autor (2025).

5.12 Correlação entre os Dados Observados e o Modelo REG – Temperatura Máxima

No primeiro semestre do ano (Figura 26), a correlação entre a temperatura máxima simulada pelo modelo regional REG e os dados observados apresentou comportamento espacialmente heterogêneo quando consideradas as saídas brutas do modelo. Observaram-se valores de correlação predominantemente fracos a moderados em grande parte da região, com áreas localizadas exibindo correlações negativas, especialmente nos meses de janeiro a março.

Com a aplicação da correção de viés por ACC (REG-ACC) notou-se uma melhoria substancial na habilidade do modelo em reproduzir a variabilidade espacial da temperatura máxima. As correlações tornaram-se predominantemente positivas e mais homogêneas, com valores moderados a elevados ao longo de praticamente todo o domínio, apresentando a eficácia do método de ACC em capturar os padrões dominantes associados à temperatura máxima no primeiro semestre. Essa melhoria sugere que a técnica consegue ajustar de forma consistente os erros sistemáticos do REG.

Resultados semelhantes foram observados com a aplicação da correção por RCP (REG-RCP), que também promoveu um aumento expressivo das correlações em relação às simulações não corrigidas. Em geral, os valores de correlação obtidos com o REG-RCP são comparáveis aos do REG-ACC, embora em alguns meses a RCP apresente ligeira superioridade espacial.

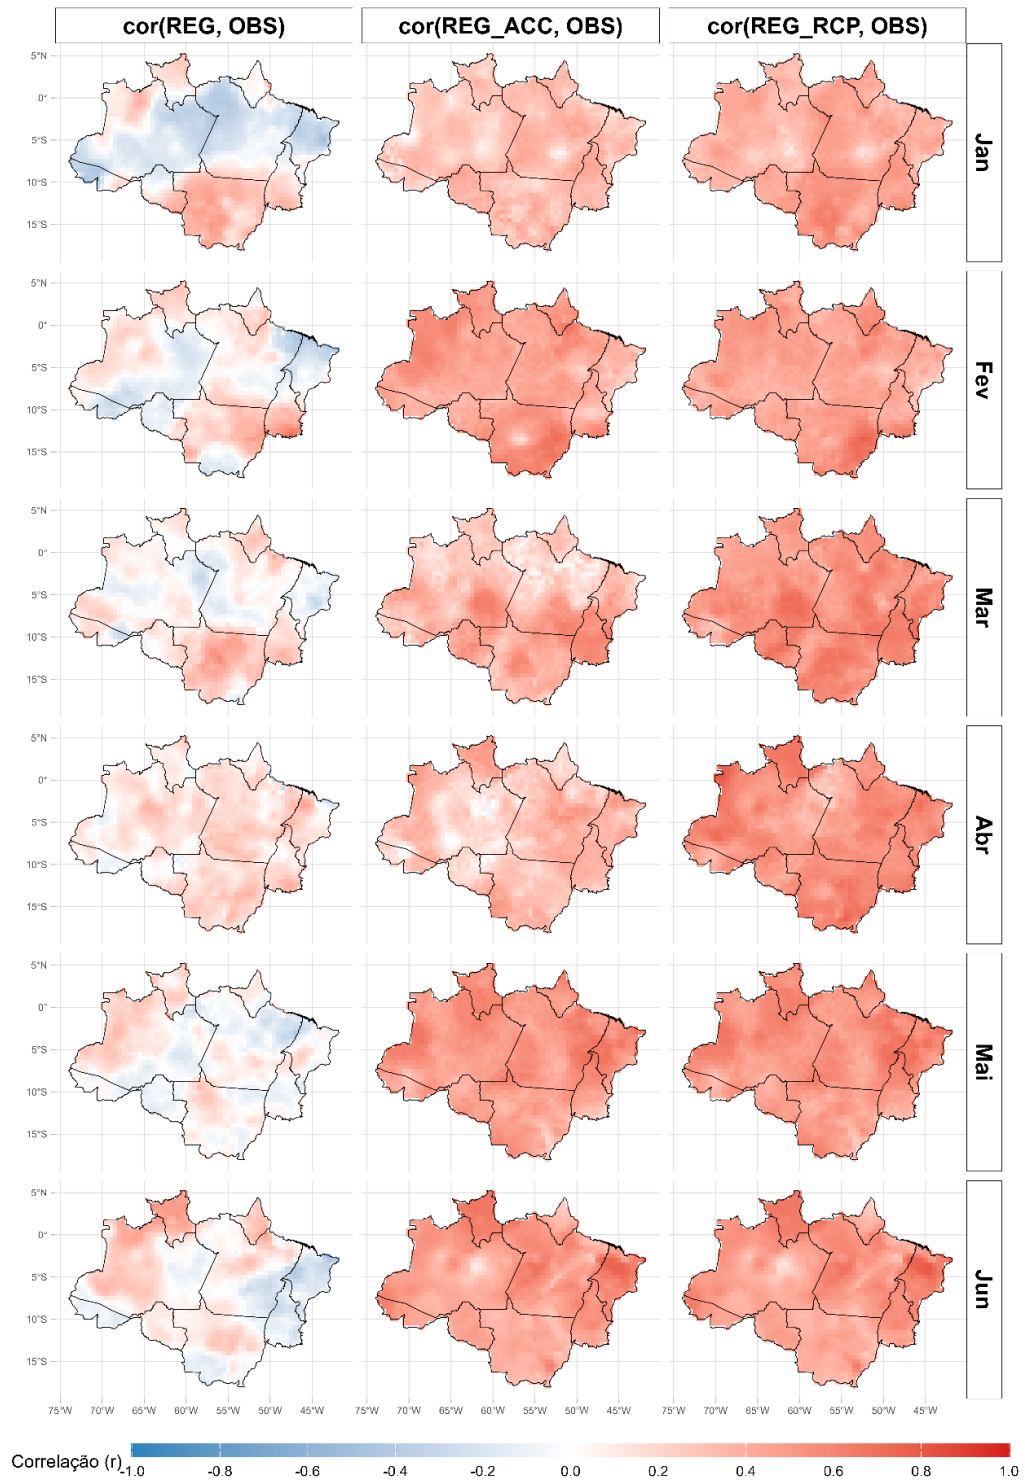
No segundo semestre (Figura 27), observou-se, novamente, um aumento geral das correlações entre o REG e os dados observados mesmo antes da aplicação das correções de viés. As saídas brutas do modelo já apresentaram correlações predominantemente positivas, sobretudo entre julho e agosto.

A aplicação do método REG-ACC intensificou esse padrão, resultando em correlações altas e espacialmente consistentes em praticamente todo o domínio ao longo do semestre. A homogeneização espacial das correlações indicou que o método ACC é particularmente eficaz em períodos de menor variabilidade atmosférica, potencializando a habilidade preditiva do REG para a temperatura máxima durante a estação seca.

De forma semelhante, o método REG-RCP também apresentou desempenho elevado no segundo semestre, com correlações altas e distribuição espacial bastante

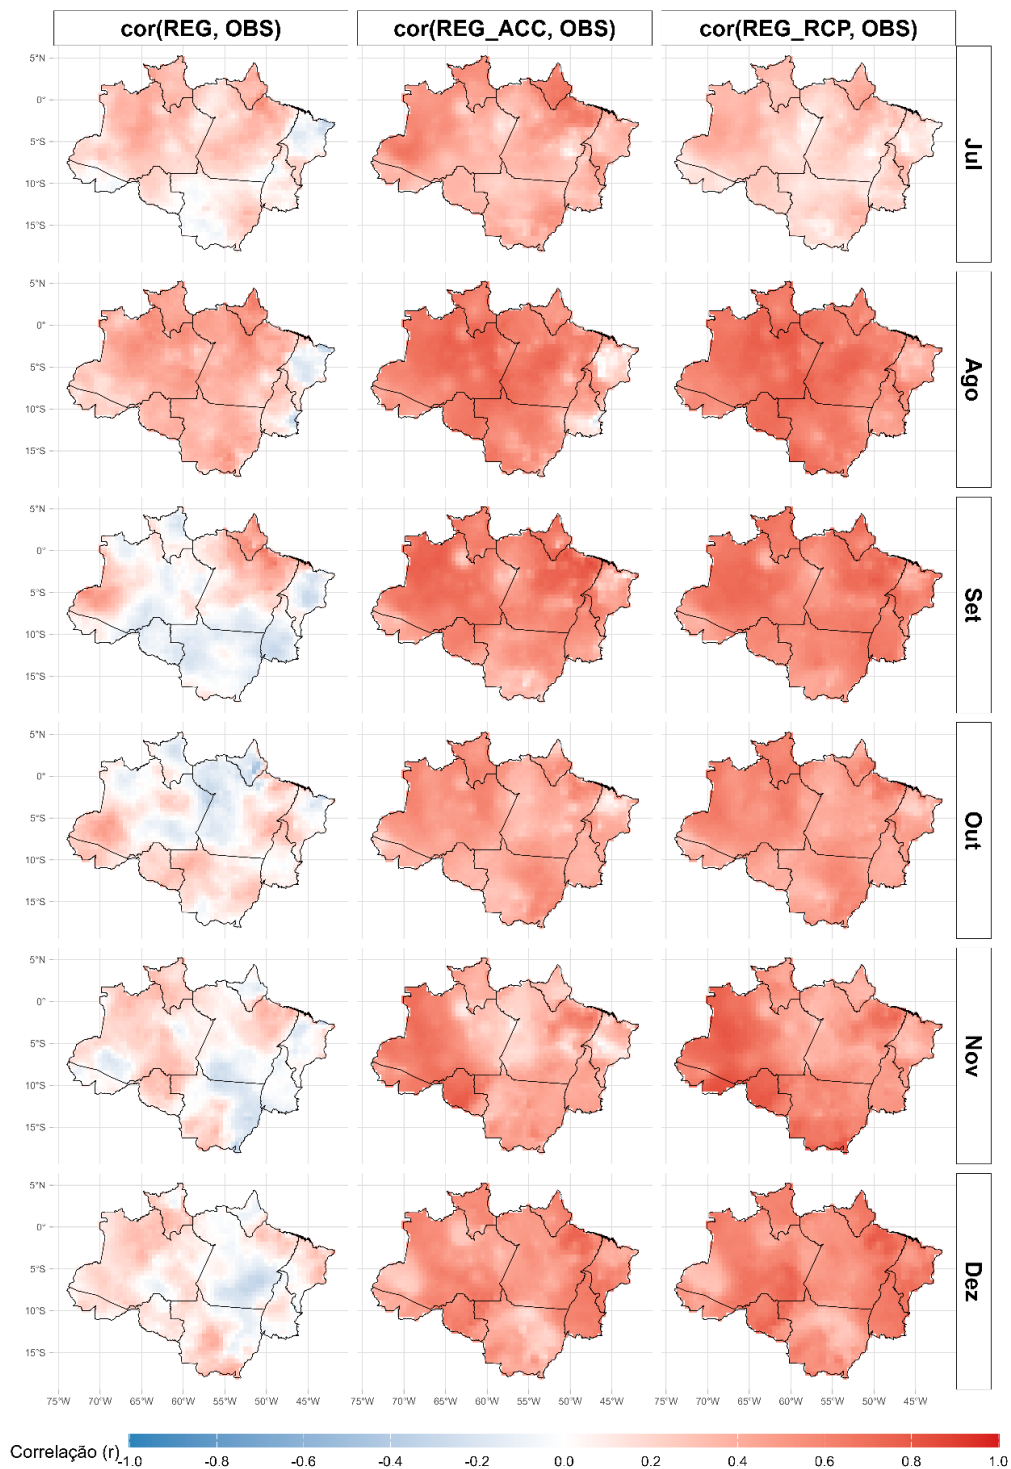
uniforme. Em diversos meses, os resultados do REG-RCP são muito próximos aos obtidos com o REG-ACC, sugerindo que ambos os métodos são robustos para a correção da temperatura máxima em condições atmosféricas mais estáveis.

Figura 26. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo REG e os dados observados na ALB, para o primeiro semestre (janeiro a junho).



Fonte: Autor (2025).

Figura 27. Distribuição espacial da correlação de Pearson (r) entre a temperatura máxima mensal simulada pelo modelo REG e os dados observados na ALB, para o segundo semestre (julho a dezembro).



Fonte: Autor (2025).

5.13 Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo MPI – Temperatura Máxima

A análise do RMSE para o primeiro semestre (figura 28) mostraram que o modelo global MPI, em sua forma bruta, apresentou erros sistemáticos espacialmente organizados sobre a ALB. Observou-se que, entre janeiro e março, os maiores valores de RMSE concentraram-se, principalmente, na porção norte e nordeste da região, com magnitudes que localmente ultrapassam valores moderados, enquanto as áreas centrais e meridionais apresentaram erros relativamente menores. Esse padrão sugere uma maior dificuldade do modelo em representar a variabilidade térmica máxima associada a regiões de intensa convecção e elevada cobertura de nuvens.

Nos meses subsequentes (abril a junho), notou-se uma leve redução dos valores de RMSE em grande parte da ALB, acompanhando a transição sazonal para condições menos convectivas em parte da região. Ainda assim, persistiram áreas com erros mais elevados no setor norte, indicando que o MPI manteve limitações na simulação da temperatura máxima mesmo em meses de menor atividade convectiva.

A aplicação das correções ACC e RCP promoveram uma redução significativa do RMSE em toda a ALB. Os mapas apresentaram valores próximos ou abaixo de 1 e se mostraram espacialmente homogêneos ao longo de todos os meses.

No segundo semestre (figura 29), o padrão de RMSE da temperatura máxima do MPI bruto apresentou uma nova configuração espacial dos erros. Entre julho e setembro, os maiores valores de RMSE deslocaram-se para porções centrais e sudeste da ALB, coincidindo com o período mais. Nessas condições, o modelo tende a apresentar maior sensibilidade a erros na parametrização da radiação, da umidade do solo e da interação superfície-atmosfera, o que se refletiu no aumento do RMSE.


Durante os meses de outubro a dezembro, observou-se novamente uma redução parcial dos erros em algumas áreas, acompanhando o início da retomada das chuvas em parte da região. No entanto, permaneceram núcleos de RMSE relativamente elevados, especialmente em regiões de transição entre áreas mais úmidas e mais secas.

Assim como observado no primeiro semestre, a aplicação das correções ACC e RCP no segundo semestre promoveu uma redução expressiva do RMSE em toda a ALB. Os mapas corrigidos apresentaram valores baixos e espacialmente homogêneos ao longo

de todos os meses, evidenciando a robustez dos métodos de correção mesmo em períodos de maior complexidade física associada à estação seca.


A análise também foi realizada com o MAE, com resultados similares aos obtidos com o RMSE.

Figura 28. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo MPI no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 29. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo MPI no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.14 Análise da Raiz do Erro Quadrático Médio (RMSE) para o Modelo REG – Temperatura Máxima

No primeiro semestre (figura 30), os mapas de RMSE para a temperatura máxima entre o campo regionalizado e as observações evidenciaram uma heterogeneidade espacial bem visível, com erros mais elevados concentrados predominantemente na porção norte e nordeste da ALB, especialmente nos meses de fevereiro e março. Nessas áreas, os valores de RMSE atingiram as classes mais altas da escala, indicando maior dificuldade do modelo regional em representar adequadamente a variabilidade da temperatura máxima durante o período chuvoso.

A presença frequente de nuvens convectivas intensificou a variabilidade espacial da radiação solar incidente, tornando a simulação da temperatura máxima particularmente sensível a erros na parametrização de nuvens e processos de convecção. Como consequência, observou-se um aumento consistente do RMSE no REG x OBS nesse semestre.

Por outro lado, quando aplicadas as correções estatísticas, tanto pela ACC quanto pela RCP, ocorreu uma redução expressiva e espacialmente homogênea do erro. Os mapas corrigidos apresentaram valores predominantemente nas classes mais baixas de RMSE, com pouca variabilidade espacial, indicando que os métodos foram eficazes em remover vieses sistemáticos associados à superestimativa da temperatura máxima pelo modelo regional.

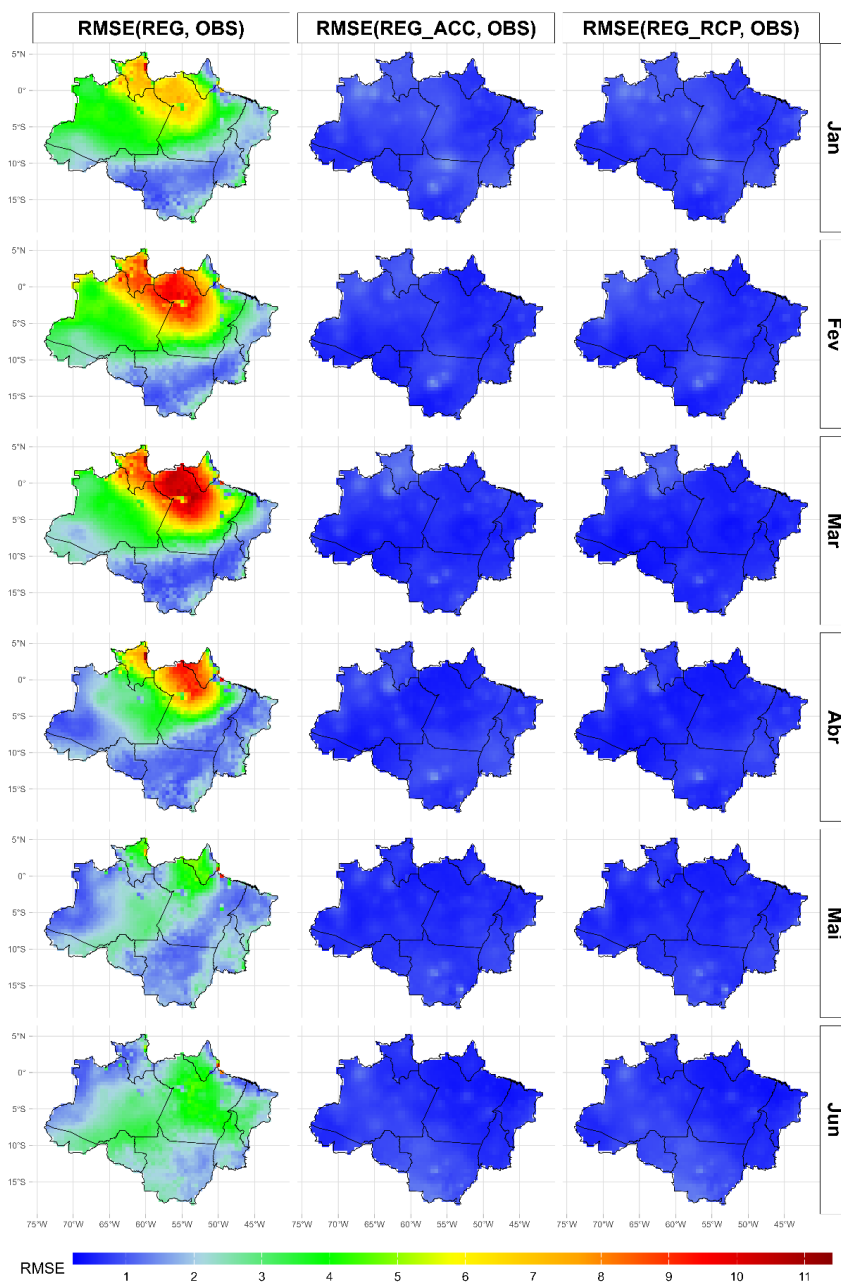
No segundo semestre (figura 31), observou-se uma redução natural dos erros em comparação ao primeiro semestre, refletindo a transição para um período mais seco em grande parte da ALB. Apesar dessa redução geral, ainda persistiram áreas com RMSE moderado a elevado, principalmente na faixa leste e sudeste da região, durante os meses de agosto a outubro. Esses meses coincidiram com o pico da estação seca, quando a temperatura máxima foi fortemente influenciada por condições de superfície, como umidade do solo e cobertura vegetal, além de possíveis efeitos associados a queimadas e aerossóis, fatores que nem sempre são plenamente representados nos modelos regionais.

Assim como observado no primeiro semestre, a aplicação das correções estatísticas resultou em uma melhoria do desempenho do modelo. Tanto o REG-ACC quanto o REG-RCP apresentaram campos de RMSE baixos e bastante uniformes ao longo

de todo o segundo semestre, indicando que os métodos conseguem ajustar adequadamente o sinal da temperatura máxima mesmo em períodos de maior aquecimento superficial.

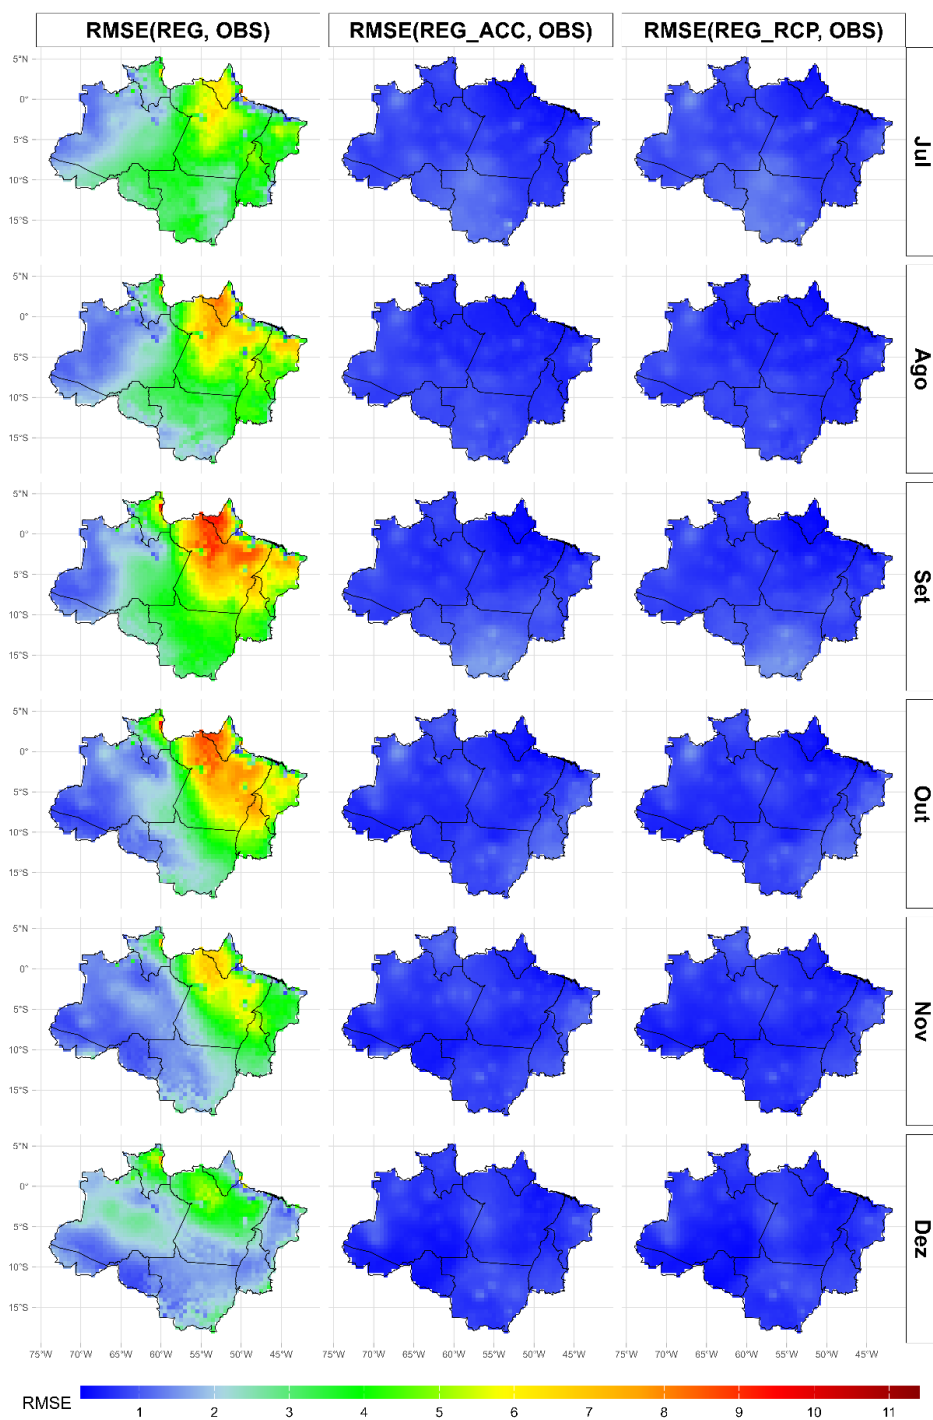
A mesma análise foi feita utilizando o MAE, foram obtidos resultados semelhantes ao RMSE.

Figura 30. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo REG no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 31. Distribuição espacial mensal da raiz do erro quadrático médio (RMSE, em °C) da temperatura máxima para o modelo REG no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.15 Análise do Kling Gupta Efficiency (KGE) para o Modelo MPI – Temperatura Máxima

O desempenho dos modelos na simulação durante o primeiro semestre (figura 32), mostraram que as simulações MPI brutas apresentaram predominantemente valores de KGE classificados como intermediários e ruins, com regiões apresentando classificação muito ruim. As piores performances concentraram-se especialmente nas porções central e norte da região, indicando limitações do modelo global em representar adequadamente tanto a variabilidade quanto o viés da temperatura máxima nesse período do ano.

A aplicação do método de correção por ACC promoveu uma melhora perceptível no desempenho, com expansão das áreas classificadas como intermediárias e redução das regiões com KGE ruim ou muito ruim, sobretudo no centro-sul da ALB. Esse resultado sugere que a correção multivariada baseada em correlação canônica contribuiu para o ajuste da estrutura estatística das simulações, especialmente no que diz respeito à variabilidade temporal.

Por sua vez, o método RCP apresentou desempenho comparável ao ACC no primeiro semestre, mantendo a predominância de classes intermediárias, mas com ganhos adicionais localizados, especialmente no noroeste da região. Ainda assim, ambos os métodos mostraram limitações em alcançar classes muito boas de forma espacialmente consistente.

No segundo semestre (figura 33), notou-se uma melhora geral do desempenho do KGE em relação ao primeiro semestre, principalmente nas simulações corrigidas. As saídas MPI brutas continuaram apresentando majoritariamente classes intermediárias, porém passou a apresentar, de forma pontual, KGE com a classificação muito boa.

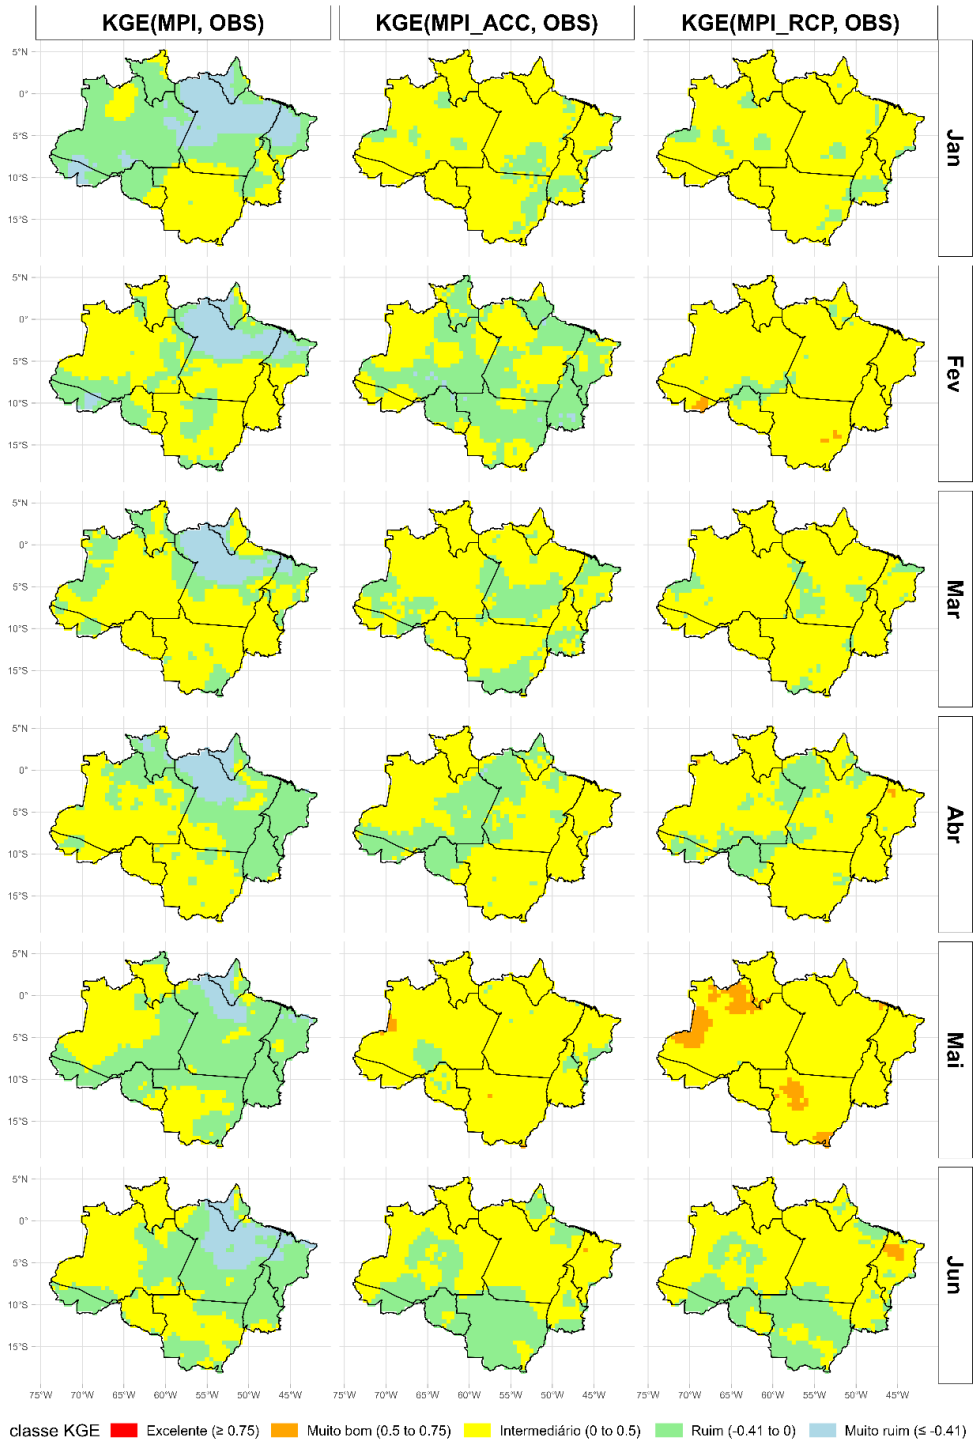
As simulações corrigidas por ACC mostraram avanço mais consistente no segundo semestre, com ampliação das áreas classificadas como intermediárias a muito boas. Esse comportamento indicou maior capacidade do método em ajustar simultaneamente viés e variabilidade durante o período seco, quando a sinalização térmica é mais bem definida.

O método RCP destacou-se no segundo semestre ao apresentar, de forma mais frequente, regiões classificadas como muito boas, especialmente entre setembro e

novembro. Esse resultado sugere que a RCP é particularmente eficiente em capturar a estrutura dominante da temperatura máxima em períodos de menor complexidade convectiva, favorecendo uma representação mais fiel das observações.

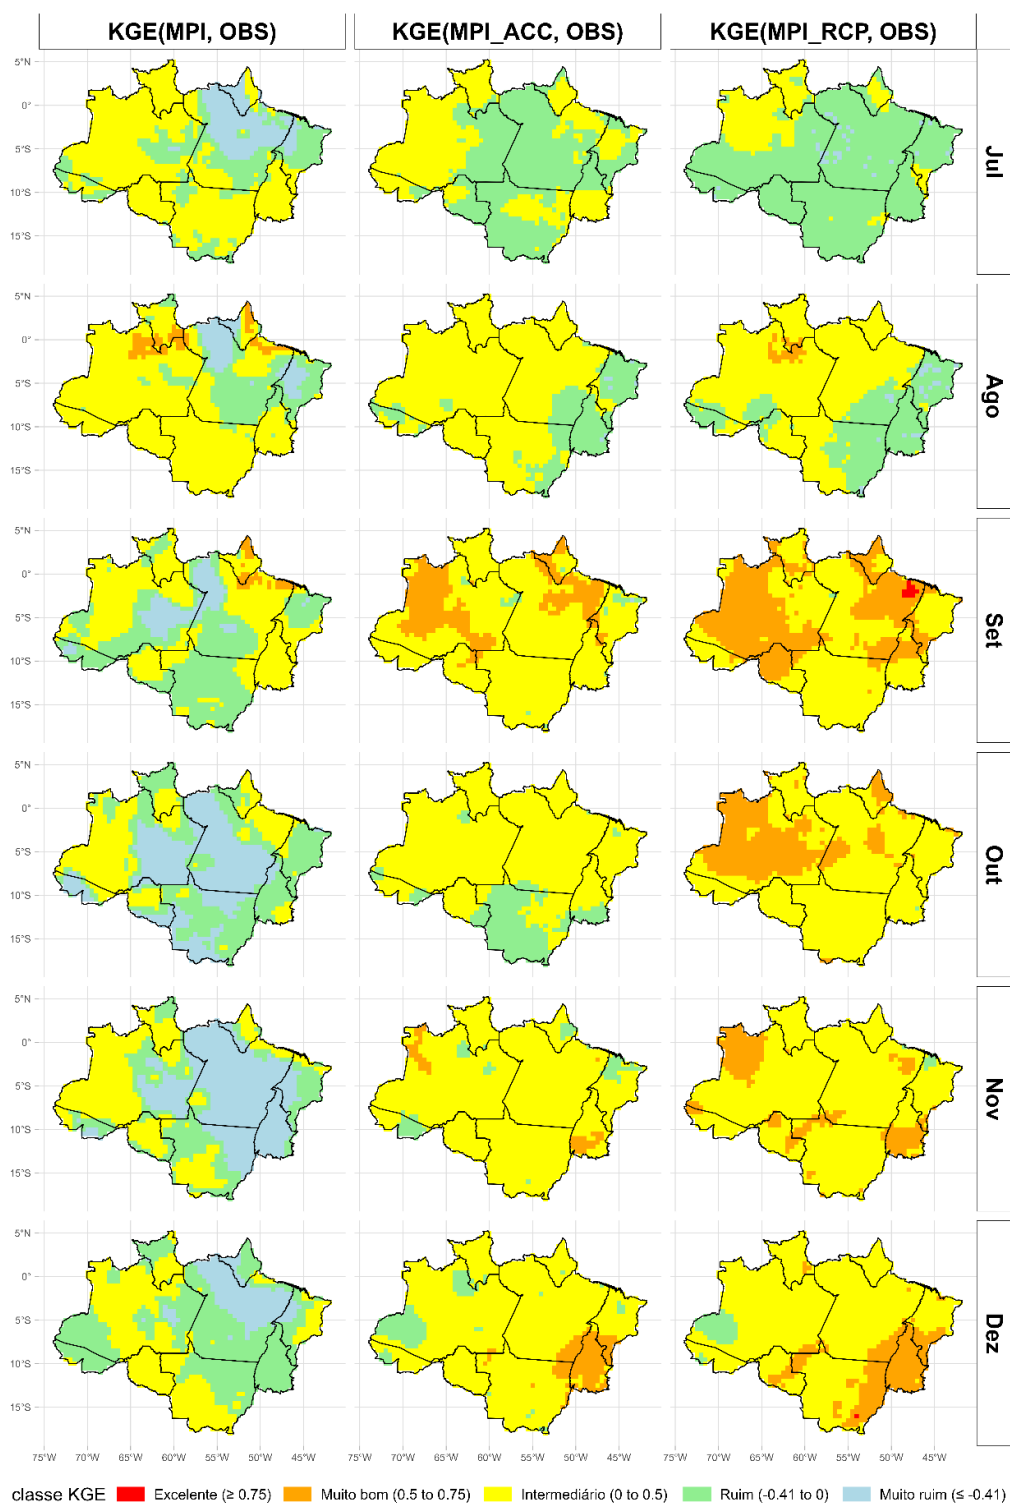
De modo geral, a análise semestral evidenciou que o desempenho do KGE para a temperatura máxima é sazonalmente dependente, com melhores resultados no segundo semestre, especialmente após a aplicação dos métodos de correção de viés.

Figura 32. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo MPI no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 33. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo MPI no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.16 Análise do Kling Gupta Efficiency (KGE) para o Modelo REG – Temperatura Máxima

No primeiro semestre (figura 34), o desempenho do modelo REG para a temperatura máxima foi predominantemente classificado como intermediário em grande parte da região, tanto para o REG bruto quanto para as versões corrigidas. Observou-se, entretanto, uma diferença clara entre as abordagens.

O REG, sem correção, apresentou extensas áreas com classes ruim a muito ruim, especialmente sobre a porção central e norte da ALB, indicando limitações na representação conjunta da variabilidade, viés e correlação da temperatura máxima durante o período chuvoso.

A aplicação das correções estatísticas resultou em melhorias consistentes. O REG-ACC promoveu uma redução das áreas classificadas como ruim, ampliando a predominância da classe intermediária, sobretudo no centro-sul e em partes do leste da região. Já o REG-RCP apresentou desempenho ligeiramente superior ao REG-ACC em alguns meses, com áreas pontuais classificadas como muito bom, indicando melhor equilíbrio entre variância, correlação e viés.

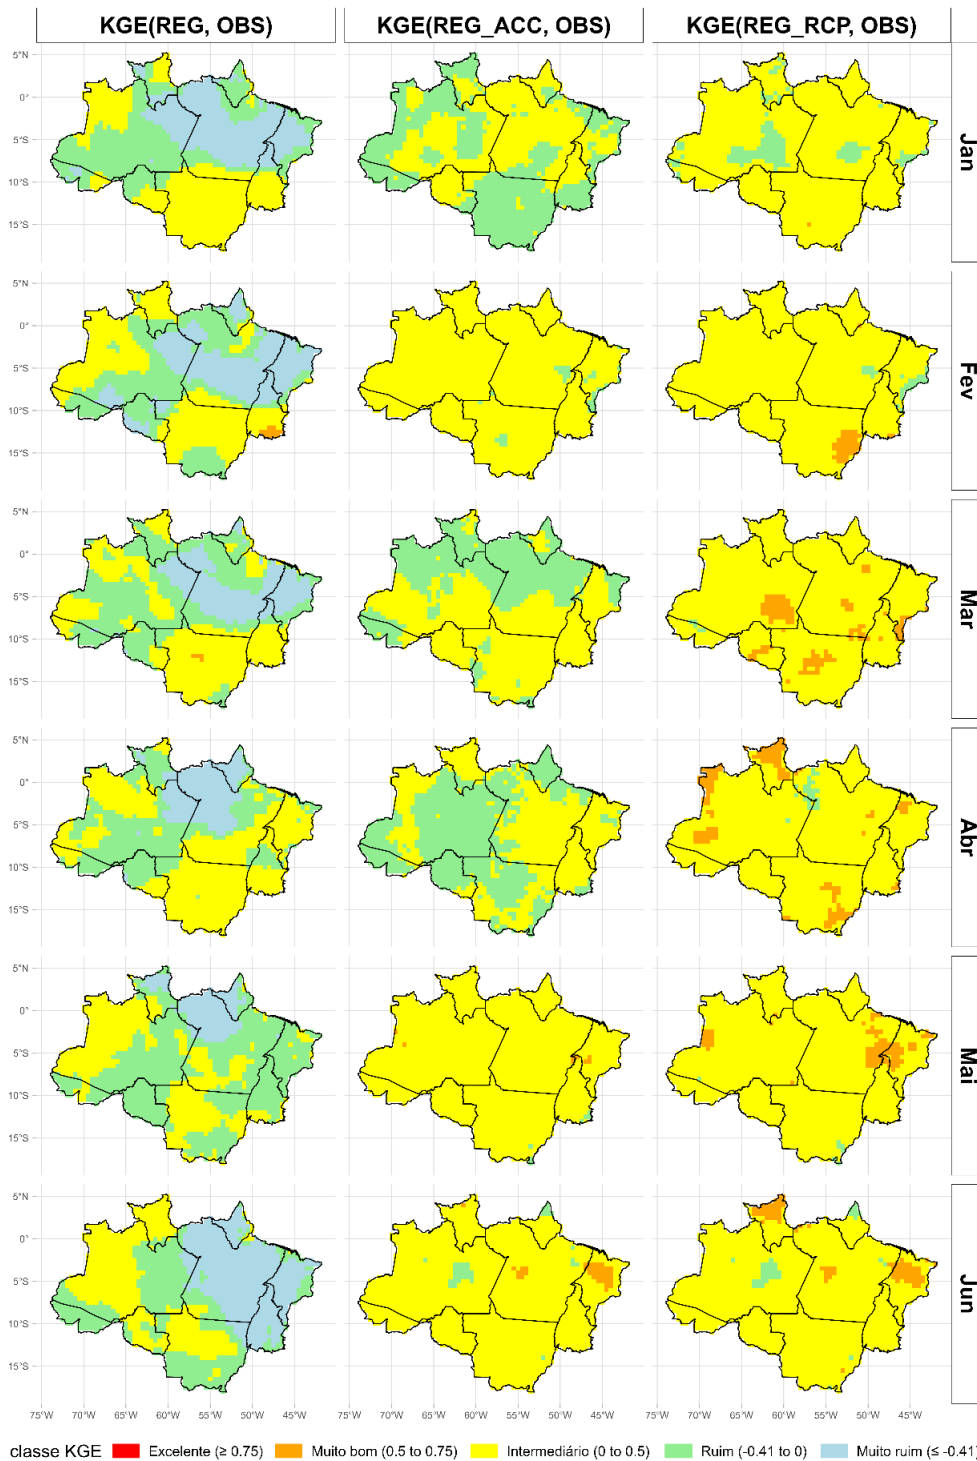
De forma geral, apesar das melhorias introduzidas pelas correções, o primeiro semestre ainda foi marcado por desempenho moderado, refletindo a maior complexidade física do período úmido para a simulação da temperatura máxima.

No segundo semestre (figura 35), notou-se uma melhora substancial no desempenho do KGE para a temperatura máxima em relação ao primeiro semestre. O REG bruto já apresentou uma ampliação das áreas classificadas como intermediárias, com redução das classes ruim e muito ruim, principalmente no período seco.

As versões corrigidas, REG-ACC e REG-RCP, evidenciaram ganhos mais expressivos. Em grande parte da região, especialmente entre agosto e novembro, predominaram classes intermediária a muito boa, com núcleos localizados de excelente desempenho, sobretudo na região central e oeste da ALB. Esse padrão indicou que, durante o período seco, o modelo conseguiu representar de forma mais consistente a variabilidade térmica diária, favorecendo o ajuste estatístico.

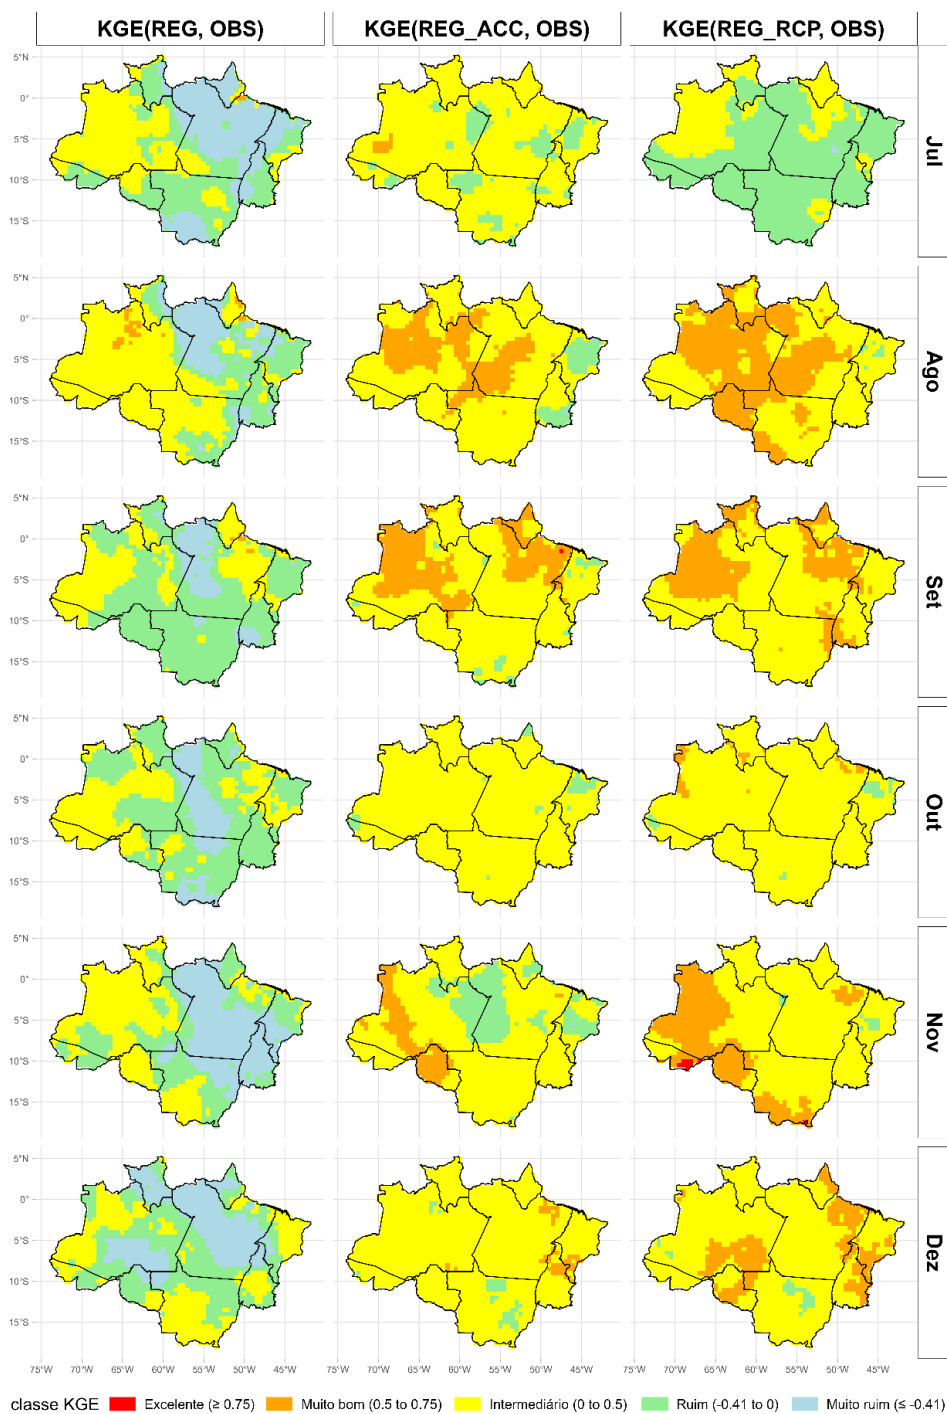
Comparativamente, o REG-RCP tendeu a apresentar maior continuidade espacial das classes muito boas no segundo semestre, enquanto o REG-ACC manteve desempenho semelhante, porém com maior heterogeneidade espacial em alguns meses.

Figura 34. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo REG no primeiro semestre (janeiro-junho).



Fonte: Autor (2025).

Figura 35. Distribuição espacial mensal do Kling Gupta Efficiency (KGE) da temperatura máxima para o modelo REG no segundo semestre (julho-dezembro).



Fonte: Autor (2025).

5.17 Análise de Cluster

A regionalização térmica da ALB foi realizada por meio de uma análise de cluster aplicada às séries de temperatura média, com o objetivo de identificar regiões climaticamente homogêneas e reduzir a elevada heterogeneidade espacial do domínio. A definição do número ótimo de grupos foi fundamentada na combinação de critérios estatísticos e na interpretação física dos padrões obtidos, conforme apresentado nas figuras 36 a 38.

Inicialmente, a escolha do número de clusters foi avaliada a partir do método do cotovelo (*elbow method*) (Figura 36a). Observou-se uma redução acentuada da soma dos quadrados dentro dos grupos para os primeiros agrupamentos, indicando ganhos significativos na explicação da variabilidade térmica. A partir de seis clusters, a inclinação da curva tornou-se progressivamente menos acentuada, sugerindo que a inclusão de novos grupos resulta em ganhos limitados. Esse comportamento indicou que seis clusters representam adequadamente a complexidade do sistema climático da ALB e a capacidade de sintetizar sua variabilidade térmica dominante.

A consistência dessa escolha é reforçada pela análise hierárquica apresentada no dendrograma (Figura 36b). O corte realizado na distância euclidiana indicada pela linha tracejada resultou claramente em seis agrupamentos bem definidos, com separação adequada entre os grupos. A concordância entre o método do cotovelo e o dendrograma confere robustez estatística à definição do número de clusters adotado.

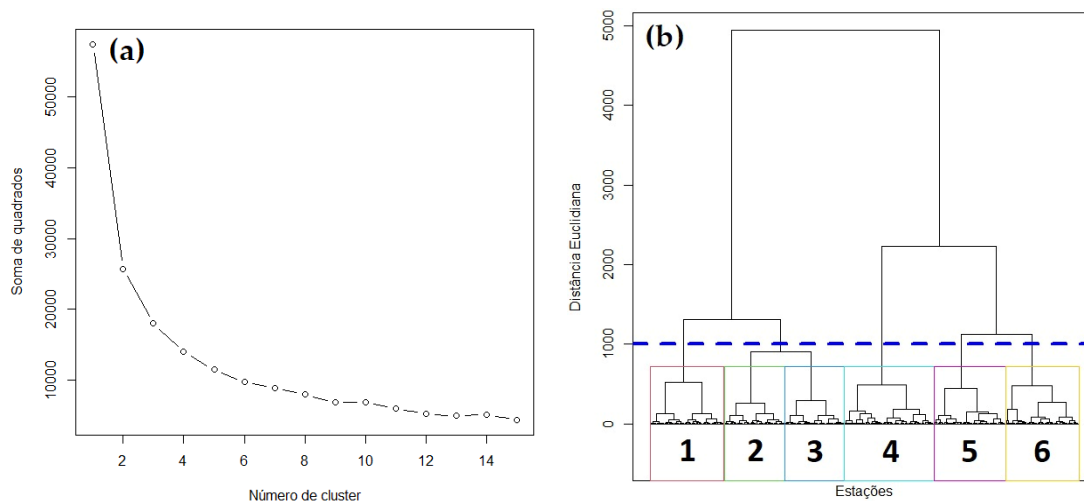
A distribuição espacial dos seis clusters é apresentada na Figura 37, evidenciando que os agrupamentos não se distribuem de forma aleatória sobre a ALB, mas refletem padrões climáticos e geográficos bem definidos. O Grupo 1, localizado predominantemente na porção oeste do domínio, apresentou características típicas de regiões continentais, com menor influência oceânica e maior amplitude térmica anual. O Grupo 2 ocupou áreas do setor norte e nordeste da ALB, associado a temperaturas médias relativamente mais amenas e menor variabilidade sazonal, possivelmente relacionadas à elevada nebulosidade e à atuação frequente de processos convectivos tropicais. O Grupo 3, concentrado na região central-norte, destacou-se por apresentar os maiores valores médios de temperatura ao longo do ano, refletindo um regime térmico mais uniforme e próximo ao equatorial. O Grupo 4 corresponde a uma região de transição entre áreas amazônicas e continentais, exibindo comportamento térmico intermediário. O Grupo 5,

localizado no sul da ALB, caracterizou-se por apresentar os menores valores médios de temperatura e maior variabilidade sazonal, evidenciando a influência de incursões de ar frio e episódios de friagem durante o inverno. Por fim, o Grupo 6, situado na faixa leste do domínio, sofreu forte influência oceânica, resultando em amortecimento térmico e em máximos mais pronunciados durante a primavera.

O comportamento sazonal de cada cluster é detalhado no ciclo anual médio de temperatura apresentado na Figura 38. Todos os grupos exibem um padrão sazonal coerente, com mínimos térmicos concentrados nos meses de junho e julho e máximos entre setembro e outubro. O Grupo 5 apresentou a maior queda de temperatura durante o inverno austral, com valores significativamente inferiores aos demais grupos, confirmando sua elevada sensibilidade à atuação de friagens e sistemas frontais que ocasionalmente avançam sobre o sul da ALB. Em contraste, o Grupo 3 manteve os maiores valores médios ao longo de todo o ano e apresenta a menor amplitude térmica sazonal, característica típica de regiões equatoriais. O Grupo 6 apresentou um pico térmico mais tardio e suavizado, enquanto os Grupos 1, 2 e 4 exibiram comportamentos intermediários, refletindo a transição entre regimes continentais e tropicais.


De forma conjunta, as Figuras 36 a 38 demonstraram que a análise de cluster foi capaz de segmentar a ALB em regiões termicamente homogêneas e fisicamente coerentes, capturando os principais gradientes climáticos do domínio. Essa regionalização reduziu a heterogeneidade interna das áreas de análise e forneceu uma base espacial robusta para a avaliação do desempenho das simulações climáticas e da eficácia das técnicas de correção de viés. Ao dividir o a área de estudo em regiões climaticamente semelhantes, reduziu-se a mistura de comportamentos distintos e criou-se uma base mais adequada para as análises seguintes, como a avaliação do desempenho médio por meio do Diagrama de Taylor e a análise de extremos térmicos.

Figura 36a e 36b: Determinação e estruturação dos grupos termicamente homogêneos na ALB. (a) Curva do método do cotovelo (*Elbow Method*), baseada na soma dos quadrados intra-clusters, utilizada para a definição do número ótimo de agrupamentos. (b) Dendrograma hierárquico obtido a partir da distância euclidiana entre as estações, evidenciando a formação de seis grupos termicamente homogêneos.




Fonte: Autor (2025).

Figura 37: Distribuição espacial dos grupos termicamente homogêneos na ALB, obtidos por meio da análise de clusters aplicada às séries de temperatura média.



Fonte: Autor (2025).

Figura 38: Ciclo anual da temperatura média nos grupos termicamente homogêneos da ALB.



Fonte: Autor (2025).

5.18 Análise Diagrama de Taylor

5.18.1 Diagrama de Taylor – Temperatura Mínima

O desempenho das simulações de temperatura mínima foi avaliado por meio do Diagrama de Taylor para cada um dos seis grupos termicamente homogêneos definidos anteriormente (Figura 39a–f), permitindo comparar, de forma integrada, a correlação, o desvio padrão e o erro centrado das simulações do modelo global MPI, da regionalização (REG) e das versões corrigidas pelos métodos ACC e RCP, em relação às observações.

No Grupo 1 (Figura 39a), observou-se que o MPI apresentou baixa correlação e superestimou a variabilidade da temperatura mínima, afastando-se significativamente do ponto de referência. A regionalização com o REG melhorou parcialmente a correlação, mas ainda mantém discrepâncias no desvio padrão. Após a aplicação das correções, especialmente da RCP, os resultados se aproximaram mais das observações, indicando redução do erro e melhor representação da variabilidade térmica mínima.

Para o Grupo 2 (Figura 39b), o MPI novamente apresentou desempenho inferior, com correlação moderada e desvio padrão elevado. O REG mostrou avanço em relação ao modelo global, sobretudo na correlação. As correções ACC e RCP promoveram melhorias adicionais, com maior proximidade do ponto de referência, sendo a RCP ligeiramente superior na redução do erro associado à temperatura mínima.

No Grupo 3 (Figura 39c), caracterizado por menor variabilidade sazonal, o MPI apresentou baixa correlação e elevada dispersão. A regionalização melhorou o desempenho médio, mas ainda não reproduziu adequadamente a variabilidade observada. As versões corrigidas, principalmente REG-RCP, apresentaram melhor equilíbrio entre correlação e desvio padrão, indicando maior consistência na simulação da temperatura mínima nesse grupo.

O Grupo 4 (Figura 39d) apresentou um dos melhores desempenhos do REG entre os grupos, com correlação relativamente elevada em relação às observações. Ainda assim, notou-se que o desvio padrão permaneceu superestimado. A aplicação das correções ACC e RCP resultou em maior aproximação do ponto de referência, evidenciando ganhos claros na representação da temperatura mínima, sobretudo após a correção aplicada ao REG.

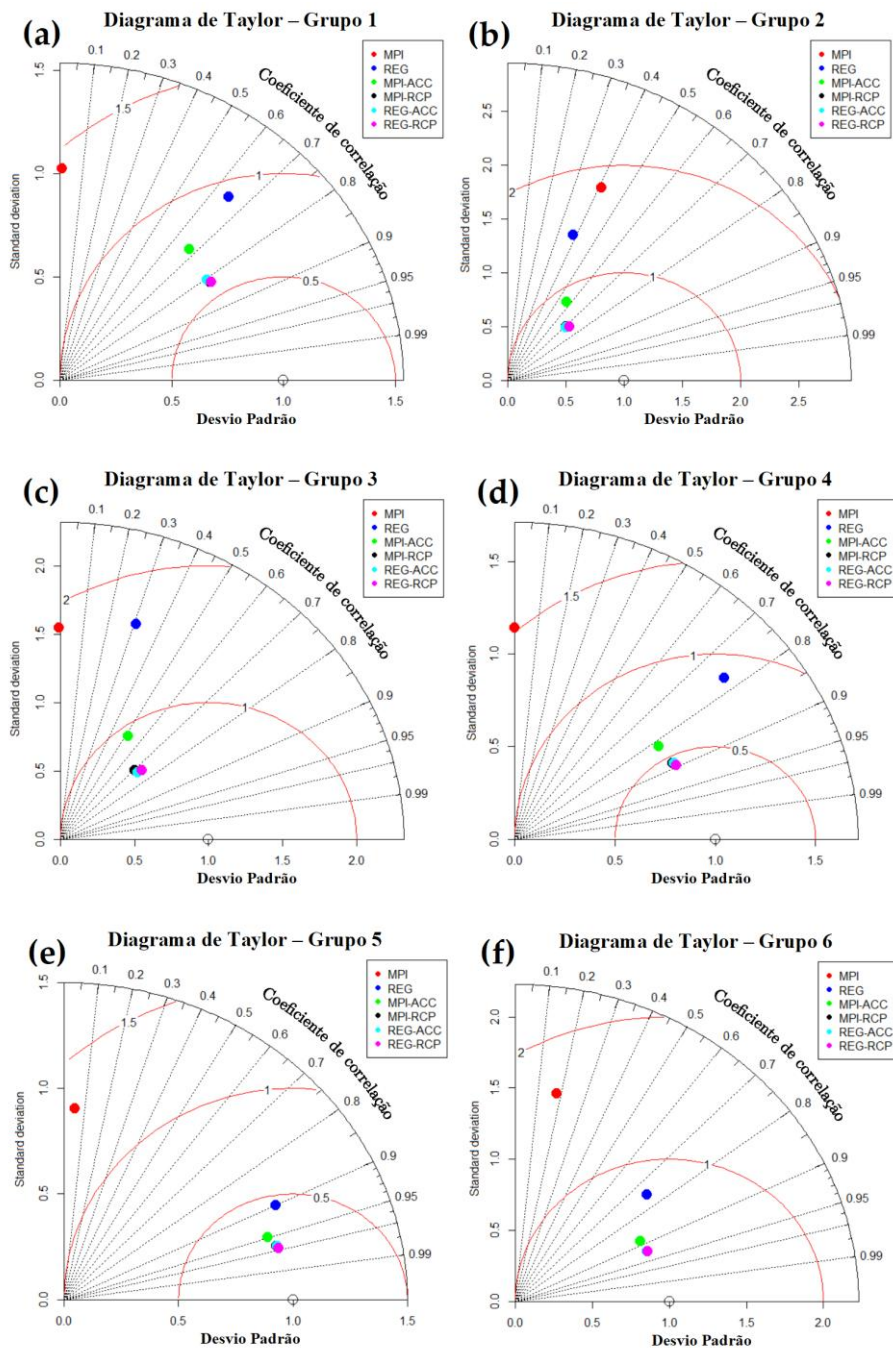
No Grupo 5 (Figura 39e), que corresponde à região mais sensível à atuação de friagens, o MPI apresentou desempenho limitado, com baixa correlação e elevada discrepância na variabilidade. O REG melhorou a correlação, mas ainda apresentou dificuldades em representar adequadamente os mínimos térmicos. As correções, especialmente a RCP, resultaram em avanços mais expressivos, indicando melhor capacidade de capturar os padrões observados de temperatura mínima nesse grupo.

Por fim, no Grupo 6 (Figura 39f), associado à forte influência oceânica, observou-se que o MPI apresentou desempenho insatisfatório, enquanto o REG apresentou ganhos moderados. As simulações corrigidas, sobretudo REG-RCP, mostraram maior proximidade do ponto de referência, com melhor ajuste tanto da correlação quanto do desvio padrão, refletindo uma representação mais realista da temperatura mínima.

De forma geral, os Diagramas de Taylor para a temperatura mínima (Figura 39a–f) indicaram que a regionalização já representou um avanço em relação ao modelo global

MPI, mas que a aplicação das técnicas de correção de viés, em especial a RCP, resultou em melhorias adicionais e mais consistentes.

Figura 39: Diagramas de Taylor para a avaliação do desempenho das simulações de temperatura mínima nos grupos termicamente homogêneos da ALB.



Fonte: Autor (2025).

Em complemento à avaliação visual realizada por meio dos Diagramas de Taylor, a Tabela 3 apresentou a classificação quantitativa dos experimentos para a temperatura mínima, considerando os seis grupos termicamente homogêneos. Essa classificação foi elaborada com base em um método de pontuação análogo ao utilizado em Silva et al. (2023), no qual cada experimento recebe uma pontuação relativa em cada grupo, de acordo com sua posição de desempenho na métrica avaliada. No procedimento adotado, os experimentos que apresentaram maior aproximação ao ponto de referência nos Diagramas de Taylor, ou seja, com maior correlação e menor desvio padrão em relação às observações, receberam pontuações mais altas por grupo (por exemplo, 10 pontos para a melhor colocação em um grupo, 9 para a segunda, e assim sucessivamente). Em seguida, a pontuação final de cada experimento é obtida pela média das pontuações de todos os grupos, resultando em um ranking geral que sintetiza o desempenho regional de cada configuração. Essa forma de agregação, que foi originalmente proposta no estudo citado para comparar fontes de dados climáticos por grupos geográficos, permitiu uma interpretação objetiva das diferenças entre os experimentos, minimizando a influência de variações locais isoladas e destacando os métodos com melhor habilidade geral na simulação da variável estudada.

No caso do Diagrama de Taylor (Tabela 3), observou-se que o experimento REG-RCP ocupou sistematicamente a primeira posição em todos os grupos (G1 a G6), resultando na pontuação máxima (10,0). Em seguida, destacaram-se REG-ACC e MPI-RCP, que apresentaram bom desempenho na maioria dos grupos, embora com pontuações inferiores. O MPI-ACC ocupou uma posição intermediária, enquanto os experimentos sem correção, REG e MPI, apresentaram os piores resultados, evidenciando limitações na representação conjunta da correlação e da variabilidade da temperatura mínima.

Resultados semelhantes foram observados para o KGE (Tabela 4), em que o REG-RCP novamente apresentou desempenho superior em todos os grupos, com pontuação máxima. As configurações REG-ACC e MPI-RCP manteve desempenho elevado, enquanto MPI-ACC apresentou resultados intermediários. Os experimentos sem correção permaneceram nas últimas posições, indicando menor habilidade na reprodução simultânea da variabilidade, correlação e viés da temperatura mínima.

Para a métrica de viés (Tabela 5), observou-se um comportamento ligeiramente distinto, com o MPI-ACC apresentando a melhor performance geral, ocupando a primeira posição em todos os grupos. Ainda assim, REG-ACC e REG-RCP também apresentaram

reduções expressivas do viés em relação às versões não corrigidas. Esse resultado indicou que diferentes técnicas de correção podem atuar de forma complementar, sendo particularmente eficazes na redução de erros sistemáticos associados à temperatura mínima.

A análise do MAE (Tabela 6) mostrou novamente a superioridade do REG-RCP, que apresentou a maior pontuação média geral, seguido por MPI-RCP e REG-ACC. Esse resultado reforça que a combinação entre regionalização e correção multivariada é especialmente eficiente na redução do erro absoluto médio da temperatura mínima. O MPI-ACC manteve desempenho intermediário, enquanto MPI e REG continuaram apresentando os maiores erros.

Comportamento semelhante foi observado para o RMSE (Tabela 7), no qual o REG-RCP apresentou a melhor performance geral, com pontuação máxima. As configurações REG-ACC e MPI-RCP apareceram novamente como as segundas melhores opções, enquanto os experimentos sem correção apresentaram os piores desempenhos, evidenciando maior dispersão dos erros.

A classificação final (Tabela 8), obtida a partir da média das pontuações associadas a todas as métricas avaliadas, consolidou o REG-RCP como o experimento de maior desempenho para a temperatura mínima, com pontuação geral de 9,6. Em seguida, destacaram-se REG-ACC (8,5) e MPI-RCP (8,3), seguidos por MPI-ACC (7,6). Os experimentos REG e MPI ocuparam as últimas posições, confirmando que a ausência de correção de viés comprometeu significativamente a representação da temperatura mínima.

Tabela 3: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos Diagramas de Taylor (temperatura mínima).

Diagrama de Taylor								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	10,0
2	9	MPI-RCP	REG-ACC	REG-ACC	REG-ACC	REG-ACC	REG-ACC	REG-ACC	8,8
3	8	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	8,2
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	REG	MPI	REG	REG	REG	REG	MPI	5,8

6	5	MPI	REG	MPI	MPI	MPI	MPI	REG	5,2
---	---	-----	-----	-----	-----	-----	-----	-----	-----

Fonte: Autor (2025).

Tabela 4: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no KGE (temperatura mínima).

KGE								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	10,0
2	9	MPI-RCP	REG-ACC	REG-ACC	REG-ACC	REG-ACC	MPI-RCP	REG-ACC	8,7
3	8	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	REG-ACC	MPI-RCP	8,3
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	REG	REG	REG	REG	REG	REG	REG	6,0
6	5	MPI	MPI	MPI	MPI	MPI	MPI	MPI	5,0

Fonte: Autor (2025).

Tabela 5: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos vieses (temperatura mínima).

Bias								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	10,0
2	9	REG-ACC	REG-RCP	REG-RCP	REG-ACC	REG-ACC	REG-ACC	REG-ACC	8,5
3	8	REG-RCP	MPI-RCP	REG-ACC	REG-RCP	REG-RCP	MPI-RCP	REG-RCP	8,2
4	7	MPI-RCP	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	REG-RCP	MPI-RCP	7,3
5	6	MPI	REG	MPI	MPI	MPI	MPI	MPI	5,8
6	5	REG	MPI	REG	REG	REG	REG	REG	5,2

Fonte: Autor (2025).

Tabela 6: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no MAE (temperatura mínima).

MAE								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos

1	10	REG-RCP	REG-RCP	MPI-RCP	REG-RCP	REG-RCP	MPI-RCP	REG-RCP	9,7
2	9	MPI-RCP	MPI-RCP	REG-RCP	MPI-RCP	REG-ACC	REG-RCP	REG-ACC	8,2
3	8	REG-ACC	REG-ACC	REG-ACC	REG-ACC	MPI-RCP	REG-ACC	MPI-RCP	9,2
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	MPI	REG	REG	REG	REG	MPI	REG	5,7
6	5	REG	MPI	MPI	MPI	MPI	REG	MPI	5,3

Fonte: Autor (2025).

Tabela 7: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no RMSE (temperatura mínima).

RMSE								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	10,0
2	9	MPI-RCP	REG-ACC	REG-ACC	MPI-RCP	REG-ACC	MPI-RCP	REG-ACC	8,5
3	8	REG-ACC	MPI-RCP	MPI-RCP	REG-ACC	MPI-RCP	REG-ACC	MPI-RCP	8,5
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	MPI	REG	MPI	REG	REG	REG	MPI	5,3
6	5	REG	MPI	REG	MPI	MPI	MPI	REG	5,7

Fonte: Autor (2025).

Tabela 8: Ranking com a classificação final do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB (temperatura mínima).

CLASSIFICAÇÃO FINAL								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	9,6
2	9	REG-ACC	REG-ACC	MPI-RCP	REG-ACC	REG-ACC	REG-ACC	REG-ACC	8,5
3	8	MPI-RCP	MPI-RCP	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	8,3
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,6
5	6	REG	MPI	MPI	REG	REG	REG	REG	5,3
6	5	MPI	REG	REG	MPI	MPI	MPI	MPI	5,7

De forma geral, esses resultados demonstram que a superioridade do REG-RCP não se restringe a uma métrica específica ou a um único grupo homogêneo, mas reflete um ganho consistente e robusto na representação da temperatura mínima em toda a ALB.

5.18.2 Diagrama de Taylor – Temperatura Máxima

No Grupo 1 (Figura 40a), o MPI apresentou correlação moderada e superestimou a variabilidade da temperatura máxima. A regionalização com o REG melhorou a correlação, porém ainda mantém discrepâncias no desvio padrão. A aplicação das correções ACC e RCP resultou em maior aproximação do ponto de referência, com destaque para a RCP, que apresentou melhor equilíbrio entre correlação e variabilidade.

Para o Grupo 2 (Figura 40b), observa-se que o MPI apresenta desempenho limitado, com correlação moderada e desvio padrão elevado. O REG melhora o desempenho em relação ao modelo global, especialmente na correlação. As simulações corrigidas mostram avanços adicionais, aproximando-se mais das observações, sendo a RCP novamente a técnica que apresenta melhor ajuste geral.

No Grupo 3 (Figura 40c), caracterizado por temperaturas mais elevadas e menor variabilidade sazonal, o MPI apresentou baixa correlação e elevada dispersão. A regionalização melhorou parcialmente o desempenho, enquanto as correções ACC e RCP promoveram uma redução mais significativa do erro. O conjunto REG-RCP destacou-se por apresentar maior proximidade do ponto de referência, indicando melhor representação da temperatura máxima nesse grupo.

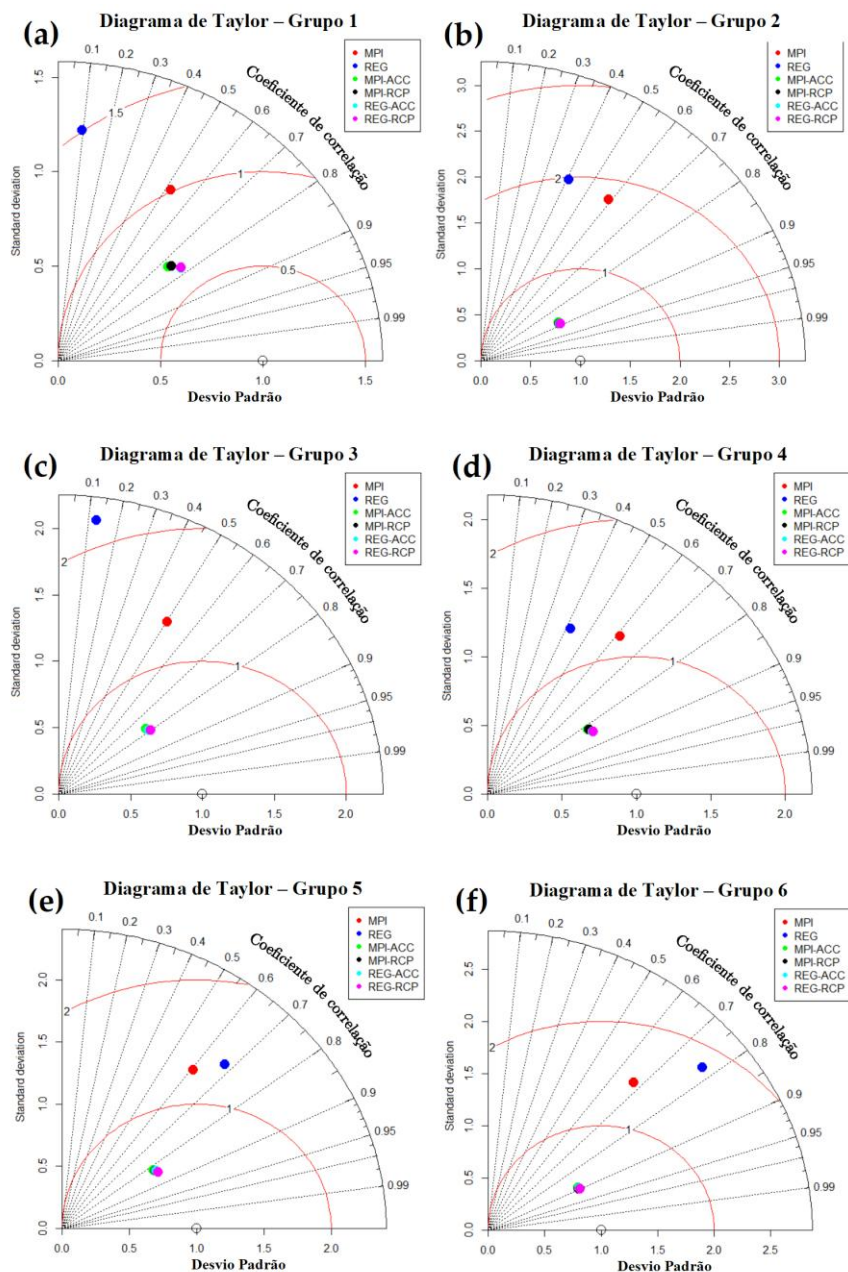
No Grupo 4 (Figura 40d), o REG apresentou desempenho relativamente superior ao MPI, com aumento da correlação em relação às observações. Ainda assim, persistiram diferenças no desvio padrão. A aplicação das correções resultou em melhorias adicionais, com as simulações corrigidas se posicionando mais próximas do ponto de referência, evidenciando ganho na representação da temperatura máxima.

Para o Grupo 5 (Figura 40e), que corresponde a uma região com maior variabilidade térmica, o MPI apresentou desempenho insatisfatório, com baixa correlação e superestimação da variabilidade. O REG melhorou parcialmente a correlação, enquanto as correções ACC e RCP reduziram de forma mais efetiva o erro. A RCP novamente apresentou o melhor ajuste, com maior proximidade do ponto de referência.

Por fim, no Grupo 6 (Figura 40f), associado à forte influência oceânica, observou-se que o MPI apresentou correlação moderada e elevada discrepância no desvio padrão. O REG melhorou a correlação, mas ainda não representou adequadamente a variabilidade observada. As versões corrigidas, especialmente REG-RCP, mostraram melhor desempenho geral, com redução simultânea do erro e melhor ajuste da variabilidade da temperatura máxima.

De forma geral, os Diagramas de Taylor para a temperatura máxima (Figura 40a-f) indicaram que a regionalização representou um avanço consistente em relação ao modelo global MPI, sobretudo no aumento da correlação com as observações. No entanto, a aplicação das técnicas de correção de viés, especialmente a RCP, resultou em melhorias adicionais e mais homogêneas entre os diferentes grupos.

Figura 40: Diagramas de Taylor para a avaliação do desempenho das simulações de temperatura máxima nos grupos termicamente homogêneos da ALB.



Fonte: Autor (2025).

De forma igual ao procedimento adotado para a temperatura mínima, os resultados dos Diagramas de Taylor da temperatura máxima são sintetizados nas tabelas de classificação por grupos homogêneos.

No que se refere ao Diagrama de Taylor (Tabela 9), o experimento REG-RCP apresentou o melhor desempenho geral, com pontuação média de 9,8, ocupando a primeira posição na maioria dos grupos. Em seguida, destacaram-se REG-ACC e MPI-RCP, que também apresentaram bom ajuste, porém com desempenho ligeiramente

inferior. O MPI-ACC manteve posição intermediária, enquanto os experimentos sem correção (MPI e REG) concentraram-se nas últimas posições, indicando menor capacidade de reproduzir simultaneamente a correlação e a variabilidade da temperatura máxima.

Resultados semelhantes são observados para o KGE (Tabela 10), no qual o REG-RCP novamente ocupou a primeira posição em todos os grupos, atingindo a pontuação máxima (10,0). As configurações REG-ACC e MPI-RCP apareceram logo em seguida, confirmando ganhos consistentes em relação às versões não corrigidas. Esse comportamento indica que a combinação entre regionalização e correção multivariada melhora de forma significativa a coerência estatística da temperatura máxima.

Na análise do viés (Tabela 11), observou-se um desempenho bastante próximo entre REG-RCP e REG-ACC, ambos com pontuação média elevada (9,5), indicando forte redução dos erros sistemáticos associados à temperatura máxima. O MPI-RCP apresentou desempenho intermediário, enquanto o MPI-ACC mostrou ganhos mais modestos. Os experimentos sem correção permaneceram com os maiores desvios médios, sobretudo nos grupos com maior variabilidade térmica.

Para as métricas MAE (Tabela 12) e RMSE (Tabela 13), o REG-RCP voltou a se destacar de forma consistente, alcançando a maior pontuação média geral em ambas as métricas. REG-ACC e MPI-RCP manteve desempenho semelhante e ocupou as posições subsequentes, reforçando que as técnicas de correção de viés são eficazes na redução dos erros associados à temperatura máxima. O MPI-ACC apresentou desempenho intermediário, enquanto MPI e REG continuaram apresentando os maiores erros.

A classificação final (Tabela 14) consolidou o REG-RCP como o experimento de melhor desempenho para a temperatura máxima, com pontuação geral de 9,9. Em seguida, destacaram-se REG-ACC (8,9) e MPI-RCP (8,2), seguidos por MPI-ACC (7,0). Os experimentos REG e MPI permaneceram nas últimas posições, confirmando que a ausência de correção de viés compromete a representação adequada da temperatura máxima.

Tabela 9: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos Diagramas de Taylor (temperatura máxima).

Diagrama de Taylor	Ranking
--------------------	---------

Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-ACC	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	9,8
2	9	REG-RCP	REG-ACC	MPI-RCP	REG-ACC	REG-ACC	REG-ACC	REG-ACC	9,0
3	8	MPI-RCP	MPI-RCP	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	8,2
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	MPI	MPI	MPI	MPI	REG	REG	MPI	5,7
6	5	REG	REG	REG	REG	MPI	MPI	REG	5,3

Fonte: Autor (2025).

Tabela 10: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no KGE (temperatura máxima).

KGE								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	10,0
2	9	REG-ACC	REG-ACC	MPI-RCP	REG-ACC	REG-ACC	REG-ACC	REG-ACC	8,8
3	8	MPI-RCP	MPI-RCP	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	8,2
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	MPI	REG	MPI	MPI	MPI	MPI	MPI	5,8
6	5	REG	MPI	REG	REG	REG	REG	REG	5,2

Fonte: Autor (2025).

Tabela 11: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base nos vieses (temperatura máxima).

Bias								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-ACC	REG-RCP	REG-ACC	REG-ACC	REG-RCP	REG-RCP	9,5
2	9	REG-ACC	REG-RCP	REG-ACC	REG-RCP	REG-RCP	REG-ACC	REG-ACC	9,5
3	8	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	MPI-ACC	MPI-RCP	7,8
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-RCP	MPI-ACC	7,2
5	6	REG	MPI	MPI	REG	REG	REG	REG	5,7
6	5	MPI	REG	REG	MPI	MPI	MPI	MPI	5,3

Fonte: Autor (2025).

Tabela 12: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no MAE (temperatura máxima).

MAE								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	10,0
2	9	REG-ACC	MPI-RCP	MPI-RCP	REG-ACC	REG-ACC	MPI-RCP	REG-ACC	8,5
3	8	MPI-RCP	REG-ACC	REG-ACC	MPI-RCP	MPI-RCP	REG-ACC	MPI-RCP	8,5
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	REG	MPI	MPI	REG	REG	REG	REG	5,7
6	5	MPI	REG	REG	MPI	MPI	MPI	MPI	5,3

Fonte: Autor (2025).

Tabela 13: Ranking do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB, com base no RMSE (temperatura máxima).

RMSE								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	10,0
2	9	REG-ACC	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	REG-ACC	REG-ACC	8,5
3	8	MPI-RCP	MPI-RCP	REG-ACC	REG-ACC	REG-ACC	MPI-RCP	MPI-RCP	8,5
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	REG	MPI	MPI	REG	REG	MPI	MPI	5,5
6	5	MPI	REG	REG	MPI	MPI	REG	REG	5,5

Fonte: Autor (2025).

Tabela 14: Ranking com a classificação final do desempenho dos modelos climáticos nos grupos termicamente homogêneos da ALB (temperatura máxima).

CLASSIFICAÇÃO FINAL								Ranking	
Ranking	Pontos	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Grupo 6 (G6)	Modelo	Pontos
1	10	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	REG-RCP	9,9
2	9	REG-ACC	REG-ACC	MPI-RCP	REG-ACC	REG-ACC	REG-ACC	REG-ACC	8,9
3	8	MPI-RCP	MPI-RCP	REG-ACC	MPI-RCP	MPI-RCP	MPI-RCP	MPI-RCP	8,2
4	7	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	MPI-ACC	7,0
5	6	REG	MPI	MPI	REG	REG	REG	REG	5,5

6	5	MPI	REG	REG	MPI	MPI	MPI	MPI	5,5
---	---	-----	-----	-----	-----	-----	-----	-----	-----

Fonte: Autor (2025).


De forma geral, os resultados indicaram que, assim como observado para a temperatura mínima, a superioridade do REG-RCP para a temperatura máxima foi robusta e consistente entre os diferentes grupos homogêneos e métricas avaliadas. Isso evidencia que a combinação entre regionalização dinâmica e correção multivariada de viés é fundamental para aprimorar a simulação da variabilidade térmica na ALB.

5.19 Análise da Tendência de Eventos Extremos

A análise das tendências dos índices de extremos climáticos no período de 1981 a 2012, organizada por grupos espaciais, revelou um padrão robusto e coerente de aquecimento, caracterizado principalmente pela diminuição dos extremos frios e pela intensificação dos extremos quentes, com maior destaque para os eventos noturnos. O símbolo (*) associado às barras indicou que a tendência estimada foi estatisticamente significativa, ao nível de 5% ($p < 0,05$), o que confere elevada confiança de que a variação observada representou uma mudança climática real e não apenas flutuações naturais de curto prazo.

No Grupo 1 (figura 41), as observações mostraram uma redução significativa da persistência de eventos frios, evidenciada pelas tendências negativas de CSDI e TN10p, ambas estatisticamente significativas. Esse comportamento sugeriu uma diminuição tanto na frequência quanto na duração de períodos frios, refletindo um enfraquecimento progressivo dos mecanismos responsáveis pelo resfriamento noturno. Em paralelo, observou-se um aumento consistente e significativo dos índices associados a extremos quentes, como TN90p, TR20, TX90p e WSDI. Esse conjunto de sinais indica não apenas mais dias e noites quentes, mas também maior persistência desses eventos, o que possui implicações diretas para o conforto térmico e a saúde humana. O MPI sem correção tendeu a superestimar essas tendências, enquanto a regionalização reduziu parcialmente esse viés. A aplicação da RCP, sobretudo no REG-RCP, permitiu um ajuste mais realista, preservando a significância estatística observada e alinhando melhor as magnitudes simuladas às observações.


Figura 41: Tendências dos índices de extremos climáticos de temperatura no Grupo 1 da ALB, no período de 1981–2012.



Fonte: Autor (2025).

No Grupo 2 (figura 42), o sinal de aquecimento foi particularmente intenso e estatisticamente robusto. As observações indicaram reduções acentuadas e significativas em CSDI e TN10p, ao mesmo tempo em que se observou um aumento expressivo em TN90p, TR20, TX90p e WSDI, com algumas tendências superiores a 1 dia por ano. A presença sistemática de (*) nesses índices evidenciou que as mudanças foram persistentes e especialmente coerentes. O MPI apresentou tendências excessivamente intensas, sobretudo para os extremos frios, sugerindo sensibilidade exagerada ao aquecimento. O REG melhorou a representação, mas foi o REG-RCP que melhor reproduziu o equilíbrio observado entre a redução de extremos frios e o aumento de extremos quentes, mantendo o sinal estatístico e evitando amplificações artificiais.


Figura 42: Tendências dos índices de extremos climáticos de temperatura no Grupo 2 da ALB, no período de 1981–2012.



Fonte: Autor (2025).

O Grupo 3 (figura 43) também apresentou um contraste marcante entre a diminuição de extremos frios e o aumento de extremos quentes. As tendências negativas significativas em CSDI e TN10p indicaram redução clara de noites frias, enquanto os aumentos significativos de TN90p, TX90p e WSDI revelaram maior frequência e persistência de eventos quentes. Um aspecto relevante nesse grupo foi o aumento significativo de TR20, indicando crescimento do número de noites tropicais, o que aponta para um aquecimento noturno particularmente pronunciado. Novamente, o MPI tendeu a exagerar os sinais, enquanto o REG-RCP se destacou por representar com maior fidelidade tanto a magnitude quanto a significância estatística das tendências observadas.


Figura 43: Tendências dos índices de extremos climáticos de temperatura no Grupo 3 da ALB, no período de 1981–2012.



Fonte: Autor (2025).

No Grupo 4 (Figura 44), o aquecimento foi amplo e consistente em praticamente todos os índices analisados. As observações mostraram redução significativa de TN10p e CSDI, acompanhada por aumentos significativos em TN90p, TR20, TX90p e WSDI. A presença generalizada de (*) indicou que esse grupo experimentou uma reorganização da distribuição térmica, com deslocamento claro em direção a temperaturas mais elevadas. A regionalização dinâmica já melhorou a representação desses sinais em relação ao MPI, mas a aplicação da RCP resultou em ganhos adicionais, permitindo ao REG-RCP capturar com maior precisão o ritmo e a intensidade das mudanças observadas.


Figura 44: Tendências dos índices de extremos climáticos de temperatura no Grupo 4 da ALB, no período de 1981–2012.



Fonte: Autor (2025).

No Grupo 5 (Figura 45), embora as tendências observadas sejam ligeiramente menos intensas do que nos Grupos 2, 3 e 4, o padrão geral de aquecimento permaneceu evidente. A redução significativa de TN10p e o aumento significativo de TN90p, TR20, TX90p e WSDI confirmaram a diminuição de extremos frios e a intensificação de extremos quentes. Nesse grupo, observou-se que o REG-RCP pode intensificar a tendência negativa de TN10p em relação às observações, sugerindo que a correção multivariada, embora eficaz, pode amplificar sinais locais em regiões de maior variabilidade climática. Ainda assim, o sinal permaneceu coerente e estatisticamente consistente.


Figura 45: Tendências dos índices de extremos climáticos de temperatura no Grupo 5 da ALB, no período de 1981–2012.



Fonte: Autor (2025).

Por fim, o Grupo 6 (figura 46) apresentou um dos sinais mais fortes de aquecimento noturno entre todos os grupos. As observações indicaram reduções significativas e expressivas em CSDI e TN10p, acompanhadas por aumentos acentuados em TN90p e TR20, ambos com forte significância estatística. O crescimento de TX90p e WSDI reforçou a intensificação tanto da frequência quanto da persistência de eventos quentes. O MPI sem correção exagerou esse comportamento, enquanto o REG apresentou melhora parcial. O REG-RCP, por sua vez, reproduziu de forma mais equilibrada as tendências observadas, especialmente para os índices noturnos, preservando a significância estatística e reduzindo os vieses sistemáticos.

Figura 46: Tendências dos índices de extremos climáticos de temperatura no Grupo 6 da ALB, no período de 1981–2012.



Fonte: Autor (2025)

De forma integrada, observou-se que as tendências estatisticamente mais consistentes concentraram-se nos índices associados à temperatura mínima, como TN10p, TN90p e TR20, evidenciando que o aquecimento noturno constituiu um dos principais sinais da mudança climática regional no período analisado. Em contraste, índices relacionados a extremos absolutos, como DTR, TXN e TNN, apresentaram menor robustez estatística, o que indica maior variabilidade interanual e sensibilidade a processos locais, como condições de nebulosidade, circulação de mesoescala e heterogeneidades de superfície, tornando essas métricas menos estáveis no longo prazo.

Em resumo, os resultados demonstraram que o aquecimento observado entre 1981 e 2012 não se limitou ao aumento das médias térmicas, mas se manifestou de forma clara e estatisticamente significativa nos extremos climáticos, sobretudo noturnos. A

regionalização dinâmica associada à correção multivariada por RCP (REG-RCP) surgiu como a abordagem mais robusta para reproduzir essas mudanças, fornecendo uma base confiável para estudos de impactos, adaptação climática e avaliação de riscos associados ao aumento de extremos térmicos.

6. Conclusões

Foi avaliado o desempenho das simulações históricas de temperatura máxima e mínima geradas pelo modelo climático global MPI e por sua regionalização com o modelo regional (REG) para a ALB, no período de 1981 a 2012, bem como a eficácia dos métodos multivariados de correção de viés ACC e RCP na redução dos erros sistemáticos associados a essas simulações.

De forma geral, os resultados evidenciaram que o modelo global MPI apresentou limitações significativas na representação da variabilidade espacial e temporal da temperatura sobre a ALB, especialmente em regiões caracterizadas pela intensa interação superfície-atmosfera. Essas limitações manifestaram-se tanto na superestimação da temperatura máxima, em porções do norte da área de estudo, quanto na dificuldade em reproduzir os valores mais baixos da temperatura mínima no sul da ALB, suavizando gradientes térmicos regionais e subestimando a intensidade de eventos frios associados às friagens.

A regionalização dinâmica por meio do REG proporcionou avanços relevantes na representação espacial das variáveis térmicas, reduzindo parcialmente os erros médios e melhorando a coerência dos padrões regionais. Entretanto, os resultados também demonstraram que a regionalização, por si só, não é suficiente para eliminar os vieses sistemáticos, os quais permanecem associados, principalmente, à representação do balanço de energia à superfície, da umidade do solo, da cobertura vegetal e dos processos convectivos, sobretudo em períodos de elevada atividade atmosférica.

Nesse contexto, a aplicação dos métodos estatísticos de correção de viés mostrou-se fundamental. Tanto o ACC quanto o RCP promoveram reduções consistentes nos valores de MAE, RMSE e aumentos nos coeficientes de correlação e nos índices de eficiência (KGE), indicando melhorias significativas na concordância entre as simulações e os dados observados. De modo geral, o método RCP apresentou desempenho superior, com maior ampliação das áreas classificadas como “muito bom” e “excelente”, especialmente para a temperatura mínima e durante os meses de transição sazonal, quando os erros tendem a ser mais pronunciados.

As análises semestrais reforçaram a dependência sazonal do desempenho dos modelos, evidenciando maiores erros no primeiro semestre do ano, período marcado pela

atuação da ZCIT e por elevada variabilidade térmica associada a sistemas convectivos. Já no segundo semestre, observou-se uma redução relativa dos erros, embora persistam discrepâncias regionais, particularmente nas áreas de transição entre floresta, cerrado e regiões sob forte influência antrópica.

A avaliação dos extremos térmicos indicou que os vieses presentes nas simulações médias também se refletem nos índices de extremos, afetando a frequência e a intensidade de eventos quentes e frios. A aplicação das correções de viés contribuiu para uma melhor representação desses extremos, reduzindo distorções na ocorrência de noites quentes, dias extremamente quentes e na amplitude térmica diária, o que é especialmente relevante para estudos de impactos climáticos.

Por fim, a análise integrada por meio de técnicas de clusterização e diagramas de Taylor, confirmou o ganho progressivo de desempenho entre as diferentes configurações avaliadas, com destaque para as simulações regionalizadas e corrigidas, que apresentaram maior similaridade estatística em relação às observações, reforçando a importância da combinação entre regionalização dinâmica e correção estatística de viés como estratégia robusta para a melhoria da qualidade das simulações climáticas na ALB.

Dessa forma, concluiu-se que, embora persistam desafios associados à complexidade climática da ALB, a abordagem adotada neste trabalho representou um avanço significativo na redução de erros sistemáticos em simulações de temperatura, fornecendo uma base mais confiável para aplicações futuras em estudos de variabilidade climática, extremos e impactos ambientais na região.

7. Referências Bibliográficas

- A. J. Komkoua Mbienda, Guenang, G. M., S. Kaissassou, Tanessong, R. S., Choumbou, P. C., & Giorgi, F. (2023). Enhancement of RegCM4.7-CLM precipitation and temperature by improved bias correction methods over Central Africa. **Meteorological Applications**, 30(1). <https://doi.org/10.1002/met.2116>
- Abatzoglou, J. T., & Brown, T. J. (2011). A comparison of statistical downscaling methods suited for wildfire applications. **International Journal of Climatology**, 32(5), 772–780. <https://doi.org/10.1002/joc.2312>
- Adam, O., Bischoff, T., & Schneider, T. (2016). Seasonal and Interannual Variations of the Energy Flux Equator and ITCZ. Part I: Zonally Averaged ITCZ Position. **Journal of Climate**, 29(9), 3219–3230. <https://doi.org/10.1175/jcli-d-15-0512.1>
- Adeyeri, O. E., Zhou, W., Wang, X., Zhang, R., Laux, P., Ishola, K. A., & Usman, M. (2022). The trend and spatial spread of multisectoral climate extremes in CMIP6 models. **Scientific Reports**, 12(1). <https://doi.org/10.1038/s41598-022-25265-4>
- Agarwal, A., Shah, D., Shen, D., & Song, D. (2021). On Robustness of Principal Component Regression. *Journal of the American Statistical Association*, 116(536), 1731–1745. <https://doi.org/10.1080/01621459.2021.1928513>
- Albert, J., Carnaval, A., Flantua, S., Lohmann, L., Ribas, C., Riff, D., Carrillo, J., Fan, Y., Figueiredo, J., Guayasamin, J., Hoorn, C., De Melo, G., Nascimento, N., Quesada, C., Ulloa, C., Val, P., Arieira, J., Encalada, A., & Nobre, C. (2023). Human impacts outpace natural processes in the Amazon. **Science**, 379. <https://doi.org/10.1126/science.abo5003>
- Albright, R., Corbett, A., Jiang, X., Creecy, E., Newman, S., Li, K., Liang, M., & Yung, Y. L. (2021). Seasonal Variations of Solar-Induced Fluorescence, Precipitation, and Carbon Dioxide Over the Amazon. **Earth and Space Science**, 9(1), e2021EA002078–e2021EA002078. <https://doi.org/10.1029/2021ea002078>
- Almada, H., Macedo, M., Lenza, E., Maracahipes, L., & Silvério, D. (2024). Indigenous lands and conservation units slow down non-GHG climate change in the Cerrado-Amazon ecotone. **Perspectives in Ecology and Conservation**. <https://doi.org/10.1016/j.pecon.2024.03.002>
- Almeida, C., Oliveira-Júnior, J., Delgado, R., Cubo, P., & Ramos, M. (2017). Spatiotemporal rainfall and temperature trends throughout the Brazilian Legal Amazon, 1973–2013. **International Journal of Climatology**, 37. <https://doi.org/10.1002/joc.4831>

- Almazroui, M. (2012). Dynamical downscaling of rainfall and temperature over the Arabian Peninsula using RegCM4. **Climate Research**, 52, 49–62. <https://doi.org/10.3354/cr01073>
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., de Moraes Gonçalves, J. L., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, 22, 711-728.
- Alves de Oliveira, B. F., Bottino, M. J., Nobre, P., & Nobre, C. A. (2021). Deforestation and climate change are projected to increase heat stress risk in the Brazilian Amazon. **Communications Earth & Environment**, 2, 1–8. <https://doi.org/10.1038/s43247-021-00275-8>
- Amaral e Silva, A. et al. (2020). Anthropic activities and the Legal Amazon: Estimative of impacts on forest and regional climate for 2030. **Remote Sensing Applications: Society and Environment**, 18, 100304. <https://doi.org/10.1016/j.rsase.2020.100304>
- Anwar, S. A., & Mostafa, S. M. (2023). Assessment of the Sensitivity of Daily Maximum and Minimum Air Temperatures of Egypt to Soil Moisture Status and Land Surface Parameterization Using RegCM4. **DOAJ (DOAJ: Directory of Open Access Journals)**, 115–115. <https://doi.org/10.3390/asec2023-15353>
- Anwar, S. A., Reboita, M. S., & Llopart, M. (2021). On the sensitivity of the Amazon surface climate to two land-surface hydrology schemes using a high-resolution regional climate model (RegCM4). **International Journal of Climatology**. <https://doi.org/10.1002/joc.7367>
- Arakawa, A. (2004). The Cumulus Parameterization Problem: Past, Present, and Future. **Journal of Climate**. https://journals.ametsoc.org/view/journals/clim/17/13/1520-0442_2004_017_2493_tcp_ppa_2.0.co_2.xml
- Artaxo, P. (2023). Amazon deforestation implications in local/regional climate change. **Proceedings of the National Academy of Sciences of the United States of America**, 120(50). <https://doi.org/10.1073/pnas.2317456120>
- Artaxo, P., Fonseca de Almeida-Val, V. M., Bilbao, B., Brando, P. M., Bustamante, M., Coe, M. T., Correa, S. B., Cuesta, F., Costa, M. H., Miralles-Wilhem, F., Salinas, N., Silvério, D. V., & Val, A. L. (2021). Chapter 23: Impacts of deforestation and climate change on biodiversity, ecological processes, and environmental adaptation. **Amazon Assessment Report 2021**. <https://doi.org/10.55161/vkmm1905>
- Artaxo, P., Rizzo, L. V., Brito, J. F., Barbosa, H. M. J., Arana, A., Sena, E. T., Cirino, G. G., Bastos, W., Martin, S. T., & Andreae, M. O. (2013). Atmospheric aerosols in

- Amazonia and land use change: from natural biogenic to biomass burning conditions. **Faraday Discussions**, 165, 203. <https://doi.org/10.1039/c3fd00052d>
- Azevedo, C. A. (2015). **Análise de Correlação Canônica**. Universidade Estadual de Campinas (UNICAMP). Material didático, 2015. [PDF] https://www.ime.unicamp.br/~cnaber/aula_ACC_Ana_Multi_2S_2015.pdf
- Baccini, A., Goetz, S. J., Walker, W., Laporte, N. T., Sun, M., Sulla-Menashe, D., ... & Houghton, R. A. (2012). Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, 2(3), 182-185. <https://www.nature.com/articles/nclimate1354>
- Baccini, A., Walker, W., Carvalho, L., Farina, M., et al. (2017). Tropical forests are a net carbon source based on aboveground measurements of gain and loss. **Science**, 358(6360), 230-234. <https://www.science.org/doi/10.1126/science.aam5962>
- Baker, J. C. A., Garcia-Carreras, L., Gloor, M., Marsham, J. H., Buermann, W., da Rocha, H. R., Nobre, A. D., de Araujo, A. C., & Spracklen, D. V. (2021). Evapotranspiration in the Amazon: spatial patterns, seasonality, and recent trends in observations, reanalysis, and climate models. **Hydrology and Earth System Sciences**, 25(4), 2279–2300. <https://doi.org/10.5194/hess-25-2279-2021>
- Ban, N., Cécile Caillaud, Coppola, E., Emanuela Pichelli, Sobolowski, S., Adinolfi, M., Ahrens, B., Alias, A., Anders, I., Bastin, S., Danijel Belušić, Ségolène Berthou, Brisson, E., Cardoso, R. M., Chan, S., Christensen, O., Jesús Fernández Fernández, L. Fita, Frisius, T., & Goran Gašparac. (2021). The first multi-model ensemble of regional climate simulations at kilometer-scale resolution, part I: evaluation of precipitation. **Climate Dynamics**, 57(1-2), 275–302. <https://doi.org/10.1007/s00382-021-05708-w>
- Barnston, A. G., & Tippett, M. K. (2017). Do Statistical Pattern Corrections Improve Seasonal Climate Predictions in the North American Multimodel Ensemble Models? **Journal of Climate**, 30(20), 8335–8355. <https://doi.org/10.1175/jcli-d-17-0054.1>,
- Barona, E., et al. (2010). The role of pasture and soybean in deforestation of the Brazilian Amazon. **Environmental Research Letters**, 5(2), 024002. <https://iopscience.iop.org/article/10.1088/1748-9326/5/2/024002>
- Bellouin, N., et al. (2020). Aerosols and their Climate Effects. **Nature Reviews Earth & Environment**. <https://www.nature.com/articles/s43017-020-0030-0>
- Boé, J., Terray, L., Habets, F., & Martin, E. (2007). Statistical and dynamical downscaling of the Seine basin climate for hydro-meteorological studies. **International Journal of Climatology**, 27(12), 1643-1655. <https://doi.org/10.1002/joc.1602>

- Bottino, M., Nobre, P., Giarolla, E., Da Silva, M., Capistrano, V., Malagutti, M., Tamaoki, J., De Oliveira, B., & Nobre, C. (2024). Amazon savannization and climate change are projected to increase dry season length and temperature extremes over Brazil. *Scientific Reports*, 14. <https://doi.org/10.1038/s41598-024-55176-5>
- Boulton, C., Lenton, T., & Boers, N. (2021). Pronounced loss of Amazon rainforest resilience since the early 2000s. *Nature Climate Change*, 12, 271 - 278. <https://doi.org/10.1038/s41558-022-01287-8>
- Brienen, R. J. W., Phillips, O. L., Feldpausch, T. R., et al. (2015). Long-term decline of the Amazon carbon sink. *Nature*, 519(7543), 344–348. <https://www.nature.com/articles/nature14283>
- Brito, A., Veiga, J., Correia, F., Michiles, A., Capistrano, V., Chou, S., Lyra, A., & Medeiros, G. (2023). Impacts of increasing greenhouse gas concentrations and deforestation on extreme rainfall events in the Amazon basin: A multi-model ensemble-based study. *International Journal of Climatology*, 43, 5512 - 5535. <https://doi.org/10.1002/joc.8158>
- Cai, W., McPhaden, M. J., Grimm, A. M., Rodrigues, R. R., Taschetto, A. S., Garreaud, R. D., Dewitte, B., Poveda, G., Ham, Y.-G., Santoso, A., Ng, B., Anderson, W., Wang, G., Geng, T., Jo, H.-S., Marengo, J. A., Alves, L. M., Osman, M., Li, S., & Wu, L. (2020). Climate impacts of the El Niño–Southern Oscillation on South America. *Nature Reviews Earth & Environment*, 1(4), 215–231. <https://doi.org/10.1038/s43017-020-0040-3>
- Camarinha-Neto, G. F., Julia, Dias-Júnior, C. Q., Matthias Sörgel, José Henrique Cattanio, Alessandro Araújo, Wolff, S., Paulo, Rodrigo, Rizzo, L. V., & Paulo Artaxo. (2021). The friagem event in the central Amazon and its influence on micrometeorological variables and atmospheric chemistry. *Atmospheric Chemistry and Physics*, 21(1), 339–356. <https://doi.org/10.5194/acp-21-339-2021>
- Cannon, A. J., Sobie, S. R., & Murdock, T. Q. (2015). Bias Correction of GCM Precipitation by Quantile Mapping: How Well Do Methods Preserve Changes in Quantiles and Extremes? *Journal of Climate*, 28(17), 6938-6959. <https://doi.org/10.1175/JCLI-D-14-00754.1>
- Chokkavarapu, S., & Mandla, V. (2019). Bias correction in climate modeling and its importance. *Environmental Science & Policy*. <https://www.sciencedirect.com/science/article/abs/pii/S1462901119301219>
- Córdova, M., Célleri, R., & Van Delden, A. (2022). Dynamics of Precipitation Anomalies in Tropical South America. *Atmosphere*. <https://doi.org/10.3390/atmos13060972>

- Costa, D., Gomes, H., Silva, M., & Zhou, L. (2022). The most extreme heat waves in Amazonia happened under extreme dryness. **Climate Dynamics**, 1-15. <https://doi.org/10.1007/s00382-021-06134-8>
- Cox, P. M., Betts, R. A., Jones, C. D., Spall, S. A., & Totterdell, I. J. (2000). Acceleration of global warming due to carbon-cycle feedbacks in a coupled climate model. **Nature**. <https://www.nature.com/articles/35035049>
- Crank, P., Middel, A., Wagner, M., Hoots, D., Smith, M., & Brazel, A. (2020). Validation of seasonal mean radiant temperature simulations in hot arid urban climates. **The Science of the total environment**, 749, 141392 . <https://doi.org/10.1016/j.scitotenv.2020.141392>
- Cui, Z., Chen, Q., & Liu, G. (2023). A two-stage downscaling hydrological modeling approach via convolutional conditional neural process and geostatistical bias correction. **Journal of Hydrology**. <https://doi.org/10.1016/j.jhydrol.2023.129498>
- Custódio, I., Da Silva Dias, P., Wainer, I., & Prado, L. (2024). Changes in the South American Monsoon System components since the Last Glacial Maximum: a TraCE-21k perspective. **Climate Dynamics**. <https://doi.org/10.1007/s00382-024-07139-9>
- Danielsom, J.; Gesch, D. Global Multi-Resolution Terrain Elevation Data 2010 (GMTED2010) (2011). **USGS**. <https://pubs.usgs.gov/of/2011/1073/pdf/of2011-1073.pdf>.
- da Silva, H. J. F., Gonçalves, W. A., Bezerra, B. G., Santos e Silva, C. M., Oliveira, C. P. de, & Mutti, P. R. (2022). Analysis of the Influence of Deforestation on the Microphysical Parameters of Clouds in the Amazon. **Remote Sensing**, 14(21), 5353. <https://doi.org/10.3390/rs14215353>
- De Bodas Terassi, P., Galvani, E., Gobo, J., Da Silva Oscar-Júnior, A., Luiz-Silva, W., Sobral, B., De Gois, G., & Biffi, V. (2023). Exploring climate extremes in Brazil's Legal Amazon. **Stochastic Environmental Research and Risk Assessment**. <https://doi.org/10.1007/s00477-023-02634-7>
- De Cáceres, M., Martin-StPaul, N., Turco, M., Cabon, A., & Granda, V. (2018). Estimating daily meteorological data and downscaling climate models over landscapes. **Environmental Modelling & Software**, 108, 186-196. <https://doi.org/10.1016/j.envsoft.2018.08.003>
- De Souza, E. B., Carmo, A. M. C., Moares, B. C., Nacif, A., Ferreira, D. B. da S., Rocha, E. J. P., & Souza, P. J. D. O. P. (2016). SAZONALIDADE DA PRECIPITAÇÃO SOBRE A AMAZÔNIA LEGAL BRASILEIRA: CLIMA ATUAL E PROJEÇÕES FUTURAS

USANDO O MODELO REGCM4. **Revista Brasileira de Climatologia**, 18. <https://doi.org/10.5380/abclima.v18i0.43711>

Dirmeyer, P. A., Chen, L., Wu, J., Chee Mahn Shin, Huang, B., Cash, B. A., Bosilovich, M. G., Sarith Mahanama, Koster, R. D., Santanello, J. A., Ek, M., Balsamo, G., Dutra, E., & Lawrence, D. M. (2018). Verification of Land–Atmosphere Coupling in Forecast Models, Reanalyses, and Land Surface Models Using Flux Site Observations. **Journal of Hydrometeorology**, 19(2), 375–392. <https://doi.org/10.1175/jhm-d-17-0152.1>

dos Santos Silva, F. D., Gomes, H. B., da Costa, C. P. W., Nogueira Neto, A. V., de Freitas, I. G. F., dos Santos Vanderlei, M. H. G., da Silva, M. C. L., Costa, R. L., dos Reis, J. S., dos Santos Franco, V., dos Santos, A. P. P., Saraiva, I., da Rocha Júnior, R. L., Cabral Júnior, J. B., da Silva, H. J. F., dos Santos Jesus, E., da Silva Ferreira, D. B., & Tedeschi, R. G. (2025). Bias correction methods for simulated precipitation in the Brazilian Legal Amazon. **Frontiers in Climate**, 7. <https://doi.org/10.3389/fclim.2025.1651474>

Döscher, R., et al. (2022). Earth System Models. **Encyclopedia of Earth System Sciences**. <https://www.sciencedirect.com/science/article/pii/B9780124095472116423>

Duffy, P., Brando, P., Asner, G., & Field, C. (2015). Projections of future meteorological drought and wet periods in the Amazon. **Proceedings of the National Academy of Sciences**, 112, 13172 - 13177. <https://doi.org/10.1073/pnas.1421010112>

Dufek, J., Pereira, G., & Ometto, J. (2020). Regional climate modeling over South America: A review. **Theoretical and Applied Climatology**, 140, 1211-1236. <https://doi.org/10.1007/s00704-020-03135-8>

Durai, S., & Bhradwaj, M. (2014). Evaluation of WRF model for precipitation simulation over mountains. **Atmospheric Research**. <https://www.sciencedirect.com/science/article/pii/S0169809514000770>

Edwards, P. N. (2010). **A Vast Machine: Computer Models, Climate Data, and the Politics of Global Warming**. MIT Press. <https://mitpress.mit.edu/books/vast-machine>

Enayati, M., Bozorg-Haddad, O., Bazrafshan, J., Hejabi, S., & Chu, X. (2020). Bias correction capabilities of quantile mapping methods for rainfall and temperature variables. **Journal of Water and Climate Change**, 12(2), 401-419. <https://doi.org/10.2166/wcc.2020.261>

Espinoza, J., Jimenez, J., Marengo, J., Schongart, J., Ronchail, J., Lavado-Casimiro, W., & Ribeiro, J. (2024). The new record of drought and warmth in the Amazon in 2023

- related to regional and global climatic features. **Scientific Reports**, 14. <https://doi.org/10.1038/s41598-024-58782-5>
- Eyring, V., Bony, S., Meehl, G. A., et al. (2016). Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. **Geoscientific Model Development**. <https://gmd.copernicus.org/articles/9/1937/2016/>
- FAS (2024). **Amazônia Legal: importância socioambiental**. <https://fas-amazonia.org/amazonia-legal-entenda-sua-importancia/>
- Ferreira, W. M., Vitorino, M. I., Barreiros, E., & Alexandre. (2012). Sazonalidade da precipitação para a Amazônia usando o modelo REGCM3: avaliando apenas a forçante do Atlântico Equatorial. **Revista Brasileira de Meteorologia**, 27(4), 435–446. <https://doi.org/10.1590/s0102-77862012000400007>
- Filho, W., Oliveira-Júnior, J., Silva, C., & De Barros Santiago, D. (2021). Influence of the El Niño–Southern Oscillation and the synoptic systems on the rainfall variability over the Brazilian Cerrado via Climate Hazard Group InfraRed Precipitation with Station data. **International Journal of Climatology**, 42, 3308 - 3322. <https://doi.org/10.1002/joc.7417>
- Flato, G., Marotzke, J., Abiodun, B., et al. (2013). Evaluation of Climate Models. In: **Climate Change 2013 - The Physical Science Basis. IPCC AR5**. https://www.ipcc.ch/site/assets/uploads/2018/02/WG1AR5_all_final.pdf
- Fowler, H. J., Blenkinsop, S., & Tebaldi, C. (2007). Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. **International Journal of Climatology**, 27(12), 1547–1578. <https://doi.org/10.1002/joc.1556>
- Friedlingstein, P., et al. (2020). Global Carbon Budget 2020. **Earth System Science Data**. <https://essd.copernicus.org/articles/12/3269/2020/>
- Gao, S. (2020). Dynamical downscaling of surface air temperature and precipitation using RegCM4 and WRF over China. **Climate Dynamics**, 55(5-6), 1283–1302. <https://doi.org/10.1007/s00382-020-05326-y>
- García-Franco, J. L., Gray, L. J., & Osprey, S. (2020). The American monsoon system in HadGEM3 and UKESM1. **Weather and Climate Dynamics**, 1(2), 349–371. <https://doi.org/10.5194/wcd-1-349-2020>
- Gatti, L. V., et al. (2021). Amazonia as a carbon source linked to deforestation and climate change. **Nature**, 595(7867), 388–393. <https://www.nature.com/articles/s41586-021-03629-6>

- Ge, J., Qiu, B., Chu, B., Li, D., Jiang, L., Zhou, W., Tang, J., & Guo, W. (2021). Evaluation of coupled regional climate models in representing the local biophysical effects of afforestation over continental China. **Journal of Climate**, 1–62. <https://doi.org/10.1175/jcli-d-21-0462.1>
- Giorgi, F., & Mearns, L. O. (1991). Approaches to the simulation of regional climate change: a review. **Reviews of Geophysics**. <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/91RG00979>
- Goodess, C., Anagnostopoulou, C., Bárdossy, A., Frei, C., Harpham, C., Haylock, M., Hundecha, Y., Maheras, P., Ribalaygua, J., Schmidli, J., Schmith, T., Tolika, K., Tomozeiu, R., & Wilby, R. (2005). **An intercomparison of statistical downscaling methods for Europe and European regions -assessing their performance with respect to extreme temperature and precipitation events**. Climatic Research Unit Research Publication, 11. https://crudata.uea.ac.uk/cru/pubs/crupr/CRU_RP11.pdf
- Green, A., & Romanov, E. (2025). The high-dimensional asymptotics of principal component regression. *The Annals of Statistics*, 53(4). <https://doi.org/10.1214/25-aos2532>
- Gutowski, W. J., et al. (2020). CORDEX: The Coordinated Regional Downscaling Experiment. **Bulletin of the American Meteorological Society**. <https://journals.ametsoc.org/view/journals/bams/101/10/bams-d-19-0077.1.xml>
- Hanadi A. Amhimmid, Fatma Alzahra A. Aljehany, Mohamed A. Mohamed, & Kasem A. Farag. (2025). Comparative Study of Four Methods in Hierarchical Cluster Analysis. *Libyan Journal of Medical and Applied Sciences*, 11–16. <https://doi.org/10.64943/ljmas.v3i4.183>
- Hawkins, E., & Sutton, R. (2009). The potential to narrow uncertainty in projections of regional precipitation change. **Climate Dynamics**. <https://link.springer.com/article/10.1007/s00382-008-0504-0>
- Herdies, D. L., Silva, F. D. dos S., Gomes, H. B., Silva, M. C. L. da, Gomes, H. B., Costa, R. L., Lins, M. C. C., Reis, J. S. dos, Kubota, P. Y., Souza, D. C. de, Melo, M. L. D. de, & Mariano, G. L. (2023). Evaluation of Surface Data Simulation Performance with the Brazilian Global Atmospheric Model (BAM). **Atmosphere**, 14(1), 125. <https://doi.org/10.3390/atmos14010125>
- Hertwig, E., von Storch, J-S., Handorf, D., Dethloff, K., Fast, I., & Krismer, T. (2015). Effect of horizontal resolution on ECHAM6-AMIP performance. **Climate Dynamics**, 45, 185–211.

- Hoffmann, H., & Rath, T. (2012). Meteorologically consistent bias correction of climate time series for agricultural models. **Theoretical and Applied Climatology**, 110(1-2), 129–141. <https://doi.org/10.1007/s00704-012-0618-x>
- Holtslag, A. A. M., De Bruijn, E. I. F., & Pan, H. (1990). A High Resolution Air Mass Transformation Model for Short-Range Weather Forecasting. **Monthly Weather Review**, 118, 1561–1575, [https://doi.org/10.1175/1520-0493\(1990\)118<1561:AHRAMT>2.0.CO;2](https://doi.org/10.1175/1520-0493(1990)118<1561:AHRAMT>2.0.CO;2)
- Holthuijzen, M., Beckage, B., Clemins, P., Higdon, D., & Winter, J. (2021). Robust bias-correction of precipitation extremes using a novel hybrid empirical quantile-mapping method. **Theoretical and Applied Climatology**, 149, 863-882. <https://doi.org/10.1007/s00704-022-04035-2>
- Hotelling, H. (1936). RELATIONS BETWEEN TWO SETS OF VARIATES. **Biometrika**, 28(3-4), 321–377. <https://doi.org/10.1093/biomet/28.3-4.321>
- Houghton, R. A. (2013). The emissions of carbon from deforestation and degradation in the tropics: Past and future. **Carbon Management**, 4(5), 539-546. <https://www.tandfonline.com/doi/full/10.4155/cmt.13.41>.
- Howell, J. C., Yizhaq, T., Drechsler, N., Zamir, Y., Beysens, D., & Shaw, J. A. (2021). Generalized nighttime radiative deficits. **Journal of Hydrology**, 603, 126971. <https://doi.org/10.1016/j.jhydrol.2021.126971>
- Iacobucci, D., Schneider, M. J., Popovich, D. L., & Bakamitsos, G. A. (2015). Mean centering helps alleviate “micro” but not “macro” multicollinearity. *Behavior Research Methods*, 48(4), 1308–1317. <https://doi.org/10.3758/s13428-015-0624-x>
- IBGE (2023). **Limites e características da Amazônia Legal**. Disponível em: <https://www.ibge.gov.br/>
- IBGE (2025). **Amazônia Legal**. <https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html>
- Ines, A. V. M., & Hansen, J. W. (2006). Bias correction of daily GCM rainfall for crop simulation studies. **Agricultural and Forest Meteorology**, 138(1-4), 44–53. <https://doi.org/10.1016/j.agrformet.2006.03.009>
- INPE (2022). **Monitoramento do desmatamento na Amazônia Legal**. <http://terrabrasilis.dpi.inpe.br/en/home/>
- IPCC (2021). **Climate Change 2021: The Physical Science Basis**. <https://www.ipcc.ch/report/ar6/wg1/>

- IPCC (2022). **Climate Change 2022: Impacts, Adaptation and Vulnerability**. <https://www.ipcc.ch/report/ar6/wg2/>
- Ishihara, J., Fernandes, L., Duarte, A., Ponte, M., & Loureiro, G. (2014). Quantitative and Spatial Assessment of Precipitation in the Brazilian Amazon (Legal Amazon) - (1978 to 2007). **Revista Brasileira de Recursos Hídricos**, 19(1), 29–39. <https://doi.org/10.21168/rbrh.v19n1.p29-39>
- Izzaddin, Langousis, A., Totaro, V., Yaseen, M., & Iacobellis, V. (2024). A new diagram for performance evaluation of complex models. *Stochastic Environmental Research and Risk Assessment*, 38(6), 2261–2281. <https://doi.org/10.1007/s00477-024-02678-3>
- Jackson, J. E. (2005). Análise de Componentes Principais. In: **Análise Multivariada de Dados**, 2ª ed., Pioneira Thompson. (Tradução e adaptação)
- Jhan Carlo Espinoza, Josyane Ronchail, Marengo, J. A., & Segura, H. (2018). Contrasting North–South changes in Amazon wet-day and dry-day frequency and related atmospheric features (1981–2017). **Climate Dynamics**, 52(9-10), 5413–5430. <https://doi.org/10.1007/s00382-018-4462-2>
- Jiang, Z., Liu, D., Dong, G., Tang, J., Wang, S., & Xiong, Y. (2024). Convection-permitting regional climate simulations over coastal regions in China. **Climate Dynamics**, 62(8), 7271–7291. <https://doi.org/10.1007/s00382-024-07278-z>
- Jiménez-Muñoz, J., Mattar, C., Barichivich, J., Santamaría-Artigas, A., Takahashi, K., Malhi, Y., Sobrino, J., & Schrier, G. (2016). Record-breaking warming and extreme drought in the Amazon rainforest during the course of El Niño 2015–2016. **Scientific Reports**, 6. <https://doi.org/10.1038/srep33130>
- Jolliffe, I. T. (2002). **Principal Component Analysis**. In Springer Series in Statistics. Springer-Verlag. <https://doi.org/10.1007/b98835>
- Kähnert, M., Sodemann, H., Remes, T. M., Fortelius, C., Bazile, E., & Esau, I. (2022). Spatial Variability of Nocturnal Stability Regimes in an Operational Weather Prediction Model. **Boundary-Layer Meteorology**, 186(2), 373–397. <https://doi.org/10.1007/s10546-022-00762-1>
- Kain, J. S., & Fritsch, J. M. (1990). A one-dimensional entraining/detraining plume model and its application in convective parameterization. **Journal of the Atmospheric Sciences**, 47(23), 2784–2802. DOI: 10.1175/1520-0469(1990)047<2784:AODEPM>2.0.CO;2

- Kain, J. S., & Kain, J. (2004). The Kain - Fritsch convective parameterization: An update. **Journal of Applied Meteorology**, 43(1), 170–181. [https://doi.org/10.1175/1520-0450\(2004\)04360:0170:tkcpau62;2.0.co;2](https://doi.org/10.1175/1520-0450(2004)04360:0170:tkcpau62;2.0.co;2)
- Karamouz, M., Nazif, S., & Fallahi, M. (2010). Rainfall Downscaling Using Statistical Downscaling Model and Canonical Correlation Analysis: A Case Study. **World Environmental and Water Resources Congress 2010**, 4579–4587. [https://doi.org/10.1061/41114\(371\)465](https://doi.org/10.1061/41114(371)465)
- Kendon, E. J., Ban, N., Roberts, N. M., Fowler, H. J., Roberts, M. J., Chan, S. C., Evans, J. P., Fosser, G., & Wilkinson, J. M. (2017). Do Convection-Permitting Regional Climate Models Improve Projections of Future Precipitation Change? **Bulletin of the American Meteorological Society**, 98(1), 79–93. <https://doi.org/10.1175/bams-d-15-0004.1>
- Kim, Y.-H., Min, S.-K., Zhang, X., Sillmann, J., & Sandstad, M. (2020). Evaluation of the CMIP6 multi-model ensemble for climate extreme indices. *Weather and Climate Extremes*, 29, 100269. <https://doi.org/10.1016/j.wace.2020.100269>
- Klami, A., Virtanen, S., & Kaski, S. (2013). Bayesian Canonical correlation analysis. **J. Mach. Learn. Res.**, 14, 965-1003. <https://doi.org/10.5555/2567709.2502612>
- L. Sangelantoni, S. Sobolowski, Lorenz, T., Ø. Hodnebrog, Cardoso, R. M., Soares, M., Ferretti, R., A. Lavín-Gullón, Fernandez, J., Goergen, K., J. Milovac, E. Katragkou, S. Kartsios, Coppola, E., E. Pichelli, Adinolfi, M., Mercogliano, P., S. Berthou, H. de Vries, & Dobler, A. (2023). Investigating the representation of heatwaves from an ensemble of km-scale regional climate simulations within CORDEX-FPS convection. **Climate Dynamics**, 62(6), 4635–4671. <https://doi.org/10.1007/s00382-023-06769-9>
- Lavado Casimiro, W. S., Labat, D., Ronchail, J., Espinoza, J. C., & Guyot, J. L. (2012). Trends in rainfall and temperature in the Peruvian Amazon-Andes basin over the last 40 years (1965-2007). **Hydrological Processes**, n/a-n/a. <https://doi.org/10.1002/hyp.9418>
- Lehner, F., et al. (2020). Projecting uncertainty changes with global warming. **Geophysical Research Letters**. <https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2019GL086983>
- Lemes, G., TEDESCHI, G., & João, S. (2020, November 30). Analysis of Moisture Transport from Amazonia to Southeastern Brazil During the Austral Summer. **Itv.org**. <https://repositorio.itv.org/items/ed19bc99-4abc-49c7-abc6-6453e9933033/full>
- Levine, P. A., Randerson, J. T., Chen, Y., Pritchard, M. S., Xu, M., & Hoffman, F. M. (2019). Soil Moisture Variability Intensifies and Prolongs Eastern Amazon Temperature

- and Carbon Cycle Response to El Niño–Southern Oscillation. **Journal of Climate**, 32(4), 1273–1292. <https://doi.org/10.1175/jcli-d-18-0150.1>
- Levine, X. J., & Boos, W. R. (2017). Land surface albedo bias in climate models and its association with tropical rainfall. **Geophysical Research Letters**, 44(12), 6363–6372. <https://doi.org/10.1002/2017gl072510>
- Lewis, S. L., et al. (2011). The 2010 Amazon drought. **Science**, 331(6017), 554-554. [suspicious link removed]
- Ling, Z., Gao, Y., & Chen, Q. (2021). Application of Principal Component Analysis in Meteorological Forecast. **IOP Conference Series: Earth and Environmental Science**, 631, 012019. <https://doi.org/10.1088/1755-1315/631/1/012019>
- Liu, R. X., Kuang, J., Gong, Q., & Hou, X. L. (2003). Principal component regression analysis with spss. **Computer Methods and Programs in Biomedicine**, 71(2), 141–147. [https://doi.org/10.1016/s0169-2607\(02\)00058-5](https://doi.org/10.1016/s0169-2607(02)00058-5)
- Loganathan, P., & Mahindrakar, A. B. (2021). Statistical downscaling using principal component regression for climate change impact assessment at the Cauvery river basin. **Journal of Water and Climate Change**. <https://doi.org/10.2166/wcc.2021.223>
- Lorenz, R., Pitman, A. J., Donat, M. G., Hirsch, A. L., Kala, J., Kowalczyk, E. A., Law, R. M., & Srbinovsky, J. (2014). Representation of climate extreme indices in the ACCESS1.3b coupled atmosphere–land surface model. **Geoscientific Model Development**, 7(2), 545–567. <https://doi.org/10.5194/gmd-7-545-2014>
- Lovejoy, T. E., & Nobre, C. (2018). Amazon Tipping Point. **Science Advances**, 4(2). <https://doi.org/10.1126/sciadv.aat2340>
- Lucas-Picher, P., Argüeso, D., Brisson, E., Trambly, Y., Berg, P., Lemonsu, A., Kotlarski, S., & Caillaud, C. (2021). Convection -permitting modeling with regional climate models: Latest developments and next steps. **WIREs Climate Change**, 12(6). <https://doi.org/10.1002/wcc.731>
- Lucas, E., Sousa, F., Silva, F., Da Rocha Júnior, R., Pinto, D., & Silva, V. (2021). Trends in climate extreme indices assessed in the Xingu river basin - Brazilian Amazon. **Weather and climate extremes**, 31, 100306. <https://doi.org/10.1016/J.WACE.2021.100306>
- Luiz-Silva, W., Bazzanela, A., Dereczynski, C., Oscar-Júnior, A., & Raupp, I. (2025). Temperature and Precipitation Extremes in the Brazilian Legal Amazon: A Summary of Climatological Patterns and Detected Trends. **Atmosphere**. <https://doi.org/10.3390/atmos16020222>

- Luo, Y., Zhang, K., Wang, W., Chen, X., Feng, J., Wang, H., Liu, W., Guo, C., Chen, C., & Wang, X. (2025). An improved statistical bias correction method for Global Climate Model (GCM) precipitation projection: A case study on the CMCC-CM2-SR5 model projection in China's Huaihe River Basin. **Journal of Hydrology: Regional Studies**. <https://doi.org/10.1016/j.ejrh.2024.102146>
- Ma, M., Ou, T., Liu, D., Wang, S., Fang, J., & Tang, J. (2022). Summer regional climate simulations over Tibetan Plateau: from gray zone to convection permitting scale. **Climate Dynamics**, 60(1-2), 301–322. <https://doi.org/10.1007/s00382-022-06314-0>
- Machado-Silva, F., Libonati, R., Melo de Lima, T. F., Bittencourt Peixoto, R., de Almeida França, J. R., de Avelar Figueiredo Mafra Magalhães, M., Lemos Maia Santos, F., Abrantes Rodrigues, J., & DaCamara, C. C. (2020). Drought and fires influence the respiratory diseases hospitalizations in the Amazon. **Ecological Indicators**, 109, 105817. <https://doi.org/10.1016/j.ecolind.2019.105817>
- Manabe, S., & Wetherald, R. T. (1967). Thermal equilibrium of the atmosphere with a given distribution of relative humidity. **Journal of the Atmospheric Sciences**. https://journals.ametsoc.org/view/journals/atsc/24/3/1520-0469_1967_024_0240_teotaw_2_0_co_2.xml
- Maraun, D. (2016). Bias Correction for Climate Change Simulations of Precipitation. **WIREs Climate Change**. <https://onlinelibrary.wiley.com/doi/full/10.1002/wcc.380>
- Maraun, D., Shepherd, T., Widmann, M., Zappa, G., Walton, D., Gutiérrez, J., Hagemann, S., Richter, I., Soares, P., Hall, A., & Mearns, L. (2017). Towards process-informed bias correction of climate change simulations. **Nature Climate Change**, 7, 764–773. <https://doi.org/10.1038/NCLIMATE3418>
- Marengo, J. A., & Espinoza, J. C. (2018). Extreme seasonal droughts and floods in Amazonia: causes, trends and impacts. **International Journal of Climatology**, 38(1), 103-123. [suspicious link removed]
- Marengo, J. A., Jimenez, J. C., Espinoza, J.-C., Cunha, A. P., & Aragão, L. E. O. (2022). Increased climate pressure on the agricultural frontier in the Eastern Amazonia–Cerrado transition zone. **Scientific Reports**, 12(1). <https://doi.org/10.1038/s41598-021-04241-4>
- Marengo, J. A., Liebmann, B., Grimm, A. M., Misra, V., Silva Dias, P. L., Cavalcanti, I. F. A., Carvalho, L. M. V., Berbery, E. H., Ambrizzi, T., Vera, C. S., Saulo, A. C., Noguez-Paegle, J., Zipser, E., Seth, A., & Alves, L. M. (2010). Recent developments on the South American monsoon system. **International Journal of Climatology**, 32(1), 1–21. <https://doi.org/10.1002/joc.2254>

- Marengo, J. A., Souza, C. M., Thonicke, K., Burton, C., Halladay, K., Betts, R. A., Alves, L. M., & Soares, W. R. (2018). Changes in Climate and Land Use Over the Amazon Region: Current and Future Variability and Trends. **Frontiers in Earth Science**, 6, 228. <https://doi.org/10.3389/feart.2018.00228>
- Marengo, J. A., Souza, C. M., Thonicke, K., Burton, C., Halladay, K., Betts, R. A., ... & Navarra, A. (2017). Reciclagem de Precipitação na Bacia Amazônica: O Papel do Transporte de Umidade e da Evapotranspiração da Superfície. **Revista Brasileira de Meteorologia**, 32(2), 243-259. Disponível em: <https://www.scielo.br/j/rbmet/a/53XZYdjvScP4gpVGZ3mp34k/?lang=pt>
- Martins, P., Sano, E., Martins, É., Vieira, L., Salemi, L., Vasconcelos, V., & Júnior, A. (2021). Terrain units, land use and land cover, and gross primary productivity of the largest fluvial basin in the Brazilian Amazonia/Cerrado ecotone: The Araguaia River basin. **Applied Geography**, 127, 102379. <https://doi.org/10.1016/J.APGEOG.2020.102379>
- Matte, D., Laprise, R., Thériault, J., & Lucas-Picher, P. (2017). Spatial spin-up of fine scales in a regional climate model simulation driven by low-resolution boundary conditions. **Climate Dynamics**, 49, 563-574. <https://doi.org/10.1007/s00382-016-3358-2>
- Mauritsen, T., Bader, J., Becker, T., Behrens, J., Bittner, M., Brokopf, R. et al. (2019). Developments in the MPI-M Earth System Model version 1.2 (MPI-ESM1.2) and its response to increasing CO₂. **Journal of Advances in Modeling Earth Systems**, 11, 998–1038.
- Mendez, M., Maathuis, B., Hein-Griggs, D., & Alvarado-Gamboa, L. (2020). Performance Evaluation of Bias Correction Methods for Climate Change Monthly Precipitation Projections over Costa Rica. **Water**. <https://doi.org/10.3390/w12020482>
- Meng, X., Lyu, S., Zhang, T., Zhao, L., Li, Z., Han, B., Li, S., Ma, D., Chen, H., Ao, Y., Luo, S., Shen, Y., Guo, J., & Wen, L. (2018). Simulated cold bias being improved by using MODIS time-varying albedo in the Tibetan Plateau in WRF model. **Environmental Research Letters**, 13(4), 044028–044028. <https://doi.org/10.1088/1748-9326/aab44a>
- Monteverde, C., De Sales, F., & Jones, C. (2022). Evaluation of the CMIP6 Performance in Simulating Precipitation in the Amazon River Basin. **Climate**. <https://doi.org/10.3390/cli10080122>

Monteverde, E., et al. (2022). Persistent dry bias in CMIP6 simulations of the Amazon. **Geophysical Research Letters**.

<https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2022GL099265>

Nahar, N. M., Kumar, S., & Parman, S. (2017). Assessment of the predictability of extreme rainfall events: Limitations of reanalysis data. **Journal of Hydrology**.

<https://www.sciencedirect.com/science/article/abs/pii/S002216941730882X>

Nepstad, D., et al. (2008). Interactions among Amazon land use, forests and climate: prospects for a near-term forest tipping point. **Philosophical Transactions of the Royal Society B**, 363(1498), 1737-1746.

<https://royalsocietypublishing.org/doi/10.1098/rstb.2007.0036>

Nobre, C., Sampaio, G., Borma, L., Castilla-Rubio, J., Silva, J., & Cardoso, M. (2016). Land-use and climate change risks in the Amazon and the need of a novel sustainable development paradigm. **Proceedings of the National Academy of Sciences**, 113, 10759 - 10768. <https://doi.org/10.1073/pnas.1605516113>

Oliveira, R., Serra, B., Wendel, Martins, G. C., Ribeiro, P. G., Queiroz, M., Silva, & Ramos, S. J. (2025). Impact of Land Cover and Meteorological Attributes on Soil Fertility, Temperature, and Moisture in the Itacaiúnas River Watershed, Eastern Amazon. **Environments**, 12(4), 98–98. <https://doi.org/10.3390/environments12040098>

Paca, V. H. da M., Espinoza-Dávalos, G., Moreira, D., & Comair, G. (2020). Variability of Trends in Precipitation across the Amazon River Basin Determined from the CHIRPS Precipitation Product and from Station Records. **Water**, 12(5), 1244. <https://doi.org/10.3390/w12051244>

Pal, J. S., Small, E. E., & Eltahir, E. A. B. (2000). Simulation of regional-scale water and energy budgets: Representation of subgrid cloud and precipitation processes within RegCM. **Journal of Geophysical Research: Atmospheres**, 105(D24), 29579–29594. <https://doi.org/10.1029/2000jd900415>

Palmer, T. N., & Weisheimer, A. (2011). Diagnosing the causes of bias in climate models – why is it so hard? **Geophysical & Astrophysical Fluid Dynamics**, 105(2-3), 351–365. <https://doi.org/10.1080/03091929.2010.547194>

Panisset, J., Libonati, R., Gouveia, C., Machado-Silva, F., França, D., França, J., & Peres, L. (2018). Contrasting patterns of the extreme drought episodes of 2005, 2010 and 2015 in the Amazon Basin. **International Journal of Climatology**, 38. <https://doi.org/10.1002/joc.5224>

- Pareja-Quispe, D., Franchito, S. H., & Pablo, J. (2021). Assessment of the RegCM4 Performance in Simulating the Surface Radiation Budget and Hydrologic Balance Variables in South America. **Earth Systems and Environment**, 5(3), 499–518. <https://doi.org/10.1007/s41748-021-00249-y>
- Parsons, L. A. (2020). Implications of CMIP6 Projected Drying Trends for 21st Century Amazonian Drought Risk. **Earth's Future**, 8(10), e2020EF001608. <https://doi.org/10.1029/2020EF001608>
- Philip, M., Mulholland, P. J., & McDowell, W. H. (2020). Hydrology and biogeochemistry of tropical forest ecosystems. **Water Resources Research**, 56(8), e2020WR027350. <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2020WR027350>
- Pierce, D., Cayan, D., Maurer, E., Abatzoglou, J., & Hegewisch, K. (2015). Improved Bias Correction Techniques for Hydrological Simulations of Climate Change. **Journal of Hydrometeorology**, 16, 2421–2442. <https://doi.org/10.1175/JHM-D-14-0236.1>
- Reboita, J. Fernández, Llopart, M., da, P., Luana Albertani Pampuch, & Cruz, F. (2014). Assessment of RegCM4.3 over the CORDEX South America domain: sensitivity analysis for physical parameterization schemes. **Climate Research**, 60(3), 215–234. <https://doi.org/10.3354/cr01239>
- Reboita, M. S., Willian de Souza Ferreira, G., Gabriel Martins Ribeiro, J., & Ali, S. (2024). Assessment of precipitation and near-surface temperature simulation by CMIP6 models in South America. **Environmental Research: Climate**, 3(2), 025011. <https://doi.org/10.1088/2752-5295/ad3fdb>
- Reddy, P., Chinta, S., Matear, R., Taylor, J., Baki, H., Thatcher, M., Kala, J., & Sharples, J. (2023). Machine learning based parameter sensitivity of regional climate models—a case study of the WRF model for heat extremes over Southeast Australia. **Environmental Research Letters**, 19. <https://doi.org/10.1088/1748-9326/ad0eb0>
- Richter, I., Doi, T., Chang, P., Xu, Z., Kataoka, T., Tomoki Tozuka, Motoki Nagura, Pascal Oettli, & De, S. P. (2015). An Overview Of Coupled GCM Biases In The Tropics. **World Scientific Series on Asia-Pacific Weather and Climate**, 213–263. https://doi.org/10.1142/9789814696623_0008
- Rocha, V. M., Wagner, F., & De (2019). Avaliação dos Impactos da Mudança do Clima na Precipitação da Amazônia Utilizando o Modelo RCP 8.5 Eta-HadGEM2-ES. **Revista Brasileira de Geografia Física**, 12(6), 2051. <https://doi.org/10.26848/rbgf.v12.6.p2051-2065>

- Ruv Lemes, M., Sampaio, G., Fisch, G., Alves, L. M., Maksic, J., Guatura, M., & Shimizu, M. (2022). Impacts of atmospheric CO₂ increase and Amazon deforestation on the regional climate: A water budget modelling study. **International Journal of Climatology**, 43(3), 1497–1513. <https://doi.org/10.1002/joc.7929>
- Sachindra, D., & Perera, B. (2016). Statistical Downscaling of General Circulation Model Outputs to Precipitation Accounting for Non-Stationarities in Predictor-Predictand Relationships. **PLoS ONE**, 11. <https://doi.org/10.1371/journal.pone.0168701>
- Santos e Silva, C. M., Silva, A., Oliveira, P., & Lima, K. C. (2013). Dynamical downscaling of the precipitation in Northeast Brazil with a regional climate model during contrasting years. **Atmospheric Science Letters**, 15(1), 50–57. <https://doi.org/10.1002/asl2.468>
- Seneviratne, S., & Hauser, M. (2020). Regional Climate Sensitivity of Climate Extremes in CMIP6 Versus CMIP5 Multimodel Ensembles. **Earth's Future**, 8. <https://doi.org/10.1029/2019EF001474>
- Shi, Y., Yu, M., Erfanian, A., & Wang, G. (2018). Modeling the Dynamic Vegetation–Climate System over China Using a Coupled Regional Model. **Journal of Climate**, 31(15), 6027–6049. <https://doi.org/10.1175/jcli-d-17-0191.1>
- Silva, J. L. G., Capistrano, V. B., Veiga, J. A. P., & Brito, A. L. (2023). Regional climate modeling in the Amazon basin to evaluate fire risk. **Acta Amazonica**, 53, 166–176. <https://doi.org/10.1590/1809-4392202201881>
- Silva Junior, C. H. L., et al. (2021). The Brazilian Amazon deforestation rate in 2020. **Nature Ecology & Evolution**, 5(4), 464–465. <https://www.nature.com/articles/s41559-021-01498-z>
- Silva, S., Brown, F., De Oliveira Sampaio, A., Silva, A., Santos, N., Lima, A., De Souza Aquino, A., Da Costa Silva, P., Moreira, J., Oliveira, I., Costa, A., & Fearnside, P. (2023). Amazon climate extremes: Increasing droughts and floods in Brazil's state of Acre. **Perspectives in Ecology and Conservation**. <https://doi.org/10.1016/j.pecon.2023.10.006>
- Sitch, S., Huntingford, C., Gedney, N., et al. (2008). Evaluation of the terrestrial carbon cycle, future plant geography and climate-carbon cycle feedbacks using five Dynamic Global Vegetation Models (DGVMs). **Global Change Biology**. <https://onlinelibrary.wiley.com/doi/full/10.1111/j.1365-2486.2008.01626.x>
- Song, Z., Deng, Q., & Ren, Z. (2019). Correlação e análise de regressão por componentes principais para estudo da qualidade do ar e elementos meteorológicos em Wuhan, China.

Environmental Progress & Sustainable Energy, 39(1), e13278.

<https://doi.org/10.1002/ep.13278>

Sorensen, B., Charalampopoulos, A., Zhang, S., Harrop, B., Leung, R., & Sapsis, T. (2024). A Non-Intrusive Machine Learning Framework for Debiasing Long-Time Coarse Resolution Climate Simulations and Quantifying Rare Events Statistics. **Journal of Advances in Modeling Earth Systems**, 16. <https://doi.org/10.1029/2023MS004122>

Sørland, S. L., Schär, C., Lüthi, D., & Kjellström, E. (2018). Bias patterns and climate change signals in GCM-RCM model chains. *Environmental Research Letters*, 13(7), 074017. <https://doi.org/10.1088/1748-9326/aacc77>

Soto-Navarro, C., Ravilious, C., Arnell, A., Lamo, X., Harfoot, M., Hill, S., Hill, S., Wearn, O., Santoro, M., Bouvet, A., Mérmoz, S., Toan, T., Xia, J., Liu, S., Yuan, W., Yuan, W., Spawn, S., Gibbs, H., Ferrier, S., Harwood, T., Alkemade, R., Schipper, A., Schipper, A., Schmidt-Traub, G., Strassburg, B., Miles, L., Burgess, N., Burgess, N., & Kapos, V. (2020). Mapping co-benefits for carbon storage and biodiversity to inform conservation policy and action. **Philosophical Transactions of the Royal Society B**, 375. <https://doi.org/10.1098/rstb.2019.0128>

Sousa, L. S., Fernandes, L. A., Silva, R. T., & Santos, B. F. (2023). Performance evaluation of regional climate models over the Brazilian Amazon. **Climate Dynamics**, 60, 3613–3630. <https://doi.org/10.1007/s00382-022-06558-x>

Srivastava, P. K., Islam, T., Gupta, M., Petropoulos, G., & Dai, Q. (2015). WRF Dynamical Downscaling and Bias Correction Schemes for NCEP Estimated Hydro-Meteorological Variables. **Water Resources Management**, 29(7), 2267-2284. <https://doi.org/10.1007/s11269-015-0940-z>

Statheropoulos, M., Vassiliadis, N., & Pappa, A. (1998). Principal component and canonical correlation analysis for examining air pollution and meteorological data. **Atmospheric Environment**, 32(6), 1087-1095. [https://doi.org/10.1016/S1352-2310\(97\)00377-4](https://doi.org/10.1016/S1352-2310(97)00377-4)

Sun, Q., Miao, C., & Duan, Q. (2015). Comparative analysis of CMIP3 and CMIP5 global climate models for simulating the daily mean, maximum, and minimum temperatures and daily precipitation over China. **Journal of Geophysical Research: Atmospheres**, 120(10), 4806–4824. <https://doi.org/10.1002/2014jd022994>

Tapiador, F. J., Navarro, A., Moreno, R., Sánchez, J. L., & García-Ortega, E. (2020). Regional climate models: 30 years of dynamical downscaling. **Atmospheric Research**, 235, 104785. <https://doi.org/10.1016/j.atmosres.2019.104785>.

- Teodoro, T. A., Reboita, M. S., Llopart, M., da Rocha, R. P., & Ashfaq, M. (2021). Climate Change Impacts on the South American Monsoon System and Its Surface–Atmosphere Processes Through RegCM4 CORDEX-CORE Projections. **Earth Systems and Environment**, 5(4), 825–847. <https://doi.org/10.1007/s41748-021-00265-y>
- Terink, W., Hurkmans, R. T. W. L., Torfs, P. J. J. F., & Uijlenhoet, R. (2010). Evaluation of a bias correction method applied to downscaled precipitation and temperature reanalysis data for the Rhine basin. **Hydrology and Earth System Sciences**, 14(4), 687–703. <https://doi.org/10.5194/hess-14-687-2010>
- Teutschbein, C., & Seibert, J. (2012). Bias correction of regional climate model simulations for hydrological climate-change impact studies: review and evaluation of different methods. **Journal of Hydrology**, 456-457, 12-29. <https://doi.org/10.1016/j.jhydrol.2012.05.052>
- Thornton, P. E., et al. (2009). Carbon-nitrogen interactions regulate climate-carbon cycle feedbacks: results from an atmosphere-ocean general circulation model. **Biogeosciences**. <https://bg.copernicus.org/articles/6/2099/2009/>
- Tiedtke, M. (1996). Representation of clouds in large-scale models. **Monthly Weather Review**, 121(11), 3040–3061. DOI: 10.1175/1520-0493(1993)121<3040:ROCILS>2.0.CO;2
- Tong, Y., Gao, X., Han, Z., Xu, Y., Xu, Y., & Giorgi, F. (2020). Bias correction of temperature and precipitation over China for RCM simulations using the QM and QDM methods. **Climate Dynamics**, 57, 1425 - 1443. <https://doi.org/10.1007/s00382-020-05447-4>
- Trentini, L., Gesso, D., Venturini, M., Guerrini, F., Calmanti, S., & Petitta, M. (2022). A Novel Bias Correction Method for Extreme Events. **Climate**. <https://doi.org/10.3390/cli11010003>
- Valente, C., Latrubesse, E., & Ferreira, L. (2013). Relationships among vegetation, geomorphology and hydrology in the Bananal Island tropical wetlands, Araguaia River basin, Central Brazil. **Journal of South American Earth Sciences**, 46, 150-160. <https://doi.org/10.1016/J.JSAMES.2012.12.003>
- Viggiano, M., Busetto, L., Cimini, D., Francesco Di Paola, Geraldi, E., Ranghetti, L., Ricciardelli, E., & Romano, F. (2019). A new spatial modeling and interpolation approach for high-resolution temperature maps combining reanalysis data and ground measurements. **Agricultural and Forest Meteorology**, 276-277, 107590–107590. <https://doi.org/10.1016/j.agrformet.2019.05.021>

- Vizcaíno, M., et al. (2009). Ice sheet models and sea level rise. **Philosophical Transactions of the Royal Society A**. <https://royalsocietypublishing.org/doi/10.1098/rsta.2008.0231>
- Wilby, R., Charles, S., Zorita, E., Timbal, B., Whetton, P., & Mearns, L. (2004). **Guidelines for Use of Climate Scenarios Developed from Statistical Downscaling Methods**. https://www.ipcc-data.org/guidelines/dgm_no2_v1_09_2004.pdf
- Wu, S., Hannig, J., & Lee, T. C. M. (2021). Uncertainty quantification for principal component regression. *Electronic Journal of Statistics*, 15(1). <https://doi.org/10.1214/21-ejs1837>
- Xavier, A. C.; King, C. W.; Scanlon, B. R. (2016). Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, v. 36, p. 2644–2659.
- Xavier, A. C., Scanlon, B. R., King, C. W., & Alves, A. T. (2022). New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, 42(16), 8390–8404. <https://doi.org/10.1002/joc.7731>
- Xie, S., Lin, W., Rasch, P. J., Ma, P., Neale, R., Larson, V. E., Qian, Y., Bogenschutz, P. A., Caldwell, P. V., Cameron-Smith, P., Jean-Christophe Golaz, Mahajan, S., Singh, B., Edelstein, S. L., Wang, H., Jin Hee Yoon, Zhang, K., & Zhang, Y. (2018). Understanding Cloud and Convective Characteristics in Version 1 of the E3SM Atmosphere Model. **Journal of Advances in Modeling Earth Systems**, 10(10), 2618–2644. <https://doi.org/10.1029/2018ms001350>
- Xu, X., Jia, G., Zhang, X., Riley, W. J., & Xue, Y. (2020). Climate regime shift and forest loss amplify fire in Amazonian forests. **Global Change Biology**. <https://doi.org/10.1111/gcb.15279>
- Yang, X., Liu, W., Liu, W., & Tao, D. (2021). A Survey on Canonical Correlation Analysis. *IEEE Transactions on Knowledge and Data Engineering*, 33(6), 2349–2368. <https://doi.org/10.1109/tkde.2019.2958342>
- Zhang, S., Harrop, B., Leung, L., Charalampopoulos, A., Sorensen, B., Xu, W., & Sapsis, T. (2024). A Machine Learning Bias Correction on Large-Scale Environment of High-Impact Weather Systems in E3SM Atmosphere Model. **Journal of Advances in Modeling Earth Systems**, 16. <https://doi.org/10.1029/2023MS004138>
- Zhu, H., Jiang, Z., Li, J., Li, W., Sun, C., & Li, L. (2020). Does CMIP6 Inspire More Confidence in Simulating Climate Extremes over China? **Advances in Atmospheric Sciences**. <https://doi.org/10.1007/s00376-020-9289-1>

Zhuang, X., Yang, Z., & Cordes, D. (2020). A technical review of canonical correlation analysis for neuroscience applications. *Human Brain Mapping*, 41(13), 3807–3833.
<https://doi.org/10.1002/hbm.25090>