

**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
Escola de Engenharia  
Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos

Leonardo Rodrigues Santos

**Utilização do método *Bluecat* para correção de viés e estimação de incertezas na  
previsão de variáveis hidroclimáticas na Região Metropolitana de Belo Horizonte**

Belo Horizonte  
2024

Leonardo Rodrigues Santos

**UTILIZAÇÃO DO MÉTODO BLUECAT PARA CORREÇÃO DE VIÉS E ESTIMAÇÃO DE INCERTEZAS NA PREVISÃO DE VARIÁVEIS HIDROCLIMÁTICAS NA REGIÃO METROPOLITANA DE BELO HORIZONTE**

Dissertação apresentada ao Programa de Pós-graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre em Saneamento, Meio Ambiente e Recursos Hídricos.

Área de concentração: Recursos Hídricos

Linha de pesquisa: Modelagem de processos hidrológicos

Orientador: Veber Afonso Figueiredo Costa

Belo Horizonte  
2024

S237u	<p>Santos, Leonardo Rodrigues.  Utilização do Método <i>Bluecat</i> para correção de viés e estimação de incertezas na previsão de variáveis hidroclimáticas na Região Metropolitana de Belo Horizonte [recurso eletrônico] / Leonardo Rodrigues Santos. – 2024.  1 recurso online (117 f. : il., color.) : pdf.</p> <p>Orientador: Veber Afonso Figueiredo Costa.</p> <p>Dissertação (mestrado) – Universidade Federal de Minas Gerais, Escola de Engenharia.</p> <p>Bibliografia: f. 108-117.</p> <p>1. Engenharia sanitária – Teses. 2. Recursos hídricos – Teses. 3. Climatologia – Teses. 4. Modelos estocásticos – Teses. 5. Belo Horizonte, Região Metropolitana de (MG) – Teses. I. Costa, Afonso Figueiredo Costa. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.</p> <p style="text-align: right;">CDU: 628(043)</p>
-------	--



UNIVERSIDADE FEDERAL DE MINAS GERAIS  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SANEAMENTO, MEIO AMBIENTE E RECURSOS HÍDRICOS

### **FOLHA DE APROVAÇÃO**

"Utilização do Método Bluecat Para Correção de Viés e Estimação de Incertezas Na Previsão de Variáveis Hidroclimáticas na Região Metropolitana de Belo Horizonte"

**LEONARDO RODRIGUES SANTOS**

Dissertação defendida e aprovada pela banca examinadora constituída pelos Senhores:

Prof. Veber Afonso Figueiredo Costa

Prof. Francisco Eustáquio Oliveira e Silva

Prof. Luiz Rafael Palmier

Prof. Eduardo Mario Menciondo

Aprovada pelo Colegiado do PG SMARH

Versão Final aprovada por

Profa. Priscilla Macedo *Moura*

Prof. Veber Afonso Figueiredo Costa

Coordenadora

Orientador

Belo Horizonte, 19 de fevereiro de 2024.



Documento assinado eletronicamente por **Veber Afonso Figueiredo Costa, Professor do Magistério Superior**, em 19/02/2024, às 14:17, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Eduardo Mario Menciondo, Usuário Externo**, em 22/02/2024, às 07:57, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Francisco Eustaquio Oliveira e Silva, Professor do Magistério Superior**, em 29/10/2024, às 10:14, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luiz Rafael Palmier, Membro**, em 30/10/2024, às 14:52, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Eduardo Coutinho de Paula, Coordenador(a) de curso de pós-graduação**, em 11/11/2024, às 11:25, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufmg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **3031517** e o código CRC **595C3436**.

## AGRADECIMENTOS

À minha família.

À Alyne, pelo apoio nas horas difíceis.

Ao professor Veber Costa pela orientação, paciência, excelente visão crítica e apoio nas horas difíceis do desenvolvimento deste trabalho.

Aos professores Eduardo Mendiando, Francisco Silva e Palmier, pelos comentários e contribuições pertinentes ao trabalho.

Ao colega de profissão Guilherme Vieira, pelo apoio com o código para o *download* dos dados de modelos climáticos.

À professora Talita, pela oportunidade de participar de seu projeto de pesquisa, além das contribuições nas bancas de seminário.

Ao professor André, pelas contribuições nos seminários.

Aos colegas Alan Barbosa, Vinícios Raposo e Luiza Virgínia, pelas dicas de programação.

Aos meus colegas de turma (2022/1), pelo companheirismo nesta caminhada árdua que é o programa.

Aos professores do EHR/CPH, por promoverem este excelente curso.

A qualquer outra pessoa, esquecida pelo autor, que tenha contribuído para o desenvolvimento deste trabalho. Já peço o perdão.

## RESUMO

Mudanças climáticas têm sido uma preocupação crescente devido aos riscos que apresentam, especialmente em áreas vulneráveis. O Painel Intergovernamental sobre Mudanças Climáticas (IPCC) é uma fonte importante de pesquisas sobre mudanças climáticas, fornecendo uma base de informações relacionadas a cenários de emissões, além de revisões de modelos climáticos por terceiros e recomendações de abordagens para documentar projeções futuras. Esses cenários são obtidos em função de condições de emissão de poluentes atmosféricos e gases do efeito estufa, ou seja, fatores que influenciam na variação da temperatura global. O clima futuro em função destes cenários é normalmente projetado em modelos climáticos de circulação global (GCMs), que são modelos matemáticos que representam de forma integrada a dinâmica dos sistemas terrestres e atmosféricos, incluindo os efeitos das atividades humanas (CMIP 6). Ressalta-se que os modelos são elaborados em escalas globais, o que pode resultar em saídas enviesadas quando aplicados a áreas de menor magnitude, ou seja, projeções de modelos climáticos necessitam correção de viés pois, normalmente, não são aderentes aos dados observados. Quando usados para fins de engenharia e pesquisa científica, a quantificação das incertezas e a inferência estatística dos resultados de um modelo GCM se faz necessária para tomadas de decisão adequadas tanto do ponto de vista da segurança quanto econômico. Como uma maneira prática e rápida de quantificar as incertezas de um modelo determinístico, Koutsoyiannis e Montanari (2021) apresentam o modelo *Bluecat* (*Brisk Local Uncertainty Estimator for Generic Simulations and Predictions*), capaz de transformar modelos determinísticos em estocásticos, com base nos dados observados de uma dada variável hidrológica. Este trabalho tem como objetivo avaliar a eficácia do método *Bluecat* para quantificar incertezas, avaliar a capacidade do modelo de correção de viés sobre diferentes cenários de emissão do IPCC, além de investigar a influência de cada modelo determinístico GCM (i.e., cenários de evolução de temperatura e precipitação) para a Região Metropolitana de Belo Horizonte. Foram estudados os cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5 do CMIP 6 para chuva e temperatura média mensal. Ao aplicar o método *Bluecat* verificou-se indiferença nas projeções de chuva mensal e pouca representatividade dos cenários de temperatura ao processo estocástico real.

Palavras-chave: *Bluecat*, IPCC, Modelos Climáticos, Processos Estocásticos.

## ABSTRACT

Climate change has been an increasing concern due to the risks it presents, especially in vulnerable areas. The Intergovernmental Panel on Climate Change (IPCC) is a significant source of information and research on climate change, providing a foundation of information related to emission scenarios, as well as reviews of third-party climate models and recommendations for approaches to document future projections. These emission scenarios are obtained based on conditions of atmospheric pollutant and greenhouse gas emissions, that is, factors that influence global temperature variation. Future climate based on emission scenarios is typically projected in global circulation climate models (GCMs), which are mathematical models that integrally represent the dynamics of terrestrial and atmospheric systems, including the effects of human activities (CMIP6). It is emphasized that the models are developed on global scales, which can result in biased outputs when applied to areas of smaller magnitude, meaning climate model projections need bias correction since they usually do not adhere to observed data. When used for engineering and scientific research purposes, the quantification of uncertainties and the statistical inference of GCM model results are necessary for appropriate decision-making from both safety and economic viewpoints. As a practical and rapid way to quantify the uncertainties of a deterministic model, Koutsoyiannis and Montanari (2021) present the Bluecat model (Brisk Local Uncertainty Estimator for Generic Simulations and Predictions), capable of transforming deterministic models into stochastic ones, based on observed data of a given hydrological variable. The present work aims to evaluate the effectiveness of the Bluecat method in quantifying uncertainties, assess the model's bias correction capability across different IPCC emission scenarios, and investigate the influence of each deterministic GCM model (i.e., scenarios of temperature and precipitation evolution) for the Metropolitan Region of Belo Horizonte. The SSP1-2.6, SSP2-4.5, and SSP5-8.5 scenarios of CMIP6 for monthly average rain and temperature were studied. Upon applying the method Bluecat, indifference was observed in the monthly rain projections and little representativeness of the temperature scenarios to the real stochastic process.

Keywords: Bluecat, IPCC, Climate Models, Stochastic Processes.

## LISTA DE FIGURAS

Figura 1 – Comparação entre dados de chuva mensal (mm/dia) observada e chuva mensal obtida da média dos GCMs (ambos subtraídos da média mensal, ou seja, apenas a parcela aleatória) .....	19
Figura 2 – Comparação de temperaturas médias mensais (°C) entre o modelo de reanálise e a média do histórico dos GCMs. ....	20
Figura 3 – Variação da temperatura e do nível de CO <sub>2</sub> dos últimos 160.000 anos na Antártida .....	26
Figura 4 – Representação esquemática das respostas rápidas e lentas do balanço de energia atmosférica e da precipitação global ao forçamento radiativo. ....	27
Figura 5 – Representação esquemática de um modelo hidrológico. ....	29
Figura 6 – Diagrama de fluxo relacionando Caminhos Socioeconômicos Compartilhados (SSPs), Caminhos de Concentração Representativa (RCPs) e projeções climáticas e seus diferentes modelos usados .....	36
Figura 7 – Aumento temperatura da superfície global em função de cada cenário SSP. ....	37
Figura 8 – Distribuição bidimensional. O gráfico de bidimensional indica a função de densidade de probabilidade multivariada. Os pontos indicam uma amostra da distribuição. As cores azul e laranja indicam funções de densidade de probabilidade marginais. ....	44
Figura 9 – Ilustração gráfica de $\Delta m(t)$ .....	46
Figura 10 – Fluxograma do procedimento de simulação de Monte Carlo para realização da integração numérica nas equações (12) e (13) .....	49
Figura 11 – Representação esquemática do conceito do método Bluecat subjacente à transformação do modelo determinístico (modelo D) para um modelo estocástico (modelo S) .....	51
Figura 12 – Estações pluviométricas consideradas para o estudo (elaborado no <i>software</i> QGIS). ....	55
Figura 13 – Dupla Massa – Estação 1943023 .....	56
Figura 14 – Dupla Massa – Estação 1944004 .....	56
Figura 15 – Dupla Massa – Estação 83587 .....	57

Figura 16 – Polígonos de Thiessen para espacialização da chuva.....	58
Figura 17 – Dados mensais observados – Chuva mensal (mm) .....	59
Figura 18 – Gráfico Box-plot – Chuva mensal (mm) .....	59
Figura 19 – Dados mensais observados – Temperatura média (°C).....	60
Figura 20 – Dados mensais observados – Temperatura média anual (°C).....	61
Figura 21 – Normais climatológicas – temperatura média – estação Conceição do Mato Dentro.....	63
Figura 22 – Normais climatológicas – Temperatura média – estação Belo Horizonte. ....	63
Figura 23 – Normais climatológicas – Temperatura média – estação Sete Lagoas. ....	64
Figura 24 – Normais climatológicas – Temperatura média – estação Ibirité. ....	64
Figura 25 – Normais climatológicas – Chuva mensal – estação Conceição do Mato Dentro.....	65
Figura 26 – Normais climatológicas – Chuva mensal – estação Belo Horizonte.....	65
Figura 27 – Normais climatológicas – Chuva mensal – estação Sete Lagoas. ....	66
Figura 28 – Normais climatológicas – Chuva mensal – estação Estação Ibirité.....	66
Figura 29 – Amostra de q e Q.....	68
Figura 30 – Distribuição condicional $F_{q Q}$ $q Q = -1,75$ . ....	68
Figura 31 – Distribuição espacial dos <i>grids</i> considerados no modelo.....	70
Figura 32 – Valores de chuva anual de cada modelo climático e valor médio do período histórico (1950 – 2014).....	71
Figura 33 – Valores de chuva anual de cada modelo climático e valor médio – projeções do cenário SSP1-2.6 (2015 – 2100).....	71
Figura 34 – Valores de chuva anual de cada modelo climático e valor médio – projeções do cenário SSP2-4.5 (2015 – 2100).....	71
Figura 35 – Valores de chuva anual de cada modelo climático e valor médio – projeções do cenário SSP5-8.5 (2015 – 2100).....	72
Figura 36 – Valores de temperatura média anual de cada modelo climático e valor médio do período histórico (1950 – 2014).....	73
Figura 37 – Valores de temperatura média anual de cada modelo climático e valor médio – projeções do cenário SSP1-2.6 (2015 – 2100).....	73
Figura 38 – Valores de temperatura média anual de cada modelo climático e valor médio – projeções do cenário SSP2-4.5 (2015 – 2100).....	73

Figura 39 – Valores de temperatura média anual de cada modelo climático e valor médio – projeções do cenário SSP5-8.5 (2015 – 2100).....	74
Figura 40 – Trajetórias suavizadas de Q e q50 .....	75
Figura 41 – Correção de Q para W.....	75
Figura 42 – Probabilidade de cobertura (90%) do período histórico (1961 – 2011) e do período teste (2012 – 2021) – chuva mensal .....	76
Figura 43 – Probabilidade de cobertura (90%) do período histórico (1961 – 2011) e do período teste (2012 – 2021) – temperatura média mensal.....	77
Figura 44 – Valores de q e Q no período de validação – as linhas tracejadas indicam o limite onde a expansão deverá ser aplicada .....	78
Figura 45 – Valores Q no período de validação.....	79
Figura 46 – Aproximação dos valores de cQ para amostra $Q(m + 1:m) < Q < Q(n - m:n)$ . .....	79
Figura 47 – Histograma dos dados mensais de temperatura (q) subtraídos da média .....	80
Figura 48 – Histograma dos dados mensais de temperatura (QSSP1-2.6) subtraídos da média.....	80
Figura 49 – Histograma dos dados mensais de temperatura (QSSP5-8.5) subtraídos da média.....	81
Figura 50 – histograma dos dados mensais de temperatura (QSSP2-4.5) subtraídos da média.....	81
Figura 51 – q e projeção estocástica versus modelo determinístico – cenários SSPs .....	83
Figura 52 – q x Q – Chuva – cenário: SSP1-2.6 .....	84
Figura 53 – q x Q – Chuva – cenário: SSP2-4.5 .....	85
Figura 54 – q x Q – Chuva – cenário: SSP5-8.5 .....	85
Figura 55 – q x Q – Temperatura – cenário: SSP1-2.6 .....	86
Figura 56 – q x Q – Temperatura – cenário: SSP2-4.5. ....	86
Figura 57 – q x Q – Temperatura – cenário: SSP5-8.5 .....	87
Figura 58 – Resultados do método Bluecat para o período histórico de chuva mensal (mm/d).....	87
Figura 59 – Resultados do método Bluecat para o período histórico de temperatura mensal (°C) .....	88

Figura 60 – Resultados do método Bluecat para o período histórico de chuva mensal – média móvel de 12 meses (mm/d) .....	88
Figura 61 – Resultados do método Bluecat para o período histórico de temperatura mensal – média móvel de 12 meses (°C) .....	88
Figura 62 – Resultados método Bluecat para a projeção de chuva no cenário de menor emissão (SSP1-2.6) .....	90
Figura 63– Resultados do método Bluecat para a projeção de chuva no cenário mediano (SSP2-4.5) .....	90
Figura 64 – Resultados do método Bluecat para a projeção de chuva no cenário maior emissão (SSP5-8.5) .....	90
Figura 65 – Resultados do método Bluecat para a projeção de chuva no cenário mediano (SSP1-2.6) – média móvel de 12 meses .....	91
Figura 66 – Resultados do método Bluecat para a projeção de chuva no cenário mediano (SSP2-4.5) – média móvel de 12 meses .....	91
Figura 67 – Resultados do método Bluecat para a projeção de chuva no cenário de maior emissão (SSP5-8.5) – média móvel de 12 meses.....	91
Figura 68 – Resultados do método Bluecat para a projeção de temperatura no cenário de menor emissão (SSP1-2.6) .....	92
Figura 69 – Resultados do método Bluecat para a projeção de temperatura no cenário mediano (SSP2-4.5) .....	92
Figura 70 – Resultados do método Bluecat para a projeção de temperatura no cenário de maior emissão (SSP5-8.5) .....	93
Figura 71 – Resultados do método Bluecat para a projeção de temperatura no cenário mediano (SSP1-2.6) – média móvel de 12 meses .....	93
Figura 72 – Resultados do método Bluecat para a projeção de temperatura no cenário mediano (SSP2-4.5) – média móvel de 12 meses .....	93
Figura 73 – Resultados do método Bluecat para a projeção de temperatura no cenário de maior emissão (SSP5-8.5) – média móvel de 12 meses.....	94
Figura 74 – Resultados mensais – Chuva – SSP1-2.6 .....	96
Figura 75 – Resultados mensais – Chuva – SSP2-4.5 .....	97
Figura 76 – Resultados mensais – Chuva – SSP5-8.5 .....	98
Figura 77 – Resultados mensais – Temperatura – SSP1-2.6 .....	99
Figura 78 – Resultados mensais – Temperatura – SSP2-4.5 .....	100
Figura 79 – Resultados mensais – Temperatura – SSP5-8.5 .....	101

Figura 80 – Viés do modelo corrigido: temperatura – SSP1-2.6 .....	102
Figura 81 – Viés do modelo corrigido: temperatura – SSP2-4.5 .....	103
Figura 82 – Viés do modelo corrigido: temperatura – SSP5-8.5 .....	103
Figura 83 – Temperatura média anual – histórico observado e projeções corrigidas .....	103

## LISTA DE QUADROS

Quadro 1 – Caracterização dos Caminhos de Concentração Representativos (RCP) .....	36
Quadro 2 – Caracterização dos <i>Shared Socioeconomic Pathways</i> (SSPs) .....	37
Quadro 3 – Variáveis incluídas no arquivo NEX-GDDP-CMIP6 *Tas (temperatura do ar próximo à superfície) é fornecida para modelos que não fornecem tasmax e tasmin; caso contrário, tas é derivado de tasmax e tasmin .....	39
Quadro 4 – Modelos CMIP6 incluídos no arquivo reduzido. Legenda: Verde = todos os experimentos disponíveis; amarelo = histórico e alguns SSP(s) disponíveis; vermelho = nenhum dado disponível. *Saída original do GCM para o hurs SSP245 faltando ano 2058.....	40
Quadro 5 – Constantes de extrapolação encontradas para cada cenário.....	84

## LISTA DE TABELAS

Tabela 1 – Probabilidades de cobertura no período teste – chuva mensal.....	76
Tabela 2 – Probabilidades de cobertura no período teste – temperatura média mensal .....	77
Tabela 3 – Probabilidades de cobertura no período histórico de chuva e temperatura .....	89
Tabela 4 – Intervalo de confiança médio para período histórico e projeção dos três cenários – chuva e temperatura .....	94

## **LISTA DE ABREVIATURAS E SIGLAS**

ANA – Agência Nacional de Águas e Saneamento Básico

BCSD – Bias-Correction Spatial Disaggregation

cGAN - Redes Adversárias Generativas Fisicamente Restritivas

CMIP5 - Coupled Model Intercomparison Project Phase 5

CMIP6 – Coupled Model Intercomparison Project Phase 6

DAEE – Departamento de Águas e Energia Elétrica do Estado de São Paulo

ECMWF – European Centre for Medium-Range Weather Forecasts

FDP – Função de Densidade de Probabilidade

GCM – Global Climate Models

GEE – Gases do Efeito Estufa

GMFD – Global Meteorological Forcing Dataset

IAM – Integrated Assessment Models

ICMM – International Council on Mining & Metals

INMET – Instituto Nacional de Meteorologia

IPCC – Intergovernmental Panel on Climate Change

MQ – Mapeamento de Quantil

NEX-GDDP – NASA Earth Exchange Global Daily Downscaled Projections

PMP – Precipitação Máxima Provável

PRI – Principles for Responsible Investment

QDM – Quantile Delta Mapping

RCP – Representative Concentration Pathways

RMBH – Região Metropolitana de Belo Horizonte

SSP – Shared Socioeconomic Pathways

UNEP – United Nations Environment Programme

WGEN – Weather Generator

WMO – World Meteorological Organization

## SUMÁRIO

1	INTRODUÇÃO .....	17
2	OBJETIVOS .....	22
2.1	Objetivo geral .....	22
2.2	Objetivos específicos .....	22
3	REVISÃO DE LITERATURA .....	23
3.1	Clima e mudanças climáticas .....	23
3.2	Efeitos das mudanças climáticas nas variáveis do ciclo hidrológico .....	25
3.3	Processos e modelos estocásticos .....	29
3.3.1	Modelo de séries temporais .....	31
3.3.2	Conceitos de estacionariedade e ergodicidade .....	32
3.3.3	Geradores estocásticos de variáveis climáticas .....	33
3.4	Clima Futuro e cenários de emissão .....	34
3.4.1	Cenários de emissão .....	34
3.4.2	Modelos de Circulação Global (GCMs) .....	38
3.4.3	Projeções regionais de mudanças climáticas .....	40
3.5	Métodos de correção de viés de modelos climáticos .....	42
3.5.1	Conceito de viés .....	43
3.5.2	Mapeamento de quantil .....	45
3.5.3	Mapeamento Delta do Quantil (QDM) .....	45
3.5.4	<i>Deep Learning</i> .....	46
3.6	<i>Brisk Local Uncertainty Estimator for Generic Simulations and Predictions (Bluecat)</i> .....	47
3.6.1	Modelagem baseada em processos de sistemas hidrológicos incertos ..	47
3.6.2	<i>Bluecat</i> : Um Estimador de Incerteza Local para Simulações e Previsões Determinísticas .....	49
3.6.3	<i>Bluecat</i> expandido: extrapolação climática em hidrologia .....	52
4	METODOLOGIA .....	54
4.1	Definição das variáveis hidroclimáticas e cenários .....	54
4.1.1	Dados observados de chuva .....	54
4.1.2	Dados observados de temperatura média .....	59
4.2	Descrição da área de estudo .....	61
4.2.1	Região Metropolitana de Belo Horizonte .....	61
4.2.2	Climatologia típica da região .....	62
4.3	Aplicação do modelo <i>Bluecat</i> para cenários do IPCC .....	67
4.4	Validação do modelo .....	68
4.5	Projeções climáticas .....	69

4.5.1	Chuva .....	70
4.5.2	Temperatura média .....	72
4.6	Correção de viés .....	74
5	APLICAÇÃO DO MÉTODO BLUECAT PARA DIFERENTES CENÁRIOS DO IPCC ..	76
5.1	Resultados da validação do método .....	76
5.2	Tratamento dos dados observados e dos modelos determinísticos.....	79
5.3	Resultados sem sazonalidade .....	82
5.3.1	Constantes de extrapolação .....	84
5.3.2	Período histórico.....	87
5.3.3	Período projetado .....	89
5.4	Resultados com sazonalidade .....	94
5.5	Correção de viés das projeções.....	102
6	CONCLUSÕES E RECOMENDAÇÕES.....	104
7	REFERÊNCIAS.....	108

## 1 INTRODUÇÃO

Muitas vezes cientistas e engenheiros precisam considerar projeções futuras de variáveis climáticas em seus estudos. Nesses estudos, a ideia de clima estático no longo termo pode se tornar frágil, uma vez que não há dúvidas de que o clima irá se modificar ao longo do tempo, seja por causas naturais ou antrópicas, como sempre ocorreu na natureza (KOUTSOYIANNIS; MONTANARI, 2022).

O impacto do clima sobre os recursos hídricos é um fato de grande relevância social e ambiental. Em situações extremas, a variabilidade climática pode comprometer a sustentabilidade da sociedade e da conservação ambiental, afetando setores como (TUCCI e BRAGA, 2003):

1. Abastecimento urbano: comunidades em regiões semiáridas, localidades abastecidas por rios de pequeno porte e mananciais urbanos com demanda acima da capacidade da disponibilidade hídrica possuem maior fragilidade com relação à variabilidade climática;
2. Irrigação: em um período crítico de disponibilidade hídrica, há risco de conflito com empresas de abastecimento, que exigirem medidas fortes para inverter a prioridade prevista na legislação para o abastecimento humano;
3. Energia hidroelétrica:
  - Previsão de curto prazo e volume de espera: a previsão de curto prazo permite o equilíbrio entre produção energética e o volume de espera, ou seja, permite gerenciar o reservatório com maior eficiência;
  - Segurança de barragens: A legislação exige que barragens com alto dano potencial associado ao seu rompimento hipotético tenha o seu sistema extravasor dimensionado para uma cheia com Tempo de Retorno (TR) máximo de projeto de 10.000 anos, ou seja, o risco de rompimento de uma barragem pela falha do seu sistema extravasor é da ordem de  $10^{-4}$ . As cheias de projeto proveniente de eventos hidrológicos com esse TR são usualmente calculadas por análise de frequência de séries históricas de chuva ou vazão. Comumente, admite-se hipótese de aleatoriedade, homogeneidade, independência e estacionariedade para cálculo das vazões de projeto (NAGHETTINI; PINTO, 2007). Essas

hipóteses são associadas ao processo estocástico subjacente, e não à amostra observada.

- Tendências: um sistema hidrelétrico com pouca folga de oferta está sujeito ao risco de comprometimento das atividades econômicas, devido à ocorrência de variações climáticas, cíclicas e de longo prazo. É necessário, então, estabelecer uma estratégia para a eventualidade do impacto da redução da disponibilidade hídrica do sistema de produção hidrelétrico;
- 4. Navegação: o sistema hidroviário é uma das importantes alternativas ao transporte rodoviário e ferroviário. No entanto, é dependente das variações dos níveis dos rios e de sua previsão a médio e curto prazo;
- 5. Qualidade e tratamento da água: na maioria dos sistemas hídricos as condições críticas de qualidade da água ocorrem durante as estiagens, quando a vazão nos rios diminui, junto com a capacidade de diluição das cargas de poluentes; e
- 6. Inundações: alterações nos padrões climáticos que agravam a frequência de eventos extremos.


Tais questões motivam projetos de pesquisa a explorar as “mudanças climáticas”, tal qual o projeto “Urbanização e mudanças climáticas: avaliação de impactos e estratégias de adaptação para bacias e reservatórios urbanos” (SILVA *et al*, 2022), para o qual esta dissertação colabora. Além da questão sobre o impacto das mudanças climáticas sobre os recursos hídricos em ambientes e reservatórios urbanos, as mudanças climáticas também são preocupação em outros setores da economia, como, por exemplo, a exploração mineral. O Padrão Global da Indústria para a Gestão de Rejeitos (ICMM, UNEP e PRI, 2020) recomenda que, para novas estruturas de disposição de rejeitos, devem ser levadas em consideração as incertezas relacionadas às mudanças climáticas. Há de se destacar que Minas Gerais é o estado de maior produção mineral do país (BRASIL, 2023a), e boa parte dessa exploração fica próxima à Região Metropolitana de Belo Horizonte (RMBH).

De acordo com IPCC (2022), o comportamento do clima futuro depende do crescente aumento da concentração de gases do efeito estufa de origem fóssil na atmosfera por atividades antrópicas. Seus efeitos demandam a criação de modelos matemáticos que

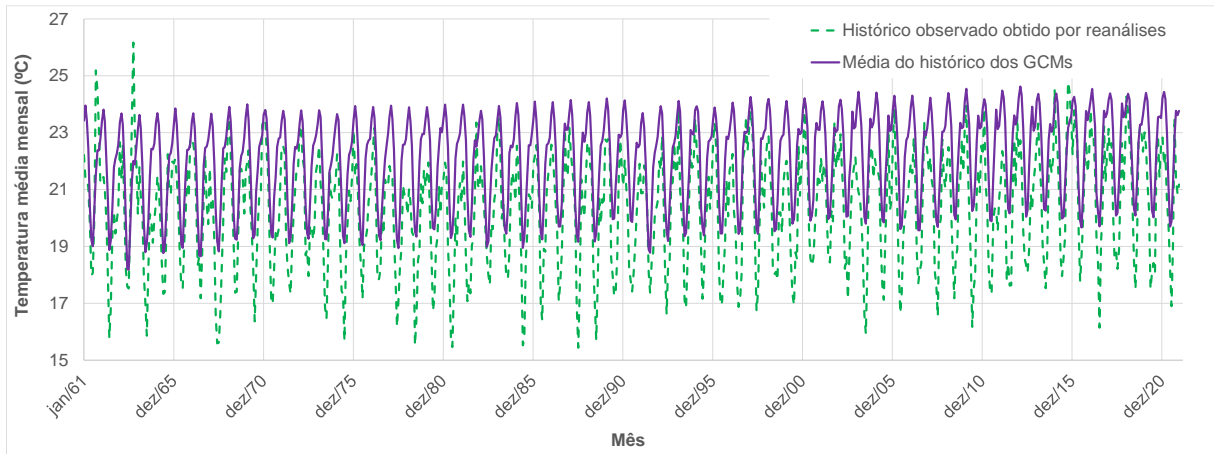
permitam prognosticar o comportamento do clima futuro em escalas de tempo de semanas a séculos. No entanto, os desafios conceituais e práticos são grandes. A atmosfera, os oceanos, a biosfera e a criosfera interagem entre si de modo não linear e caótico (BRASIL, 2016). A consideração da atividade humana torna os modelos mais completos e abrangentes, porém o maior número de parâmetros pode incorporar maior incerteza nos modelos. Por fim, a incapacidade dos modelos em agregar todas as variáveis atuantes no processo (assim como as respectivas relações de dependência) acarreta variados níveis de viés (referências). Portanto, para elaborar estudos da área de recursos hídricos considerando mudanças ambientais, torna-se imprescindível a inferência estatística e correção de viés dos modelos, de modo que seja possível estimar o grau de incerteza correspondente.

Um modelo enviesado pode ser visualizado, por exemplo, pela falta de variabilidade da parcela aleatória do processo estocástico, como se pode observar na Figura 1, na qual os dados de chuva, subtraídos de sua média ( $q$ ), apresentam maior dispersão do que as estimativas obtidas pelos Modelos de Circulação Global (da sigla em inglês GCMs) sem sazonalidade ( $Q$ ). Já o gráfico da Figura 2 apresenta nítida falta de aderência entre os dados históricos provenientes de reanálise e a média entre os dados históricos dos GCMs, o que indica a incapacidade do GCM em representar as observações.

**Figura 1 – Comparação entre dados de chuva mensal (mm/dia) observada e chuva mensal obtida da média dos GCMs (ambos subtraídos da média mensal, ou seja, apenas a parcela aleatória)**



**Figura 2 – Comparação de temperaturas médias mensais (°C) entre o modelo de reanálise e a média do histórico dos GCMs.**



É evidente que há um grau de não correspondência entre estimativas de modelos e observações para ambas as variáveis. Desta forma, técnicas de correção de viés procuram aproximar as estatísticas das variáveis climáticas observadas com as variáveis climáticas obtidas de GCMs. Em geral, a técnica mais empregada na correção de viés é o mapeamento de quantil, o qual para corrigir vieses distributivos sistemáticos em resultados de variáveis de modelos climáticos. Destaca-se que o mapeamento de quantil (MQ) vem sendo aprimorado por meio de técnicas de redes neurais (HESS *et al.*, 2023), como forma de melhorar a representatividade espacial dos modelos corrigidos. De acordo com Hess *et al.* (2023), a aplicação de redes neurais é capaz de corrigir as simulações Modelos de Sistema Terrestre (MST) em dois aspectos: distribuições temporais em longas escalas de tempo, incluindo extremos nas caudas das distribuições, bem como padrões espaciais de instantâneos globais individuais da saída do modelo.

As técnicas de correção de viés são empregadas para medidas de tendência central e, por consequência, os GCMs geralmente não conseguem reproduzir a variabilidade observada. Cannon *et al.* (2015) aplicaram o mapeamento de quantis para correção de viés de GCMs no âmbito do *Coupled Model Intercomparison Project Phase 5* (CMIP5) e observaram que o referido método pode corromper artificialmente as tendências futuras projetadas pelo modelo. De acordo com os autores, o grau de corrupção nas tendências do GCM, por QM, é especialmente grande para mudanças nos valores de retorno de longo período.

No entanto, os trabalhos citados não apresentam os intervalos de confiança para os modelos, ou seja, não se tem a incerteza das estimativas do modelo. Os GCMs são modelos determinísticos e, na prática utiliza-se, para o cenário desejado, o maior número possível de projeções dos GCMs, de modo a se obter uma variabilidade de resultados. Esse conjunto de projeções é chamado de *ensemble*.

Com o objetivo de inferir as incertezas atreladas aos modelos determinísticos (e.g., 90%), Koutsoyiannis e Montanari (2022) propuseram o modelo “*Brisk local uncertainty estimator for generic simulations and predictions*” (*Bluecat*). Esse método parte da premissa de que os modelos determinísticos (modelo-D) podem ser transformados em modelos estocásticos com base nas observações da variável de interesse. O *Bluecat* se mostra uma ferramenta vantajosa com relação a outros métodos, pois, além de corrigir o viés, fornece a distribuição condicional para todos os dados do modelo-D.

Nesse sentido, este trabalho irá tratar da aplicação do modelo *Bluecat* para resultados de projeções climáticas da Região Metropolitana de Belo Horizonte (RMBH), avaliando a sua capacidade descritiva e preditiva para diferentes cenários de emissão propostos pelo Painel Intergovernamental de Mudanças Climáticas (IPCC). Além deste capítulo de introdução, esta dissertação é organizada da seguinte forma: o Capítulo 2 discorre sobre os objetivos geral e específicos da pesquisa. No Capítulo 3 é apresentada a revisão dos principais conceitos sobre clima, mudanças climáticas, efeito das mudanças climáticas no ciclo hidrológico, variáveis hidroclimáticas, processos estocásticos, cenários de emissão e métodos de correção de viés. Já no capítulo 4 é apresentada a metodologia empregada nesta dissertação: tratamento dos dados históricos observados, tratamento dos dados dos GCMs para cenários de menor emissão, emissão média e maior emissão, aplicação do método *Bluecat* e correção de viés dos modelos climáticos. O capítulo 5 apresenta os resultados obtidos da aplicação do *Bluecat*; e, no capítulo 6, são abordadas as conclusões e recomendações.

## 2 OBJETIVOS

### 2.1 Objetivo geral

Avaliar as capacidades descritiva e preditiva do método *Bluecat* para correção de viés e quantificação de incertezas das estimativas de temperatura e precipitação oriundas das projeções do Painel Intergovernamental sobre Mudanças Climáticas (IPCC) na Região Metropolitana de Belo Horizonte (RMBH).

### 2.2 Objetivos específicos

A seguir são apresentados os objetivos específicos:

- Avaliar a capacidade do método de correção de viés dos modelos determinísticos sob diferentes cenários de emissão da 6ª fase do Projeto de Intercomparação de Modelos Acoplados (do inglês CMIP6);
- Investigar a influência de cada modelo determinístico (i.e., cenários de evolução de temperatura e precipitação) na largura dos intervalos de confiança;
- e
- Avaliar a capacidade do modelo para reproduzir eventuais tendências monotônicas diante da evidência nas variáveis observadas.

### 3 REVISÃO DE LITERATURA

#### 3.1 Clima e mudanças climáticas

A *World Meteorological Organization* (WMO, 1992) define clima como sendo a síntese das condições meteorológicas de uma determinada área, caracterizada por estatísticas de longo prazo (valores médios, variâncias, probabilidades de valores extremos etc.) dos elementos meteorológicos dessa área (WMO, 1992).

De acordo com o IPCC (2013), o clima pode ser definido:

“O clima, num sentido estrito, é geralmente definido como o tempo médio, ou mais rigorosamente, como a descrição estatística em termos da média e da variabilidade de quantidades relevantes durante um período que varia de meses a milhares ou milhões de anos. O período clássico para calcular a média dessas variáveis é de 30 anos, conforme definido pela Organização Meteorológica Mundial. As quantidades relevantes são na maioria das vezes variáveis de superfície, como temperatura, precipitação e vento. O clima, num sentido mais amplo, é o estado, incluindo uma descrição estatística, do sistema climático”.

Nota-se, pelas definições apresentadas, que o clima está relacionado diretamente com localização geográfica, estatísticas das variáveis meteorológicas desse local (variáveis hidroclimáticas) e período analisado.

Dada a definição de clima, Koutsoyiannis (2021) apresenta as seguintes definições sobre sistema climático e processos climáticos:

“Sistema climático é o sistema que consiste na atmosfera, na hidrosfera (incluindo sua fase sólida - a criosfera), na litosfera e na biosfera, que interagem mutuamente e respondem a influências externas (entradas do sistema), especialmente aquelas que determinam a radiação solar que atinge a Terra, como a atividade solar, o movimento da Terra e a atividade vulcânica.”

“Processos climáticos são os processos físicos, químicos e biológicos que são produzidos pelas interações e respostas dos componentes do sistema climático por meio de fluxos de energia e massa, e reações químicas e biológicas.”

De acordo com WMO (1992), as mudanças climáticas são definidas como:

1) No sentido mais geral, o termo "mudanças climáticas" abrange todas as formas de inconstância climática (ou seja, quaisquer

diferenças entre estatísticas de longo prazo dos elementos meteorológicos calculados para períodos diferentes, mas relativos à mesma área), independentemente da sua natureza estatística ou causas físicas. As alterações climáticas podem resultar de fatores como alterações na emissão solar, alterações de longo período nos elementos orbitais da Terra (excentricidade, obliquidade da eclíptica, precessão dos equinócios), processos internos naturais do sistema climático ou forçantes antropogênicas (por exemplo, aumento das concentrações atmosféricas de dióxido de carbono e outros gases de efeito estufa.).

2) O termo "mudanças climáticas" é frequentemente utilizado num sentido mais restrito, para denotar uma alteração significativa (isto é, uma alteração com importantes efeitos econômicos, ambientais e sociais) nos valores médios de um elemento meteorológico (em particular a temperatura ou a quantidade de precipitação) no decurso de um determinado período, em que os meios são medidos durante períodos da ordem de uma década ou mais.

Já o IPCC (2001) define "mudanças climáticas" como as mudanças de clima no tempo devido à variabilidade natural e/ou resultado das atividades humanas (ações antrópicas).

No Brasil e no mundo, os padrões das variáveis hidroclimáticas são observados, principalmente, pelos dados históricos das estações climáticas, pluviométricas e pluviográficas, além de dados de vazão das estações fluviométricas, que ajudam a entender as dinâmicas das bacias hidrográficas. Uma vez que não-homogeneidade do clima é verificada em uma série histórica, deve-se verificar as seguintes alternativas, segundo Tucci e Braga (2003):

- Mudança climática, tal qual definida anteriormente;
- Falta de representatividade das séries históricas para identificar a variabilidade natural dos processos climáticos;
- Alterações nas características físicas/químicas e biológicas da bacia hidrográfica devido a efeitos naturais e/ou antrópicos.

O conceito de mudança climática nesta dissertação refere-se exclusivamente aos cenários propostos pelo IPCC (item Cenários de emissão), na qual os padrões climáticos se alteram em função de taxas de emissão de gases do efeito estufa (GEE).

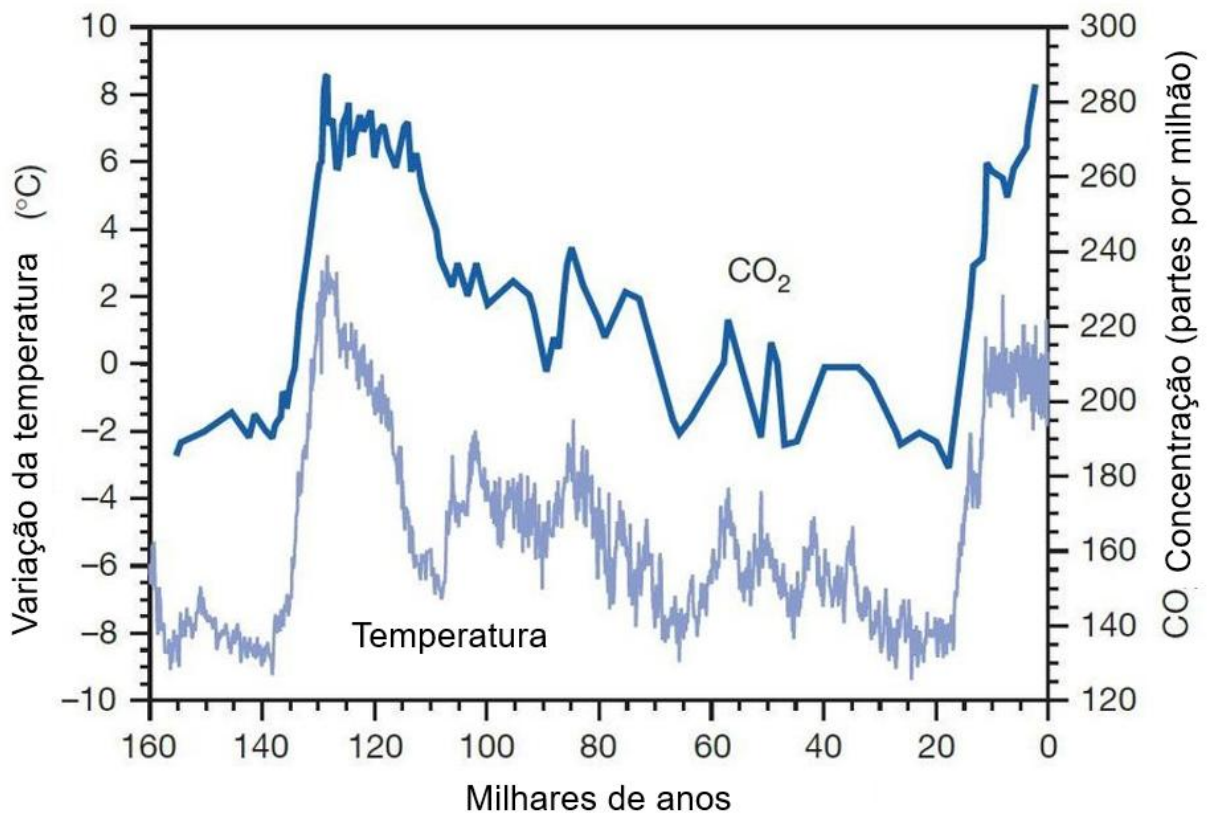
### 3.2 Efeitos das mudanças climáticas nas variáveis do ciclo hidrológico

Chuva, umidade do solo e cobertura de solo são fatores importantes para prever escoamento superficial sobre uma bacia (CHOKKAVARAPU; MANDLA, 2019). Os fluxos futuros de água podem ser calculados utilizando modelos de precipitação-vazão para analisar mudanças climáticas, utilizando dados climáticos por satélite como entrada meteorológica (CLERIDOU et al., 2014).

De acordo com Cleridou et al (2014) para entender o ciclo hidrológico da bacia, é necessário estimar os valores sazonais e anuais de precipitação, escoamento superficial, evaporação e taxas de recarga. A mudança climática pode impactar os recursos hídricos superficiais e subterrâneos (AWOTWI et al., 2015), como inundações severas, precipitação e temperatura, escoamento superficial e fluxo de base da bacia, afetando a evapotranspiração do ecossistema, a capacidade de infiltração do solo e os regimes de fluxo superficial e subsuperficial (QI, 2009).

No capítulo 3.4.1 serão apresentados os cenários propostos pelo IPCC para elaborar previsões climáticas em função de cenários de taxas de emissões de CO<sub>2</sub>. De acordo com Engel (2018), uma das principais evidências do aumento do efeito estufa citada na literatura é a forte correlação entre o CO<sub>2</sub> na atmosfera e a temperatura média do globo, apresentados na Figura 3**Erro! Fonte de referência não encontrada..**

Figura 3 – Variação da temperatura e do nível de CO<sub>2</sub> dos últimos 160.000 anos na Antártida




Fonte: Adaptado de Engel (2018)

As alterações globais de precipitação e evaporação são determinadas pelo balanço de energia da Terra (IPCC, 2021). Em escalas regionais, as alterações no ciclo d'água são regidas pelo transporte de umidade (DAGAN *et al.*, 2019; JAKOB *et al.*, 2019; DAGAN e STIER, 2020), os quais dependem de processos termodinâmicos.

De acordo com IPCC (2021), embora a termodinâmica exerça um forte controle sobre as mudanças no vapor d'água, a precipitação média global e a evaporação são limitadas pelo equilíbrio dos fluxos de energia na atmosfera e na superfície, conforme ilustrado na Figura 4.

Os painéis 1-3 na Figura 4 ilustram as respostas rápidas (horas – dias) de mudanças no saldo de energia atmosférica e propriedades atmosféricas (temperatura, nuvens e vapor d'água) a efeitos de um agente de forçamento radioativo (SHERWOOD *et al.*, 2015). O painel 3 ilustra as mudanças relativamente rápidas (dias a meses) do sistema climático, a qual envolve interações com a vegetação e a temperatura da superfície terrestre, as quais respondem de maneira mais rápida comparada à temperatura do oceano a uma forçante radioativa (CAO *et al.*, 2012; DONG *et al.*, 2014).

Figura 4 – Representação esquemática das respostas rápidas e lentas do balanço de energia atmosférica e da precipitação global ao forçamento radiativo.



Fonte: adaptado, Douville et al. (2021).

De acordo com Douville *et al.* (2021), as mudanças no saldo de radiação resultantes de alterações na concentração de gases de efeito estufa, aerossóis e albedo da superfície têm reflexos tanto em escalas globais quanto regionais, influenciando a evaporação e a precipitação. Skinner e Poulsen (2016) observam que o aumento do dióxido de carbono atmosférico geralmente reduz a transpiração das plantas, impactando a umidade do solo, as vazões em cursos d'água e o retorno de umidade para a atmosfera.

Aerossóis afetam a precipitação por meio de duas principais vias: alterando a radiação de ondas curtas e longas, e influenciando as propriedades microfísicas das nuvens (IPCC, 2021).

Aerossóis dispersam e absorvem a radiação solar, reduzindo a energia disponível para evaporação da superfície e, conseqüentemente, a precipitação. Segundo Douville *et al.* (2021), o aumento das taxas de emissão de gases de efeito estufa tem contribuído para ampliar as disparidades nas quantidades de precipitação entre as estações úmida e seca, afetando também os regimes climáticos em áreas tropicais, com resultados que possuem "média confiança" de acordo com os autores. Além disso, há um aumento detectável da precipitação em altas latitudes no hemisfério norte, com os autores atribuindo "alta confiança" a esses resultados.

As mudanças regionais na evapotranspiração (ET) são condicionadas por transformações tanto no clima quanto nas propriedades da superfície terrestre e dos ecossistemas. Este último também reage às mudanças no clima e na composição atmosférica. Por exemplo, em climas mais quentes, a demanda evaporativa aumenta (BERG *et al.*, 2016), enquanto totais sazonais de precipitação (HOVENDEN *et al.*, 2014) influenciam a quantidade de umidade do solo disponível para evaporação.

O relatório AR6 WGI (DOUVILLE *et al.*, 2021) destaca a identificação de uma tendência global (de crescimento ou decréscimo, a depender da região) na umidade do solo por meio de reanálises, atribuindo-a ao forçamento pelos gases de efeito estufa. Conclui-se, com alto grau de probabilidade, que as mudanças climáticas antropogênicas impactaram os padrões globais de umidade do solo ao longo do século XX.

### 3.3 Processos e modelos estocásticos

Uma série temporal é um conjunto de observações tomadas sequencialmente no tempo (BOX *et al.* 2016), podendo compreender, por exemplo, o preço médio mensal de ações de uma empresa, o número semanal de acidentes no trânsito na marginal Tietê em São Paulo ou a variação diária do nível do reservatório de um lago urbano.

Engenheiros de recursos hídricos tomam séries de variáveis hidroclimáticas para elaboração de estudos de análises de frequência (local ou regional), de modo a subsidiar projetos de obras hidráulicas. Essas, por sua vez, são dimensionadas para uma determinada probabilidade de falha. Normalmente, a probabilidade de falha é atrelada a um tempo de retorno (TR), definido, segundo Koutsoyiannis (2021) como um tempo médio de ocorrências consecutivas de um dado evento  $A$ , associado a uma probabilidade de ocorrência  $P$ .

Uma vez definida a variável hidrológica a ser trabalhada, essa pode se tornar uma variável de entrada ( $I(t)$ ) de um modelo hidrológico, definido por um operador  $\psi$ , que vai resultar em um resultado de saída ( $Q(t)$ ), conforme apresentado na Figura 5.

Figura 5 – Representação esquemática de um modelo hidrológico.



As variáveis de entrada são transformadas, por meio de um modelo matemático, em variáveis de saída. Sendo o modelo hidrológico podendo ser classificado em dois tipos: probabilística/aleatória ou determinística. São chamadas de aleatórias ou probabilísticas, as variáveis que não possuem um valor particular fixo no tempo e no espaço. Por sua vez, um modelo determinístico não considera parâmetros aleatórios, ou seja, em uma formulação determinística, a saída do sistema é exclusivamente determinada pela entrada. Desta forma, dados de entrada são precisamente

associados à resposta do modelo e, portanto, a incerteza na estrutura do modelo não é levada diretamente em consideração (Koutsoyiannis & Montanari, 2014).

Seja  $X_t$  uma variável aleatória e  $X_1, X_2, X_3, \dots, X_n$ , em que a subscrição representa intervalos de tempo, conforme definição explicitada anteriormente. Pode-se chamar a sequência de  $n$  valores aleatórios de  $X_t$  de série temporal. Além disso, se o processo associado ao valor de  $X_t$  é um processo definido por uma distribuição de probabilidades, este pode ser chamado de processo probabilístico, ou, em termos gerais, de processo estocástico (Salas *et al.*, 1980).

Hassler (2016) define formalmente um processo estocástico como sendo um conjunto de valores reais de variáveis aleatórias,  $\{X(t; \omega)\}_{t \in T}$ , para um dado conjunto  $T$ :

$$X: T \times \Omega \rightarrow R$$

$$(t; \omega) \rightarrow X(t; \omega)$$

Onde  $\Omega$  é o conjunto possível de resultados de um experimento aleatório,  $\omega$  é um evento elementar tal que  $\{\omega\} \subseteq \Omega$ , e  $t \in T$  é interpretado como “tempo”. No ponto fixo no tempo  $t_0$  o processo estocástico é, portanto, uma variável aleatória simples:

$$X: \Omega \rightarrow R$$

$$\omega \rightarrow X(t_0; \omega)$$

Um  $\omega_0$  fixo, no entanto, resulta em um caminho, uma trajetória ou uma realização de um processo no qual também é referenciado como uma série temporal:

$$X: T \rightarrow R$$

$$t \rightarrow X(t; \omega)$$

De fato, um processo estocástico é bastante complexo (HASSLER, 2016). Para caracterizá-lo matematicamente, vetores aleatórios de comprimento finito e arbitrário  $n$  em pontos arbitrários em tempo  $t_1 < \dots < t_n$  deve ser considerada:

$$X_n(t_i) = (X(t_1; \omega), \dots, X(t_n; \omega))', t_1 < \dots < t_n$$

A distribuição multivariada de uma dada variável aleatória caracteriza um processo estocástico.

### 3.3.1 Modelo de séries temporais

De acordo com Salas *et al.* (1980), um modelo matemático que representa um processo estocástico é chamado de “modelo estocástico” ou “modelo de série temporal”. Box *et al.* (2016) apresentam um fluxograma do processo iterativo para modelagem de uma série temporal:

1. Seleção do tipo do modelo: escolher, dentre os vários modelos existentes, o mais apropriado. Considerando variáveis hidrológicas (com dependência no tempo), são muito utilizadas as cadeias de Markov e modelos autorregressivos (SALAS *et al.*, 1980);
2. Identificação da forma do modelo: uma vez escolhido o modelo, são determinados os parâmetros que vão dar forma ao modelo. Se, por exemplo, for escolhido o modelo autorregressivo, o próximo passo é descobrir se é de primeira ordem (um parâmetro), segunda ordem (dois parâmetros) etc.
3. Estimação dos parâmetros do modelo: uma vez escolhida a forma do modelo, são estimados os parâmetros que vão deixar o modelo aderente à forma escolhida;
4. Verificação do modelo (o modelo é adequado? Se sim, utiliza-se o modelo para previsão; caso contrário, retorna-se para a etapa 2).

Uma variável ( $X(t)$ ) de um modelo de série temporal pode ser representada por três parcelas: tendência ( $T(t)$ ); variação sazonal ou cíclica ( $S(t)$ ); e um termo aleatório ( $a_t$ ). Este termo aleatório é representado por uma variável aleatória normalmente distribuída com média zero e desvio padrão unitário:

$$X(t) = T(t) + S(t) + a_t$$

Cada parcela da série temporal do modelo pode ser obtida através da função “decompose()”, presente no RStudio.

### 3.3.2 Conceitos de estacionariedade e ergodicidade

De acordo com Milly *et al.* (2008), modelos estatísticos de previsão de variáveis hidrológicas devem ser tomados como não estacionários devido às ações humanas, que contribuem para aumento de emissão de CO<sub>2</sub> na atmosfera e, por conseguinte, influencia nos padrões estatísticos das variáveis hidroclimáticas. No entanto, os modelos GCM são modelos determinísticos para os quais, segundo Koutsoyiannis e Montanari (2014), o conceito de estacionariedade e não-estacionariedade não se aplicam. Além disso, modelos estatísticos não estacionários possuem funções determinísticas que permitem obter variação das estatísticas do modelo em função do tempo, ou seja, conceitualmente, um modelo como o descrito não é o mais correto. Os autores defendem a ideia de que modelos determinísticos devem ser calibrados antes de ser aplicado e, portanto, seu uso nunca eliminará a necessidade de fazer inferência estatística. Desta forma, na opinião dos autores, as mudanças climáticas devem ser modeladas como um processo estocástico de base física, que em geral pode ser estacionário e apenas em casos justificados, não estacionários.

De acordo com Komolgorov (1931, 1938) e Khintchine (1934), um processo é estacionário se suas propriedades estatísticas são invariantes no tempo:  $x(t)$  e  $x(t')$  possuem a mesma distribuição (multivariada) para quaisquer  $t$  e  $t'$ . Ou seja, um processo é estacionário se a sua média é constante e sua autocovariância depende unicamente das diferenças de tempo. Em termos gerais (equação (1)):

$$E(x(t)) = \mu (\text{constante}), \text{cov}[x(t), x(t+h)] = c(h) \quad (1)$$

A estacionariedade é um conceito importante que deve ser levado em conta em Modelos de Circulação Global (GCM) baseados em cenários de emissão futura de CO<sub>2</sub> na atmosfera. Portanto, modelos GCM costumam apresentar tendências nas estatísticas das variáveis geradas pelo modelo.

Segundo Koutsoyiannis (2021), em sistemas dinâmicos, por definição, a ergodicidade é a propriedade de um sistema cujos conjuntos invariantes sob a transformação dinâmica são triviais (têm probabilidade zero). Em termos matemáticos, um processo

estocástico  $\underline{x}(t)$  é ergótico se a média de tempo de qualquer função integrável  $g(\underline{x}(t))$ , no tempo tendendo ao infinito, é igual ao valor esperado de  $g(\underline{x}(t))$  – equação (2):

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T g(\underline{x}(t)) dt = E[g(\underline{x}(t))] \quad (2)$$

Ou ainda, na forma discreta, equação (3):

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^T g(\underline{x}(t)) = E[g(\underline{x}(t))] \quad (3)$$

O lado direito nas equações (2) e (3) representa a média verdadeira, também conhecida como “média do conjunto”; já o lado esquerdo das equações (2) e (3) representa a média de tempo, para o caso limite de tempo infinito (KOUTSOYIANNIS, 2021).

### 3.3.3 Geradores estocásticos de variáveis climáticas

Geradores estocásticos de variáveis climáticas são ferramentas comumente utilizadas para produzir séries climáticas sintéticas de qualquer tamanho com as mesmas características dos dados de entrada (KING *et al.*, 2015).

Uma vez que as estimativas dos modelos climáticos dos GCMs são provenientes de modelos determinísticos (item Modelos de Circulação Global (GCMs)), eventualmente, uma vez que o uso de *ensembles* (item 3.4), possui um número de simulações limitado pelo número de estimativas dos GCMs, frequentemente faz-se necessário a geração de séries sintéticas de modo a aumentar a variabilidade da estimativa do processo.

De acordo com King *et al.* (2015), há três categorias de geradores estocásticos de variáveis hidroclimáticas:

- i. Paramétricos: os modelos paramétricos utilizam a técnica da cadeia de Markov para produzir dias secos e chuvosos. As variáveis são calculadas de acordo com as distribuições de probabilidade para temperatura ou chuva ;
- ii. Semiparamétricos: Os modelos semiparamétricos foram desenvolvidos para mitigar parte das dificuldades elencadas dos modelos paramétricos; e
- iii. Não paramétricos: face às dificuldades dos modelos paramétricos e semiparamétricos, os modelos não paramétricos surgem como uma opção. Essa abordagem baseia-se no procedimento de *K-Nearest Neighbor (K-NN)*, que faz uma reamostragem a partir dos dados históricos, com reposição.

### 3.4 Clima Futuro e cenários de emissão

As projeções das alterações climáticas desempenham um papel fundamental na melhoria da compreensão do sistema climático, bem como na caracterização dos riscos sociais e das opções de resposta (O'Neill *et al.*, 2016). Dessa forma, o Projeto de Intercomparação de Modelos de Cenários (do inglês *ScenarioMIP*) compreende a atividade principal da 6ª fase do Projeto de Intercomparação de Modelos Acoplados (do inglês CMIP6), que fornecerá projeções climáticas multimodelos (*ensembles*) baseadas em cenários de emissões futuras e mudanças no uso do solo produzidas com modelos de avaliação integrados.

#### 3.4.1 Cenários de emissão

Cenários que descrevem possíveis mudanças climáticas relacionadas a fatores antropogênicos (ou seja, gases de efeito estufa, aerossóis e mudanças no uso do solo) consistentes com desenvolvimentos socioeconômicos desempenham um papel importante na pesquisa climática (ONEILL *et al.*, 2016).

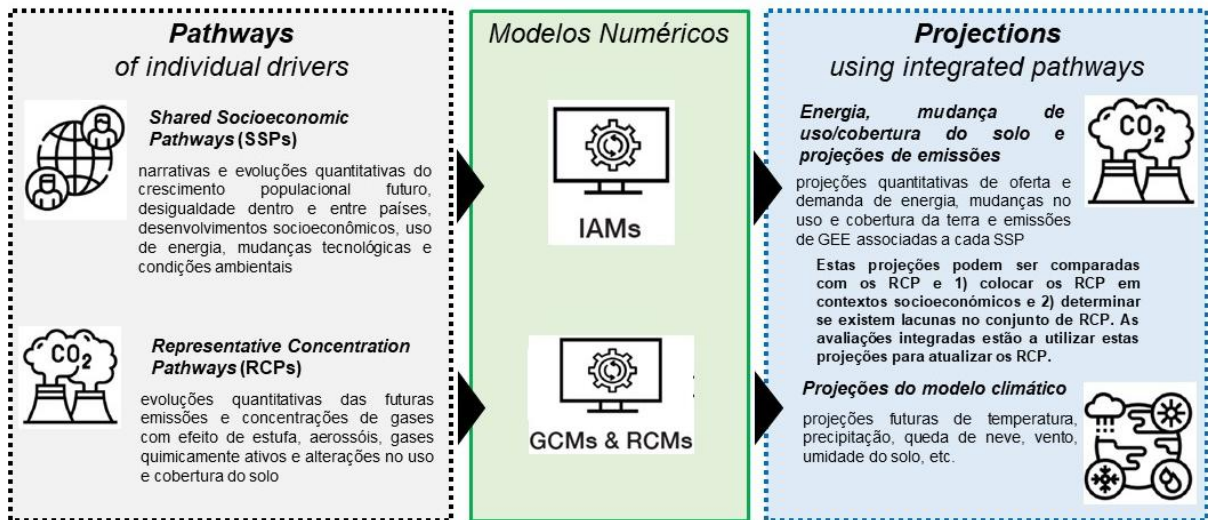
Cenários produzidos no Relatório Especial sobre Cenários de Emissões (SRES) do IPCC (Nakicenović *et al.*, 2000) formaram a base para as projeções de modelos climáticos na 3ª Fase do Projeto Intercomparação de Modelos Acoplados (CMIP3) e sua avaliação no *Fourth Assessment Report – AR4* (IPCC, 2007).

Posteriormente, novos cenários foram criados com o conceito de identificação das Vias de Concentração Representativas (Van Vuuren, 2011), do inglês: chamados *Representative Concentration Pathways* (RCPs). Os RCPs foram utilizados como

base para as projeções dos modelos climáticos da 5ª Fase do Projeto Intercomparação de Modelos Acoplados (CMIP5) e sua avaliação no *Fifth Assessment Report – AR5* (IPCC, 2014).

De acordo com Oneill et al. (2016), o Projeto de Intercomparação de Modelos de Cenários (ScenarioMIP) é agora a principal atividade dentro do CMIP6 que forneceu projeções climáticas multimodelos com base em cenários alternativos que são diretamente relevantes para a sociedade em relação à mitigação, adaptação ou impactos das mudanças climáticas. Essas projeções climáticas são impulsionadas por um novo conjunto de cenários de emissões e uso de solo produzidos com modelos de avaliação integrada (IAMs) baseados em novos caminhos futuros de desenvolvimento social, chamados de Caminhos Socioeconômicos Compartilhados, do inglês “*Shared Socioeconomic Pathways*” (SSPs). Estes novos cenários de modelos climáticos são uma combinação de “caminhos” forçados pelo desenvolvimento socioeconômico e políticas de desenvolvimento sustentável, que pode ter influência no saldo de radiação (isso é, forçamento radioativo). Os chamados SSPs descrevem como as sociedades podem evoluir, no que diz respeito ao crescimento populacional, à desigualdade dentro e entre países, à evolução socioeconômica, à utilização de energia, às mudanças tecnológicas e às condições ambientais (ANN ARBOR *et al.*, 2021). Cada SSP é relacionado com projeções futuras de emissão de gases do efeito estufa (GEE), que são *inputs* para cada RCP. A Figura 6 ilustra essa abordagem paralela, na qual os SSPs são inseridos em Modelos de Avaliação Integrados (do inglês *Integrated Assessment Models* IAMs) que produzem cenários de projeções de energia, mudanças no uso/cobertura do solo e emissões de GEE, os quais são comparáveis aos RCPs.

**Figura 6 – Diagrama de fluxo relacionando Caminhos Socioeconômicos Compartilhados (SSPs), Caminhos de Concentração Representativa (RCPs) e projeções climáticas e seus diferentes modelos usados**



Fonte: adaptado de Ann Arbor *et al.*, 2021

Os RCPs foram concebidos como base de projeções climáticas da 5ª fase do Projeto de Intercomparação de Modelos Acoplados, do inglês CMIP5 (Taylor *et al.*, 2012). Os quatro tipos de RCPs são funções do aumento do saldo de radiação, conforme indicado no Quadro 1. Já os SSPs são caracterizados por cinco tipos, discriminados no Quadro 2. A Figura 7 apresenta as taxas médias de aumento de temperatura global, se acordo com cada SSP.

**Quadro 1 – Caracterização dos Caminhos de Concentração Representativos (RCP)**

Cenário	Radiação	Caracterização
RCP2.6	2,6 W/m <sup>2</sup>	Cenário de pico e declínio, onde o forçamento radioativo atinge pela primeira vez 3,1 W/m <sup>2</sup> em meados do século e retorna a 2,6 W/m <sup>2</sup> em 2100. Isso é conseguido através de uma redução substancial dos gases de efeito estufa ao longo do tempo através de uma política climática rigorosa.
RCP4.5	4,5 W/m <sup>2</sup>	O forçamento radioativo total é estabilizado logo após 2100, sem ultrapassagem. Isso é conseguido através de uma redução dos gases de efeito estufa ao longo do tempo através da política climática.
RCP6.0	6,0 W/m <sup>2</sup>	Sem esforços adicionais para restringir as emissões (cenários de base).
RCP8.5	8,5 W/m <sup>2</sup>	Aumento das emissões de gases de efeito estufa ao longo do tempo, sem estabilização; representativo de cenários que levem a altos níveis de concentração de gases de efeito estufa.


Fonte: Adaptado de Van Vuuren *et al.* (2011)

**Quadro 2 – Caracterização dos *Shared Socioeconomic Pathways* (SSPs)**

SSP	Saldo de radiação em 2100 (W/m <sup>2</sup> )	Cenário	Mudança de temperatura global (°C)	Caracterização
1	1,9 2,6	Sustentabilidade – Baixa para mitigação e adaptação	1,0 – 2,4	O desenvolvimento sustentável prossegue a um ritmo razoavelmente elevado.
2	4,5	Meio da Estrada – Meio para mitigação e adaptação	2,1 – 3,5	Um caso intermediário análogo ao cenário RCP4.5.
3	7,0	Rivalidade Regional – Alta para mitigação e adaptação	2,8 – 4,6	As emissões não mitigadas são elevadas devido ao crescimento econômico moderado.
4	3,4 6,0	–	–	Um mundo misto, com desenvolvimento tecnológico relativamente rápido em fontes de energia de baixo carbono em regiões-chave emissoras, levando a uma capacidade mitigativa relativamente grande em lugares onde mais importava para as emissões globais.
5	8,5	Desenvolvimento movido a combustíveis fósseis – Baixo para mitigação, alto para adaptação	3,3 – 5,7	Na ausência de políticas climáticas, a demanda de energia é alta e a maior parte dessa demanda é atendida com combustíveis à base de carbono. Análogo ao cenário RCP 8.5.

Fonte: adaptado de O'Neill *et al*, 2014

**Figura 7 – Aumento temperatura da superfície global em função de cada cenário SSP.**



Fonte: adaptado de IPCC, 2021.

Hausfather *et al.* (2022) alerta que um subconjunto da mais recente geração de modelos está “muito quente” e projeta aquecimento climático em resposta às emissões de dióxido de carbono que podem ser maiores do que aquelas suportadas por outras evidências.

Os modelos CMIP6 incluem tratamentos mais sofisticados de gelo, água e nuvens do que os anteriores, incluindo os da fase 5 (CMIP5). Os modelos mais recentes também incorporam uma variedade maior de processos físicos do que antes. À medida que os modelos se tornam mais realistas, espera-se que converjam. Enquanto isso, melhorias individuais podem afetar a sensibilidade dos modelos a certos processos de aquecimento, de maneiras frequentemente impossíveis de prever (HAUSFATHER et al, 2022).

A maior fonte de incerteza nas temperaturas globais daqui a 50 ou 100 anos é o volume das futuras emissões de gases de efeito estufa, que estão amplamente sob controle humano. No entanto, mesmo se soubéssemos precisamente qual seria esse volume, ainda não saberíamos exatamente quão quente o planeta ficaria.

#### 3.4.2 Modelos de Circulação Global (GCMs)

O clima futuro é projetado usando modelos climáticos de circulação global (sigla em inglês GCM). De acordo com IPCC (2022), o clima futuro em função de cenários de emissão é normalmente projetado em modelos climáticos de circulação global (GCMs), que são modelos matemáticos que tratam, de forma integrada, a representação numérica em função das propriedades físicas, químicas e biológicas dos sistemas marítimo, atmosférico, terrestre e da criosfera, os quais são sistemas globais que interagem entre si de modo múltiplo e não linear – o que gera, por definição, um sistema altamente caótico – ou cuja previsibilidade é limitada (BRASIL, 2016).

Os GCMs foram desenvolvidos por várias agências governamentais, mas compartilham elementos comuns descritos pelo IPCC. É importante ressaltar que o IPCC não executa os modelos, mas atua como uma espécie de *instituição intermediária* para a distribuição e compartilhamento de suas previsões.

Neste trabalho, o conjunto de séries de cenários climáticos globais derivados das simulações dos GCMs realizadas no âmbito do CMIP6 foram obtidos a partir do *NASA Earth Exchange Global Daily Downscaled Projections*, da sigla em inglês NEX-GDDP-CMIP6.

O Quadro 3 lista o conteúdo atual, incluindo as variáveis disponíveis para cada modelo (Quadro 4), e notas sobre eventuais discrepâncias de inventário entre os modelos. Uma única variante de cada um dos 35 modelos listados foi usada para redução de escala (THRASHER *et al.*, 2022). Estão inclusos dados históricos diários de 1950 até 2014, além de quatro cenários de SSPs: SSP1-2.6, SSP2-4.5, SSP3-7.0 e SSP5-8.5.

**Quadro 3 – Variáveis incluídas no arquivo NEX-GDDP-CMIP6 \*Tas (temperatura do ar próximo à superfície) é fornecida para modelos que não fornecem tasmx e tasmin; caso contrário, tas é derivado de tasmx e tasmin**

Variável	Descrição	Unidade
hurs	Umidade relativa próxima à superfície	%
huss	Umidade específica próxima à superfície	kg/kg
pr	Precipitação (incluindo fases líquida e sólida)	kg/m <sup>2</sup> /s
rlds	Radiação de ondas longas de superfície	W/m <sup>2</sup>
rsds	Radiação de ondas curtas de superfície	W/m <sup>2</sup>
sfcWind	Velocidade do vento de superfície	m/s
tas*	Temperatura do ar próximo à superfície	K
tasmx*	Temperatura máxima do ar próximo à superfície	K
tasmin*	Temperatura mínima do ar próximo à superfície	K

Fonte: THRASHER *et al.*, 2022

**Quadro 4 – Modelos CMIP6 incluídos no arquivo reduzido. Legenda: Verde = todos os experimentos disponíveis; amarelo = histórico e alguns SSP(s) disponíveis; vermelho = nenhum dado disponível. \*Saída original do GCM para o hurs SSP245 faltando ano 2058**

Modelo	Variante	hurs	huss	pr	rlds	rsds	sfcWind	tas	tasmax	tasmin
ACCESS-CM2	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
ACCESS-ESM1-5	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
BCC-CSM2-MR	r1i1p1f1	Vermelho	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
CanESM5	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
CESM2	r4i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Vermelho	Vermelho	Vermelho
CESM2-WACCM	r3i1p1f1	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Vermelho	Vermelho	Vermelho
CMCC-CM2-SR5	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Amarelo	Vermelho	Vermelho	Vermelho
CMCC-ESM2	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
CNRM-CM6-1	r1i1p1f2	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
CNRM-ESM2-1	r1i1p1f2	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
EC-Earth3	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
EC-Earth3-Veg-LR	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
FGOALS-g3	r3i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
GFDL-CM4 (gr1)	r1i1p1f1	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo
GFDL-CM4 (gr2)	r1i1p1f1	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo
GFDL-ESM4	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
GISS-E2-1-G	r1i1p1f2	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
HadGEM3-GC31-LL	r1i1p1f3	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo
HadGEM3-GC31-MM	r1i1p1f3	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo
IITM-ESM	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Vermelho	Vermelho	Vermelho
INM-CM4-8	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
INM-CM5-0	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
IPSL-CM6A-LR	r1i1p1f1	Verde	Vermelho	Verde	Verde	Verde	Verde	Verde	Verde	Verde
KACE-1-0-G	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
KIOST-ESM*	r1i1p1f1	*	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
MIROC-ES2L	r1i1p1f2	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
MIROC6	r1i1p1f1	Verde	Amarelo	Verde	Verde	Verde	Verde	Verde	Verde	Verde
MPI-ESM1-2-HR	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
MPI-ESM1-2-LR	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
MRI-ESM2-0	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
NESM3	r1i1p1f1	Vermelho	Vermelho	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo	Amarelo
NorESM2-LM	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
NorESM2-MM	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
TaiESM1	r1i1p1f1	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
UKESM1-0-LL	r1i1p1f2	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde

Fonte: THRASHER *et al.*, 2022

### 3.4.3 Projeções regionais de mudanças climáticas

A resolução dos GCMs, via de regra, é muito grosseira para uso direto, com resolução variando entre 1° x 1° a 2,81° x 2,81° (XU *et al.*, 2021), pois não resolve padrões

climáticos e extremos ou climatologia em escalas locais (THRASHER *et al.*, 2022). Além de usar a saída do GCM diretamente, existem diferentes opções para analisar as projeções climáticas em escala regional. Para tanto, as estimativas dos modelos globais precisam ser submetidas a correção de viés e desagregadas espacialmente, de modo a se obter informações de variáveis climáticas com resolução espacial mais detalhada.

Dessa forma, de modo a reduzir a resolução espacial dos GCMs, além de correção de viés no período histórico, foi utilizado a técnica *Bias-Correction Spatial Disaggregation* (BCSD), usada para gerar o conjunto de dados do NEX-GDDP-CMIP6 (THRASHER *et al.*, 2022). Trata-se de um algoritmo estatístico de redução de escala, desenvolvido especificamente para resolver essas limitações dos resultados globais do GCM (Wood *et al.*, 2002; Thrasher *et al.*, 2012).

De acordo com Thrasher *et al.* (2012), devido ao fato de o método BCSD não ajustar as tendências de forma explícita nas variáveis climáticas produzidas pelos GCMs, é extraída a tendência de larga escala das estimativas de temperatura dos GCMs, que é calculada com a média móvel com passo de tempo nove anos para cada mês.

A correção de viés empregada se baseia em comparações realizadas com os dados históricos do *Global Meteorological Forcing Dataset* (GMFD). Para cada variável climática em um determinado dia, o algoritmo gera a função de distribuição acumulada (FAP) para os dados GMFD e para as simulações retrospectivas do GCM, respectivamente, agrupando e classificando os valores de origem correspondentes (dia do ano +/- 15 dias) durante o período de 1960 a 2014.

Em seguida, são comparadas as FAPs em vários limites de probabilidade para estabelecer um mapa de quantis entre as estimativas do GCM e os dados climáticos históricos. Com base nesse mapa, os valores GCM em qualquer quantil da FAP podem ser traduzidos em valores GMFD correspondentes ao mesmo quantil.

A etapa de desagregação espacial interpola espacialmente os dados do GCM ajustado para um *grid* de resolução mais fina dos dados GMFD: 0,25° - correspondente a aproximadamente um *grid* de 27,8 x 27,8 km. A desagregação espacial é feita em quatro etapas (THRASHER *et al.*, 2012):

1. A climatologia diária suavizada é gerada a partir das observações em *grid* durante o período de referência 1960-2014, usando uma Transformada Rápida de Fourier e mantendo três harmônicos nas resoluções nativa e GCM;
2. Para cada intervalo de tempo, o algoritmo compara as variáveis GCM com correção de viés com a climatologia GMFD correspondente para calcular “fatores de escala”;
3. Os fatores de escala de resolução mais grosseira são interpolados bilinearmente na grade GMFD de resolução fina; e
4. Os fatores de escala são aplicados por adição ou “mudança” para temperaturas e por multiplicação para as restantes variáveis, nas climatologias GMFD de resolução fina para obter os campos climáticos reduzidos desejados.

Conforme comentado anteriormente, o algoritmo BCSD não ajusta a inclinação das tendências nas projeções do GCM, apenas corrige o viés no período histórico. No caso da temperatura, por exemplo, se o GCM prevê um aumento médio da temperatura de 2°C entre 2015 e 2100, a mesma mudança de temperatura (ou seja, uma tendência de 2°C ao longo de 86 anos) será observada na temperatura em escala reduzida.

### **3.5 Métodos de correção de viés de modelos climáticos**

Muitos impactos possíveis das futuras mudanças climáticas serão estimados em escala regional (IPCC, 2014). Esses impactos podem ser quantificados por modelos, que frequentemente exigem dados meteorológicos de alta resolução para as condições atuais (WILBY *et al.*, 2000).

Os erros sistemáticos nas saídas dos modelos climáticos podem ser atribuídos a diferentes fontes. Por exemplo, (EDEN *et al.*, 2012) classificam os erros nos campos de precipitação dos GCM como sendo devido:

1. À variabilidade em larga escala ou resposta irrealista a forçamentos de cenários climáticos;
2. À variabilidade interna imprevisível que difere das observações (por exemplo, como pode ocorrer se o período histórico amostrado coincidir com a fase

positiva da oscilação decadal do Pacífico nas observações e a fase negativa no modelo climático) e;

3. A erros em parametrizações convectivas e orografia não resolvida em escala subgrid.


De acordo com Maraun (2016), a correção de viés é amplamente utilizada na modelagem de impactos climáticos, pois visa ajustar as estatísticas selecionadas de uma simulação de modelo climático para melhor corresponder às estatísticas observadas durante um período de referência histórico.

Quando se quer trabalhar com modelos de menor escala, opta-se por fazer *downscaling* de Modelos Regionais de Circulação (da sigla em inglês: RCM). O *downscaling* do clima futuro envolve integração do RCM com as condições de contorno de um Modelo de Circulação Global (GCM). Essa interação entre RCM e GCM faz que o viés da condição de contorno seja propagado para o RCM (XU et al., 2021).

### 3.5.1 Conceito de viés

De acordo com Maraun (2016), os climas observado e simulado podem ser considerados como uma amostra de uma distribuição de probabilidade multivariada dependente do tempo, multivariada no espaço, no tempo e entre diferentes variáveis climáticas (Figura 8). A distribuição incondicional de uma única variável em um local e momento específicos é conhecida como distribuição marginal. O viés climático refere-se à discrepância sistemática entre uma estatística climática simulada e sua contraparte no mundo real.

**Figura 8 – Distribuição bidimensional.** O gráfico de bidimensional indica a função de densidade de probabilidade multivariada. Os pontos indicam uma amostra da distribuição. As cores azul e laranja indicam funções de densidade de probabilidade marginais.



Fonte: adaptado de Maraun, 2016

Seja uma variável diária simulada através de um modelo em algum momento do período histórico, pertencente a uma série histórica de tamanho  $N$ :  $x_i^p$ . Seja agora  $y_i^p$  a correspondente variável diária observada no mesmo instante de tempo que  $x_i^p$ .

As variáveis seguem as distribuições marginais:  $x_i^p \sim D_{modelo}^p$  e  $y_i^p \sim D_{real}^p$ , e suas médias  $\hat{\mu}_{modelo}^p = \bar{x}^p$  e  $\hat{\mu}_{real}^p = \bar{y}^p$ . Um estimador do viés do modelo pode ser obtido através da seguinte relação (equação (4)):

$$\widehat{Bias}(\mu^p) = \bar{x}^p - \bar{y}^p \quad (4)$$

### 3.5.2 Mapeamento de quantil

Conforme discutido anteriormente, eventualmente há a necessidade de correção do viés dos modelos climáticos. O estado da arte da correção de viés dos GCM é introduzido pela técnica de mapeamento de quantil. De acordo com Cannon *et al.* (2015), o mapeamento de quantil iguala as funções acumuladas de probabilidades (FAP)  $F_{o,h}$  e  $F_{m,h}$  dos dados históricos (denotado pelo índice  $h$ ) observados  $x_{o,h}$ , denotado pelo índice  $o$ , e das estimativas dos modelos climáticos  $x_{m,h}$ . Portanto, o quantil proveniente da correção de viés do modelo é estimado por meio da seguinte equação (5):

$$\hat{x}_{m,p}(t) = F_{o,h}^{-1}\{F_{m,h}[x_{m,p}(t)]\} \quad (5)$$

Essa equivalência das FAPs pode ser feita com auxílio de funções de transferência, conforme sugerido por Piani *et al.* (2010). Recentemente, técnicas de *machine learning* (RAVURI *et al.*, 2021) vêm sendo utilizadas para correção de viés dos modelos do CMIP6 vêm sendo estudadas como, por exemplo, técnicas de redes neurais (WANG e TIAN, 2022).

Nos itens seguintes, é apresentada uma síntese de dois exemplos de técnicas de correção de viés via mapeamento de quantil (item Mapeamento Delta do Quantil (QDM)) e *machine learning* (item *Deep Learning*).

### 3.5.3 Mapeamento Delta do Quantil (QDM)

Seja  $x_{m,p}$  uma variável no tempo da projeção de um modelo GCM, com FAP empírica no tempo  $t$  escrita conforme apresentado na Equação (6):


$$\varepsilon_{m,p}(t) = F_{m,p}[x_{m,p}(t)], \tau_{m,p}(t) \in \{0,1\} \quad (6)$$

Define-se  $\Delta_m(t)$  como a razão entre a variável do modelo no período de projeção  $x_{m,p}(t)$  e o inverso da FAP do histórico do modelo ( $F_{m,h}^{-1}()$ ) em  $\varepsilon_{m,p}(t)$ :

$$\Delta_m(t) = \frac{x_{m,p}(t)}{F_{m,h}^{-1}[\tau_{m,p}(t)]} \quad (7)$$

Graficamente, o valor de  $\Delta_m(t)$  é apresentado como a distância entre quantis com mesma probabilidade de excedência no histórico e no período projetado. A Figura 9 ilustra essa relação.

**Figura 9 – Ilustração gráfica de  $\Delta_m(t)$ .**



Define-se agora o inverso da FAP do histórico observado como  $\varepsilon_{m,p}(t)$ :

$$\hat{x}_{o:m,h:p}(t) = F_{o,h}^{-1}[\varepsilon_{m,p}(t)] \quad (8)$$

A correção de viés é feita, portanto, a partir da seguinte relação:

$$\hat{x}_{m,p}(t) = \hat{x}_{o:m,h:p}(t)\Delta_m(t) \quad (9)$$

### 3.5.4 Deep Learning

De acordo com Hess *et al.* (2023), os métodos de correção de viés, como o Mapeamento Delta do Quantil (QDM), estão limitados a corrigir erros nas distribuições de frequência simuladas localmente, ou seja, em cada *grid*. Segundo os autores, padrões irrealistas de saída dos GCMs, que exigiriam contexto espacial, até o momento da pesquisa, não haviam sido abordados por métodos de pós-processamento.

Hess *et al.* (2023) mostram que um método de pós-processamento baseado em redes adversárias generativas fisicamente restritivas (cGANs) pode corrigir o viés de GCMs do CMIP6, melhorando distribuições de frequência locais, bem como corrigindo o viés de padrões espaciais.

O modelo é capaz de corrigir os modelos globais em dois sentidos:

- Distribuições temporais em longa escala de tempo, incluindo extremos nas caudas das distribuições; e
- Padrões espaciais das saídas do modelo.

Nos capítulos seguintes sé apresentado os principais conceitos da aplicação de redes neurais na correção de viés de GCM, apresentado em Hess *et al.* (2023).

### **3.6 *Brisk Local Uncertainty Estimator for Generic Simulations and Predictions (Bluecat)***

Conforme citado anteriormente, o método Bluecat é um estimador rápido de incerteza local para simulações e previsões determinísticas, o Bluecat está enraizado em um projeto para a modelagem baseada em processos de sistemas hidrológicos incertos, proposto por Montanari e Koutsoyiannis (2012), e é definido pelos autores como um método para transformar um modelo de previsão determinístico em um modelo de previsão estocástico, passando assim de uma previsão pontual para a distribuição de probabilidade do preditor. A partir dessa última distribuição, obtém-se uma previsão média (ou mediana) juntamente com as faixas de confiança.

Os capítulos 3.6.1 a 3.6.3 na apresentam o desenvolvimento do método Bluecat, passando pelo primeiro *Framework* (MONTANARI; KOUTSOYIANNIS, 2012) até sua expansão para inferir incerteza em modelos climáticos (KOUTSOYIANNIS; MONTANARI, 2022).

#### **3.6.1 Modelagem baseada em processos de sistemas hidrológicos incertos**

O desenvolvimento do modelo é introduzido por Montanari e Koutsoyiannis (2012), por meio da definição de um modelo hidrológico expresso pela seguinte formulação determinística:

$$Q = S(\boldsymbol{\theta}, \mathbf{X}) \quad (10)$$

na qual  $Q$  é o modelo,  $\mathbf{X}$  representa o vetor de dados de entrada e  $\boldsymbol{\theta}$  o vetor de parâmetros. Somando um termo de erro  $e$ , com densidade de probabilidade  $f_e(e)$ , à Equação (10), tem-se:

$$Q = S(\boldsymbol{\theta}, \mathbf{X}) + e \quad (11)$$

O termo  $e$  representa as incertezas nos parâmetros, nos dados de entrada, na estrutura do modelo. Definidas as distribuições  $f_\theta(\theta)$ ,  $f_X(X)$  e  $f_e(e)$ , os autores inferem a densidade de probabilidade de  $f_Q(Q)$  pela resolução das integrais das equações (12) e (13) via simulações de Monte Carlo:

$$f_Q(Q) = \int_{\theta} \int_X f_e(Q - S(\boldsymbol{\theta}, \mathbf{X}) | \boldsymbol{\theta}, \mathbf{X}) f_\theta(\theta) f_X(X) d\theta dX \quad (12)$$

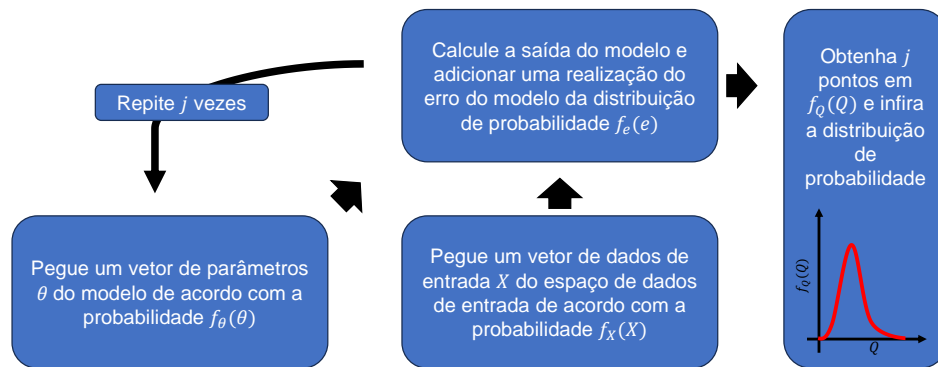
$$f_Q(Q) = \int_{\theta} \int_X f_e(Q - S(\boldsymbol{\theta}, \mathbf{X})) f_\theta(\boldsymbol{\theta}) f_X(\mathbf{X}) d\boldsymbol{\theta} d\mathbf{X} \quad (13)$$

O fluxograma apresentado na Figura 10 ilustra como proceder com a simulação de Monte Carlo para inferir a densidade de probabilidade de  $Q$ :  $f_Q(Q)$ . Destaca-se que os autores aplicaram esse método para a simulação de vazões em bacias localizadas na Itália. O procedimento ilustrado pela Figura 10 é aplicado através dos respectivos passos:

1. Um vetor de parâmetros para o modelo hidrológico é selecionado aleatoriamente a partir do espaço de parâmetros do modelo de acordo com a densidade de probabilidade.  $f_\theta(\boldsymbol{\theta})$ ;
2. Um vetor de dados de entrada para o modelo hidrológico é escolhido aleatoriamente a partir do espaço de dados de entrada de acordo com a densidade de probabilidade  $f_X(\mathbf{X})$ ;

3. O modelo hidrológico é executado e uma previsão do modelo (ou um vetor de previsões)  $S(\theta, X)$  é computado;
4. Um resultado do erro do modelo (ou vetor de erros) é escolhido aleatoriamente a partir da população de erros do modelo de acordo com a densidade de probabilidade  $f_e(e)$  e adicionado à previsão do modelo  $S(\theta, X)$ ;
5. A simulação descrita pelos itens de 1 a 4 é repetida  $j$  vezes. Portanto, obtemos  $j$  (vetores de) resultados da previsão  $Q$ ;
6. Finalmente, a densidade de probabilidade  $f_Q(Q)$  é inferida por meio das realizações mencionadas no item 5.

**Figura 10 – Fluxograma do procedimento de simulação de Monte Carlo para realização da integração numérica nas equações (12) e (13)**



Fonte: Adaptado de Montanari e Koutsoyiannis (2012)

### 3.6.2 *Bluecat*: Um Estimador de Incerteza Local para Simulações e Previsões Determinísticas

Koutsoyiannis e Montanari (2021) propuseram uma alternativa ao primeiro método apresentado, baseada no procedimento descrito no item 3.6.2, denominado *Bluecat*. Essa nova abordagem foi aplicada pelos autores para um modelo hidrológico. Seu princípio básico é que um modelo estocástico (modelo-S) pode ser representado por uma faixa de valores possíveis, ao invés de fornecer um único resultado (modelo-D).

Seja um *output* do modelo hidrológico determinístico ( $Q_\tau$ ), simulado em intervalos de tempo discretos  $\tau$  (e.g., chuva diária), expresso em função de variáveis de entrada  $x_\tau$ :

$$Q_\tau = G(x_\tau) \quad (14)$$

Assume-se que as variáveis de entrada  $\underline{x}_\tau$  têm função de densidade de probabilidade estacionária  $f_x(x)$  e função acumulada  $F_x(x)$ . A variável de saída  $\underline{q}_\tau$  é então definida pela equação (15), na qual as variáveis sublinhadas representam processos estocásticos.

$$\underline{q}_\tau = g(\underline{x}_\tau) \quad (15)$$

O processo estocástico  $\underline{q}_\tau$  é assumido como correspondente ao processo real, enquanto o modelo representado pela Equação (14) é uma estimativa de  $\underline{q}_\tau$ . Seja  $G(\neq g)$  uma função determinística da variável  $\underline{x}_\tau$  (por exemplo: chuva), obtém-se o estimador  $\underline{Q}_\tau$  da variável de saída  $\underline{q}_\tau$  (por exemplo: vazão):

$$\underline{Q}_\tau = G(\underline{x}_\tau) \quad (16)$$

Para avançar no desenvolvimento do método, define-se a distribuição condicional apresentada na Equação (17):

$$F_{(q|Q)}(q|Q) = P\{\underline{q} \leq q | \underline{Q} = Q\} \quad (17)$$

Onde  $q$  representa o processo real e  $Q$  o estimador determinístico de  $q$ . De acordo com Koutsoyiannis e Montanari (2021), determinar  $F_{(q|Q)}(q|Q)$  apenas pelos dados sem assumir uma distribuição em específico não é simples. Sendo assim, os autores propuseram a seguinte aproximação da função acumulada  $F_{(q|Q)}(q|Q)$ , usando amostras nas vizinhanças de  $Q$ :

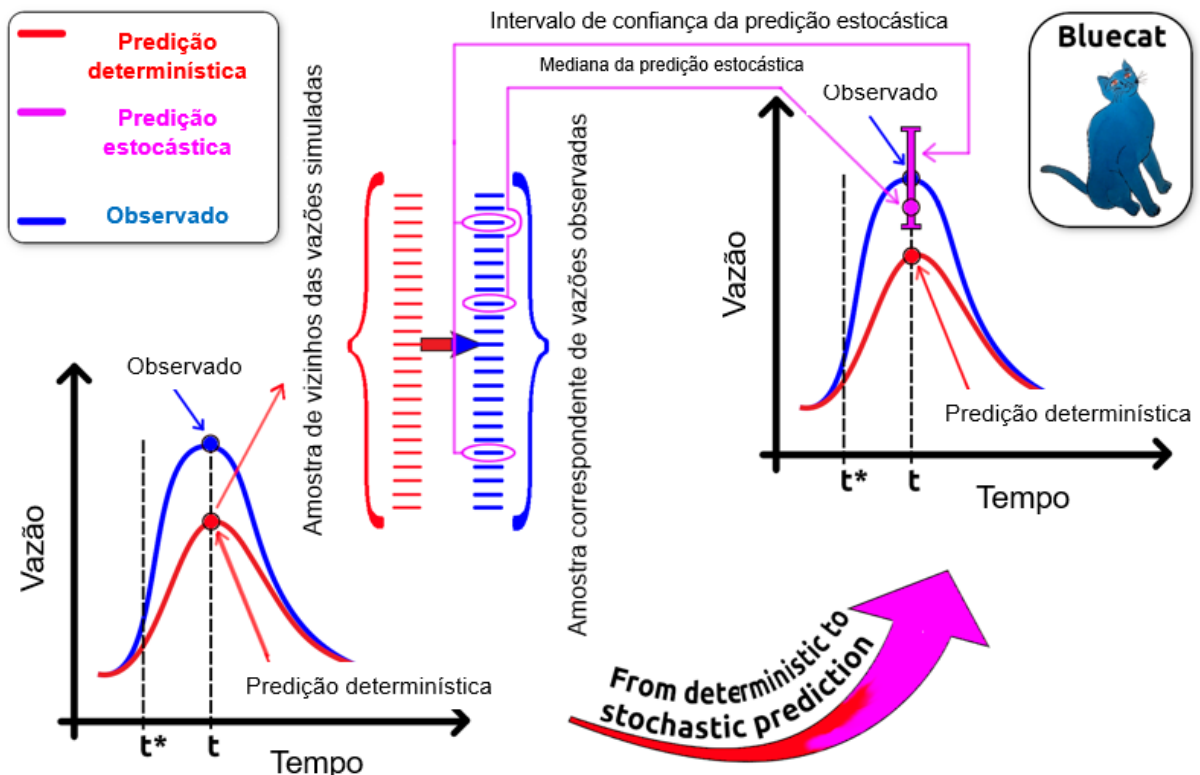
$$\begin{aligned} F_{(q|Q)}(q|Q) &= P\{\underline{q} \leq q | \underline{Q} \leq Q\} \approx P\{\underline{q} \leq q | Q - \Delta Q_1 \leq \underline{Q} \leq Q + \Delta Q_1\} \\ &= P\{\underline{q} \leq q | F_Q(Q) - \Delta F_1 \leq F_Q(\underline{Q}) \leq F_Q(Q) + \Delta F_2\} = F_{(q|[Q])}(q|Q, \Delta F_1, \Delta F_2) \end{aligned} \quad (18)$$

Na prática, o método *Bluecat* funciona por meio do seguinte procedimento:

- Uma previsão pontual é obtida com base em um modelo determinístico (modelo-D);
- Uma amostra de vazões em rios simulados é coletada do período de calibração;
- Uma amostra correspondente de vazões observadas é coletada. Isso é usado para estimar (a partir de dados) a distribuição de probabilidade condicionada.
- Em particular, o valor médio (ou mediano) é extraído junto com as faixas de confiança; e
- A previsão estocástica é obtida juntamente com a avaliação da incerteza.

A Figura 11 apresenta o conceito da aplicação do método *Bluecat*:

**Figura 11 – Representação esquemática do conceito do método *Bluecat* subjacente à transformação do modelo determinístico (modelo D) para um modelo estocástico (modelo S).**



Fonte: Adaptado de Montanari e Koutsoyiannis (2021)

### 3.6.3 Bluecat expandido: extrapolação climática em hidrologia

Koutsoyannis e Montanari (2022) expandiram o método Bluecat para aplicação em extrapolação de temperatura e precipitação em todo o território da Itália, aplicando o mesmo princípio de estimar a distribuição condicional com base nos dados “vizinhos”. Para tanto, primeiramente é obtida a função acumulada  $F_{(q|Q)}$  de forma empírica, considerando um número de vizinhos de possíveis valores de  $[Q]$  igual a  $2m + 1$ . Formalmente:

$$F_{q(i:2m+1|[Q])}(q|Q) = \frac{i - 0,439}{2m + 1 + 0,123} \quad (19)$$

Os possíveis valores de  $Q$  correspondem a  $2m + 1$  valores do processo real  $q$ . Dada uma amostra de  $Q$  e  $q$  de tamanho  $n$ . Nota-se que tal procedimento só pode ser realizado para a condição:

$$Q_{(m+1:m)} < Q < Q_{(n-m:n)}$$

Caso o valor de  $Q$  esteja fora da condição apresentada, é definida uma constante  $c \neq 1$ , de modo que se obtenha, para valores de  $Q$  fora do intervalo apresentado anteriormente, amostras a seguinte aproximação:

$$Q_{(m+1:m)} < cQ < Q_{(n-m:n)}$$

Por fim, estima-se a distribuição condicional para valores de  $Q$  fora da amostra com auxílio da seguinte equação (20):

$$F_{(q|Q)}(q|Q) \approx F_{(q|Q)}\left(q + a\left(1 - \frac{1}{c}\right)cQ \mid cQ\right) \quad (20)$$

na qual  $a$  é um parâmetro representando a inclinação da reta de regressão entre  $Q$  e  $q$ . A constante  $c$  é obtida para as condições  $Q < Q_{(m+1:n)}$  e  $Q > Q_{(m+1:n)}$  por meio das equações (21) e (22), respectivamente.

$$cH = Q_{(n-m:n)}/Q_H \quad (21)$$

$$cL = Q_{(m+1:n)}/Q_L \quad (22)$$

Sendo  $Q_H$  e  $Q_L$ , respectivamente, os valores máximos e mínimos para o intervalo da amostra de dados do modelo determinístico. Os valores de  $a_L$  e  $a_H$  são determinados através de regressão linear entre  $q$  e  $Q$  na parte mais baixa e mais alta (por exemplo, um quarto ou um terço).

## 4 METODOLOGIA

### 4.1 Definição das variáveis hidroclimáticas e cenários

Conforme apresentado no capítulo 3.2, a chuva é um importante componente no ciclo hidrológico de uma bacia. Neste trabalho, optou-se por trabalhar com projeções de chuva mensal. Apesar de a escala temporal diária e sub-diária serem as mais adequadas para se trabalhar extremos, a escala mensal é importante na questão de gestão de secas.

Além da chuva, outras variáveis representativas do clima como vento, umidade, evapotranspiração, radiação solar estão correlacionadas, direta ou indiretamente, com a temperatura atmosférica. Portanto, a outra variável climática a ser abordada é a temperatura média mensal.

Conforme introduzido no capítulo 3.4 há diversos cenários de forçantes radioativas que levam em conta taxas de emissões de gases do efeito estufa. Neste trabalho, pretende-se tirar conclusões sobre o desempenho dos cenários mais extremos (maior e menor emissão) e um cenário mediano. Portanto, optou-se por trabalhar com os cenários do CMIP6: SSP1-2.6, SSP2-4.5 e SSP5-8.5, cujas características são apresentadas no Quadro 2.

#### 4.1.1 Dados observados de chuva

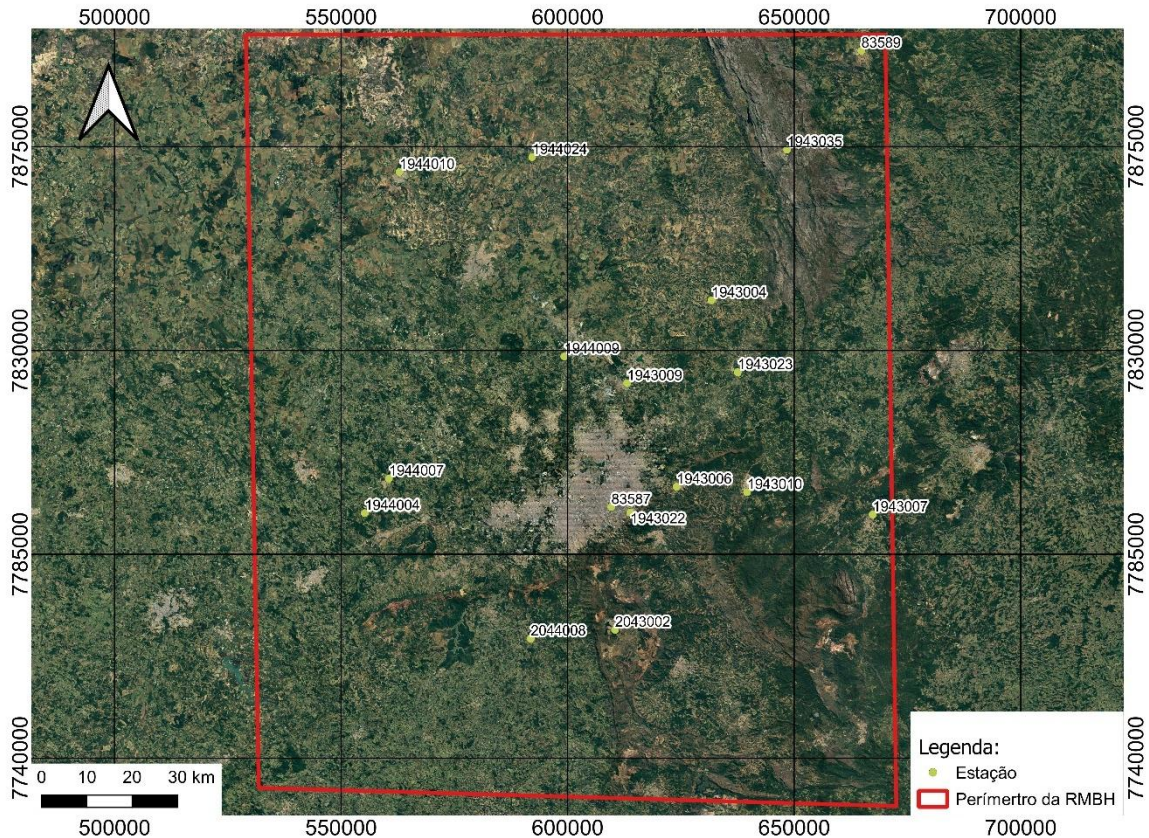
As estações com dados mensais de chuva foram escolhidas de acordo com os seguintes critérios:

- Localização;
- Disponibilidade de dados entre 1961 e 2021; e
- Disponibilidade de dados mensais superior a 80%.

Os dados de chuva mensal foram obtidos nos sites HIDROWEB da Agência Nacional de Águas e Saneamento – ANA (<https://www.snirh.gov.br/hidroweb/serieshistoricas>) e no banco de dados do Instituto Nacional de Meteorologia – INMET

(<https://bdmep.inmet.gov.br/>). As estações escolhidas são apresentadas no mapa apresentado Figura 12.

**Figura 12 – Estações pluviométricas consideradas para o estudo (elaborado no *software* QGis).**



Apenas as estações 1943023, 1944004 e 83587 apresentam 100% da disponibilidade de dados mensais. As falhas diárias do restante das estações foram preenchidas com a ferramenta disponível no R Studio: “fillGap()” (XU, 2023). Esta ferramenta faz o preenchimento de falha a partir de regressão linear simples usando o posto com maior correlação linear como “preditor”.

A consistência dos dados preenchidos foi avaliada por meio do método de “Dupla-Massa” (Pinto *et. al.*, 1976). Os gráficos dos valores acumulados são apresentados nas figuras 13, 14 e 15. Notória a proximidade com uma reta, admitiu-se a homogeneidade dos dados de chuva.

Figura 13 – Dupla Massa – Estação 1943023




Figura 14 – Dupla Massa – Estação 1944004


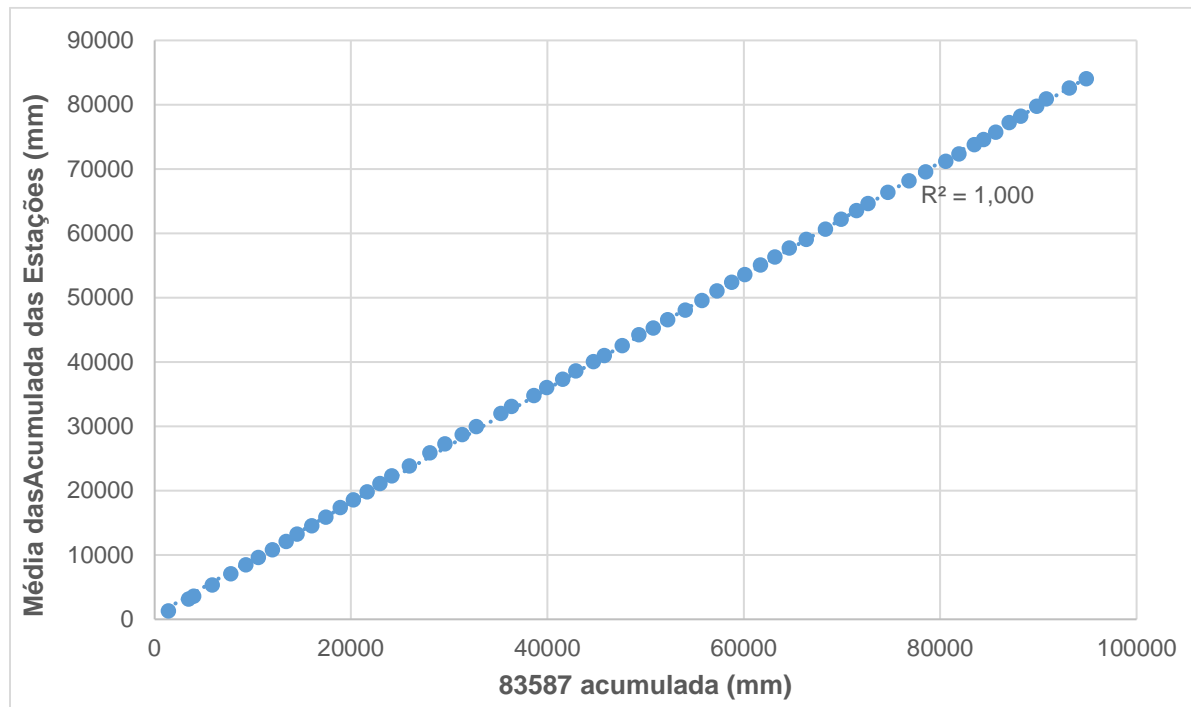
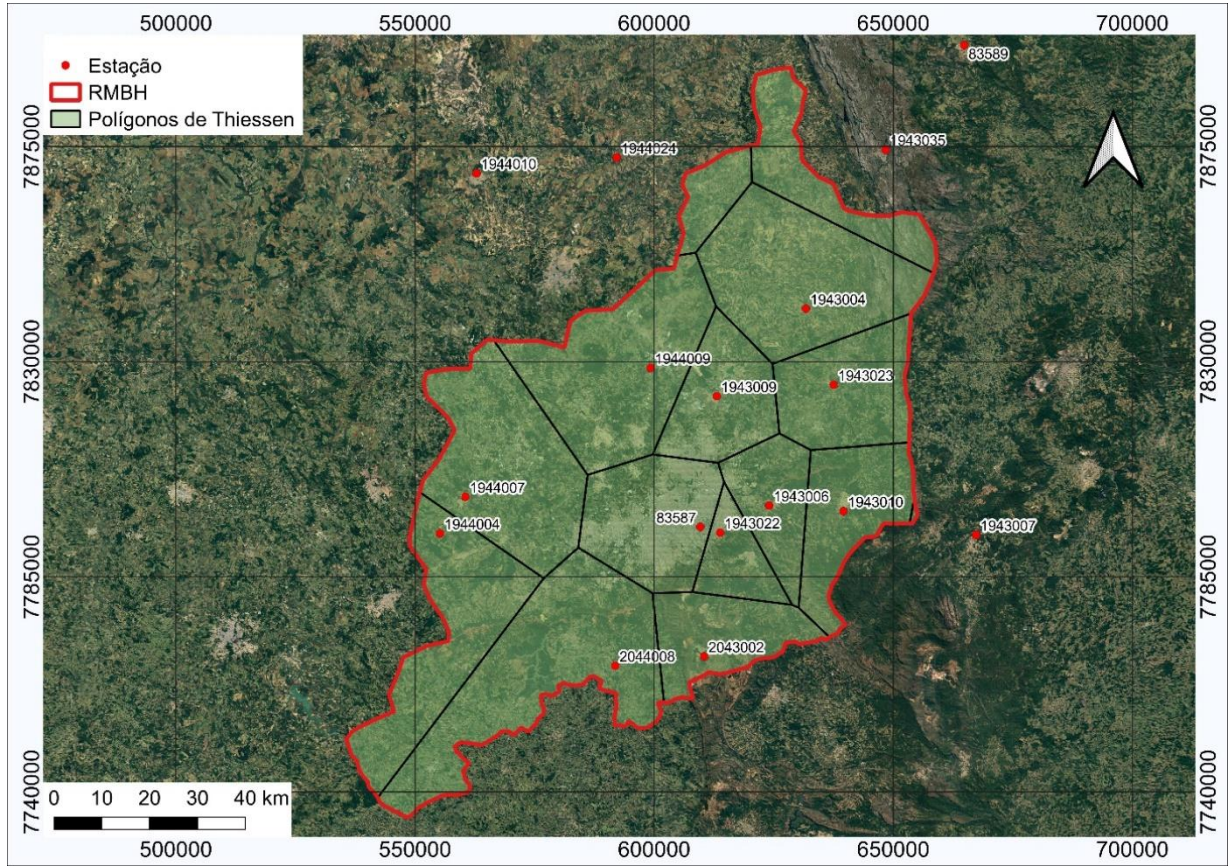


Figura 15 – Dupla Massa – Estação 83587

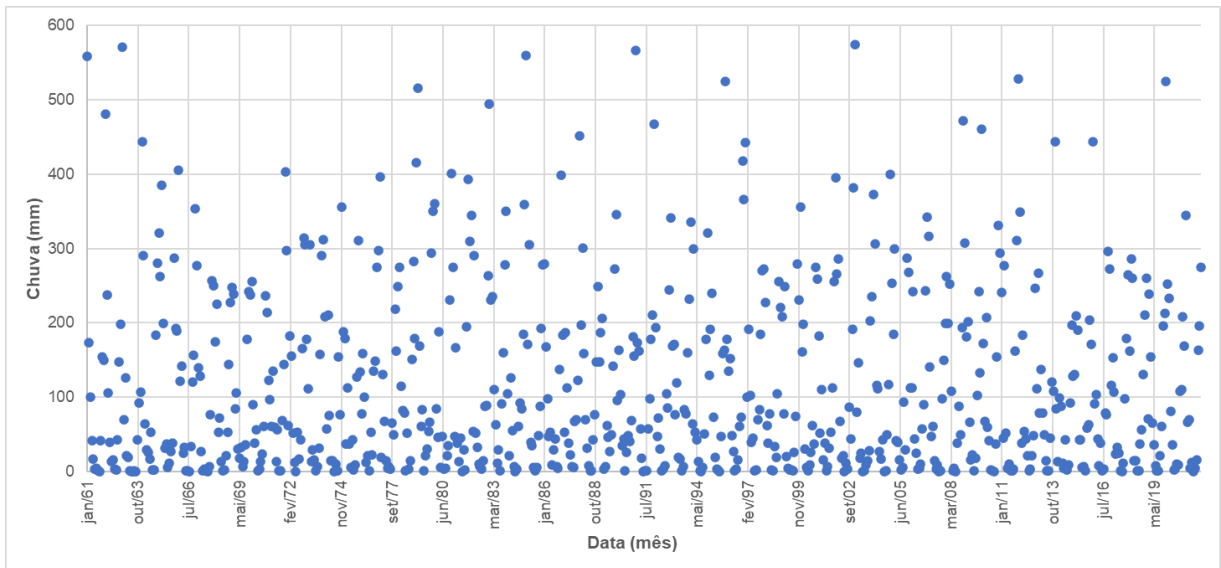


Uma vez preenchidas as falhas e verificada a consistência das informações, os dados observados de chuva mensal de cada estação foram especializados na região metropolitana de Belo Horizonte por meio do método de Thiessen (1911). Os polígonos resultantes são apresentados na Figura 16 e os valores de altura mensal de chuva, por sua vez, são apresentados na Figura 17. As estatísticas descritivas dos dados mensais de chuva são apresentadas no gráfico Box-Plot da Figura 18.


Figura 16 – Polígonos de Thiessen para espacialização da chuva



**Figura 17 – Dados mensais observados – Chuva mensal (mm)**



**Figura 18 – Gráfico Box-plot – Chuva mensal (mm)**




#### 4.1.2 Dados observados de temperatura média

Inicialmente, foi feita uma pesquisa de estações climáticas na região, a partir do banco de dados do INMET (<https://bdmep.inmet.gov.br/>), e foram encontradas apenas 4 estações climatológicas.

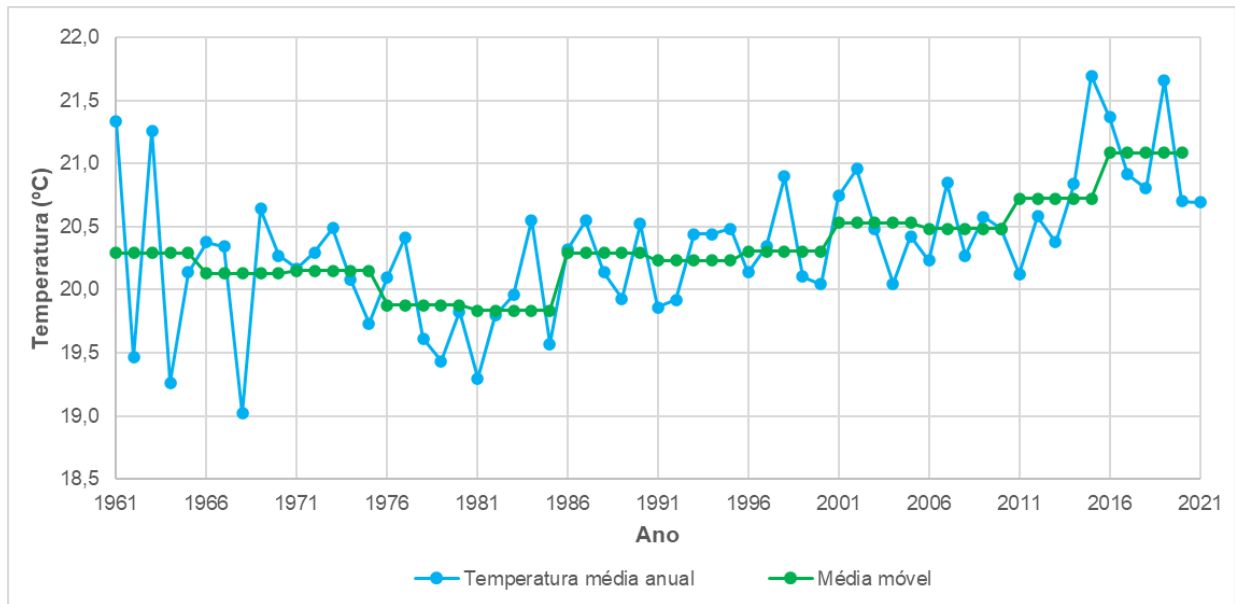
Dado o número reduzido de estações climatológicas na região, optou-se, no caso da temperatura média, por utilizar o conjunto de dados de reanálise em *grid* do Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF) Re-Analysis (ERA5) (Hersbach *et al.*, 2020). O conjunto de dados consiste de uma reanálise de resultados oriundos de um modelo meteorológico em *grid* com resolução espacial de aproximadamente 30 km. ERA5 é a quinta geração de conjuntos de dados de reanálise atmosférica produzidos pelo ECWMF e é baseada em um modelo de previsão que simula componentes interativos da atmosfera, terra e oceano em uma grade global. A assimilação de dados é usada para reunir observações terrestres e de satélite e reduzir a incerteza das previsões.

Os dados mensais de temperatura foram obtidos como camada matricial raster, com auxílio da ferramenta “download\_ERA()”, do R Studio (KUSCH; DAVY, 2022), em unidade de temperatura Kelvin (K). Para transformar os dados em graus Celsius (°C), foi subtraído 273,15 de cada dado mensal. As Figuras 19 e 20 apresentam, respectivamente, os dados de temperatura média mensal e anual, obtidos de Re-Analysis (ERA5). A média móvel da temperatura anual apresentada na Figura 20 sugere uma tendência de aumento a partir dos anos 1990.

**Figura 19 – Dados mensais observados – Temperatura média (°C)**



**Figura 20 – Dados mensais observados – Temperatura média anual (°C)**



## 4.2 Descrição da área de estudo

### 4.2.1 Região Metropolitana de Belo Horizonte

A RMBH inicialmente foi instruída em 1973 pela Lei Complementar nº 14, que também criou as regiões metropolitanas de São Paulo, Porto Alegre, Recife, Salvador, Curitiba, Belém e Fortaleza. Inicialmente, 14 municípios pertenciam à RMBH, a saber: Belo Horizonte, Betim, Caeté, Contagem, Ibirité, Lagoa Santa, Nova Lima, Pedro Leopoldo, Raposos, Ribeirão das Neves, Rio Acima, Sabará, Santa Luzia e Vespasiano.

Já em 1989, a Constituição Estadual de Minas Gerais incorporou os municípios de Brumadinho, Esmeraldas, Igarapé e Mateus Leme à RMBH. Os demais municípios foram incorporados por meio destas leis complementares: nº 43 (31/05/1996); nº 48 (12/11/1997); nº 53 (01/12/1999); nº 56 (12/01/2000); nº 63 (10/01/2002) e nº 89 (12/01/2006). Atualmente, a RMBH conta com 26 municípios: Belo Horizonte, Betim, Brumadinho, Caeté, Confins, Contagem, Esmeraldas, Florestal, Ibirité, Igarapé, Juatuba, Lagoa Santa, Mário Campos, Mateus Leme, Nova Lima, Pedro Leopoldo, Raposos, Ribeirão das Neves, Rio Acima, Rio Manso, Sabará, Santa Luzia, São Joaquim de Bicas, São José da Lapa, Sarzedo e Vespasiano.

#### 4.2.2 Climatologia típica da região

Os climas predominantes da RMBH são do tipo Cwa e Cwb, de acordo com os critérios de Köppen aplicados para o Brasil (ALVARES *et al.*, 2014). A letra “C” indica clima úmido subtropical, a letra “w” indica inverno seco, e as letras “a” e “b” indicam, respectivamente, verão quente e temperado. A Tabela 1 apresenta as faixas de chuva e temperatura da classificação da classificação de Köppen para a RMBH.

**Tabela 1 – Caracterização climatológica da RMBH (adaptado de ALVARES *et al.*, 2014)**


Temperatura		Caracterização	Classificação
$T_{COLD}$	$T_{HOT}$	$R_M$	
$\geq -3\text{ °C} & < 18\text{ °C}$	$\geq 22\text{ °C}$	$R_{DRY} < 40\text{ mm}$	Cwa
	$< 22\text{ °C} & T_{M10} \geq 4$	$R_{SWET} \geq 10^* R_{DRY}$	Cwb

Onde:  $T_{COLD}$  = temperatura mínima do mês;  $T_{HOT}$  = temperatura mais quente do mês;  $R_M$  = chuva mensal;  $R_{DRY}$  = chuva total do mês mais seco;  $R_{SWET}$  = chuva do mês mais úmido no verão.


Além da classificação de Köppen, outra forma de entender a climatologia típica é por meio das “Normais Climatológicas” fornecidas pelo Instituto Nacional de Meteorologia (INMET). As normais climatológicas são valores médios de variáveis meteorológicas calculados para um período relativamente longo e uniforme, compreendendo no mínimo três décadas consecutivas, e representa as características médias do clima em um dado local (BRASIL, 2023). As Figuras 21 a 28 apresentam as normais climatológicas de temperatura média mensal e chuva mensal das estações climatológicas de Belo Horizonte (83587), Conceição do Mato Dentro (83589), Ibirité (83632) e Sete Lagoas (83586), nos períodos de 1961 a 1990, 1981 a 2010 e 1991 a 2020. Apenas as estações de Belo Horizonte e Conceição do Mato Dentro possuem dados nos três períodos das normais climatológicas, obtidas no endereço eletrônico de Brasil (2023). Nota-se que todas as estações climáticas sugerem aumento da temperatura média mensal em cada período analisado. Já os dados mensais de chuva das mesmas estações analisadas não apresentam tendências claras na média mensal e chuva total anual.

Uma tendência em um processo, se esta existir, deve sempre ser avaliada em uma janela maior de tempo do que apenas 30 anos. A ideia de comparação entre comportamentos de processos é conferir se os dados obtidos por reanálise do ERA5 possuem comportamentos similares aos dados observados nos postos climáticos do INMET, e não inferir conclusões a respeito de variabilidade da temperatura na RMBH.


**Figura 21 – Normais climatológicas – temperatura média – estação Conceição do Mato Dentro.**




**Figura 22 – Normais climatológicas – Temperatura média – estação Belo Horizonte.**



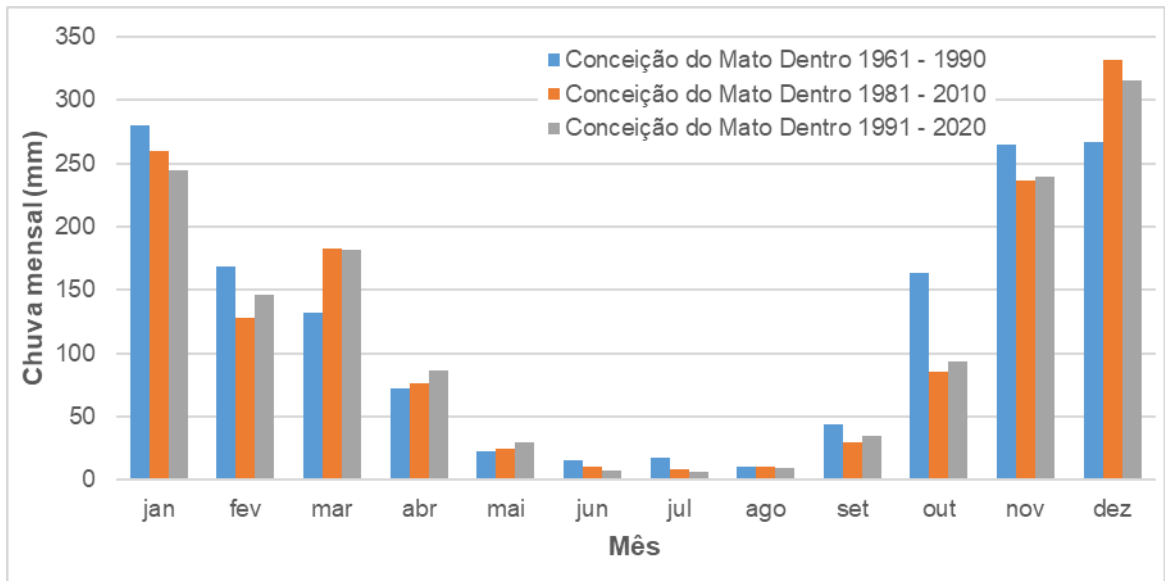
**Figura 23 – Normais climatológicas – Temperatura média – estação Sete Lagoas.**




**Figura 24 – Normais climatológicas – Temperatura média – estação Ibirité.**




**Figura 25 – Normais climatológicas – Chuva mensal – estação Conceição do Mato Dentro.**




**Figura 26 – Normais climatológicas – Chuva mensal – estação Belo Horizonte.**



**Figura 27 – Normais climatológicas – Chuva mensal – estação Sete Lagoas.**



**Figura 28 – Normais climatológicas – Chuva mensal – estação Estação Ibirité.**



Ressalta-se que no Brasil, geralmente, há poucas estações de dados climatológicos com extensão de mais de 50 anos. Como o método Bluecat é um método que fornece a probabilidade de cobertura de quantís de modelos determinísticos em função de dados observados, quanto maior a série de processos reais, mais representativo é o modelo. A escassez de informação espacial também é um ponto a ser destacado, uma vez que não apenas as estações climatológicas possuem dados limitados temporalmente, sua baixa densidade no território nacional também implica que os efeitos orográficos, principalmente em regiões de terreno escarpado, podem não ser bem representados pelas estações climatológicas disponíveis.

### 4.3 Aplicação do método Bluecat para cenários do IPCC

A seguir, é apresentado o procedimento de aplicação do método Bluecat para os cenários do IPCC empregados neste trabalho:

1. A sazonalidade foi extraída subtraindo a média mensal de cada quantil observado e dos modelos determinísticos;
2. Koutsoyannis e Montanari (2022) indicam a aplicação do Bluecat válida apenas se o processo for gaussiano (normalmente distribuído). Caso contrário, os autores recomendam a transformação logarítmica apresentada na equação (23):

$$q' = \lambda \ln \left( 1 + \frac{q}{\lambda} \right) \quad (23)$$

na qual  $q'$  e  $q$  são as variáveis transformada e original, respectivamente (relação também válida para  $Q$ ) – o valor de  $\lambda$  foi obtido por meio de uma função objetivo que aproxima ao máximo os valores sem sazonalidade do Item 1 a uma distribuição empírica com posição de plotagem de Blom, adequada para a distribuição Normal.

3. Dentro da amostra de tamanho  $n$ , escolhe-se um intervalo de vizinhança de  $Q$  com  $m = 50$  valores de  $q$  (exemplo: a Figura 29 apresenta os  $2m+1$  valores de  $q$  correspondentes a  $Q = 1,75$ );
4. Para cada valor de  $Q_{(m+1:m)} < Q < Q_{(n-m:n)}$ , é estimada a função acumulada de probabilidade condicional, considerando a Equação (19) (e.g., a Figura 30 apresenta a função condicional acumulada  $F_{q|Q}(q|Q = -1,75)$ ).
5. São obtidos os parâmetros de extrapolação  $c_H$ ,  $c_L$ ,  $a_H$  e  $a_L$ ;
6. Para os valores fora do intervalo  $Q_{(m+1:m)} < Q < Q_{(n-m:n)}$ , assume-se a aproximação:  $F_{q|Q}(q|Q) \approx F_{(q|Q)} \left( q + a \left( 1 - \frac{1}{c} \right) cQ \middle| cQ \right)$ , e são repetidos os procedimentos 3 e 4.

Figura 29 – Amostra de  $q$  e  $Q$ .

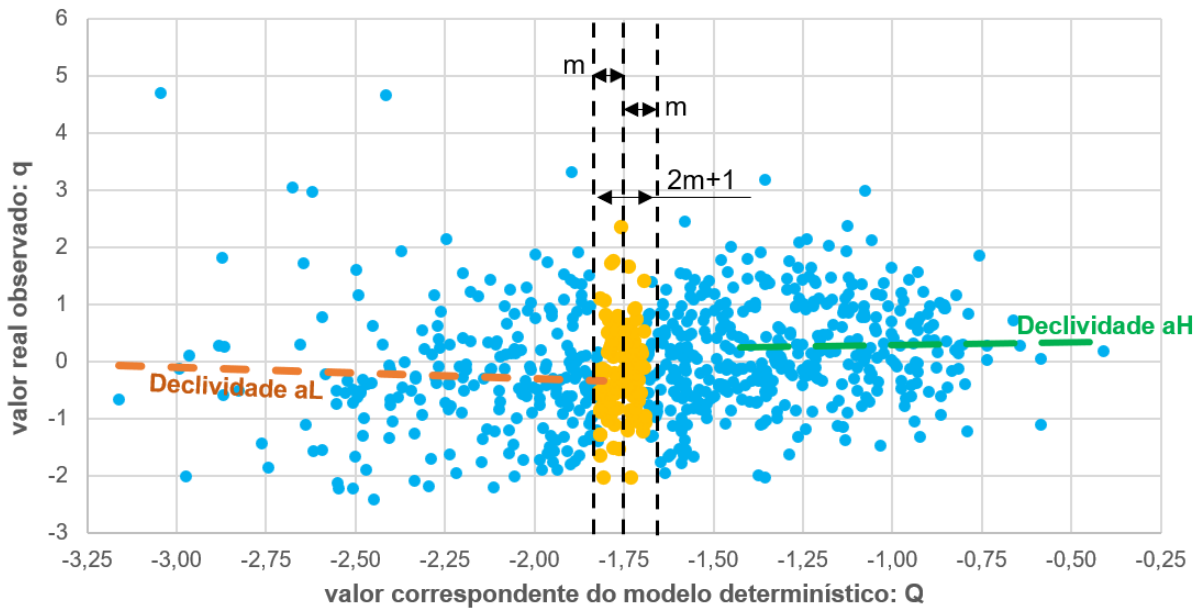



Figura 30 – Distribuição condicional  $F_{q|Q}(q|Q = -1,75)$ .



#### 4.4 Validação do método

Foram considerados como período histórico as séries mensais de chuva e temperatura no período de 1961 a 2021. A amostra de dados observados ( $q$ ) e estimativas do modelo ( $Q$ ) para validação do método Bluecat foi tomada no período de 1961 a 2011, sendo o período de 2012 a 2021 escolhido para validação do modelo (período de teste).

Para os últimos 10 anos do período histórico, foi obtido o intervalo de confiança de 90% ( $F = 0,05$  e  $0,95$  para os limites inferior e superior, respectivamente), conforme descrito no item 4.3.

O objetivo da validação é observar se a probabilidade de cobertura é verificada no período teste, (de 2012 a 2021). Como a validação é feita para um intervalo de confiança de 90%, espera-se a probabilidade de cobertura com a seguinte condição:

$$\text{probabilidade de cobertura} = \left( 1 - \frac{N_{q>q_{95}} + N_{q<q_5}}{N_q} \right) \times 100\% = 90\% \quad (24)$$

Onde:  $N_{q>q_{95}}$  e  $N_{q<q_5}$  se referem, respectivamente, ao número de valores de  $q$  maiores e menores do  $q_{95}$  e  $q_5$ ; sendo  $q_{95}$  e  $q_5$  o quantil  $q$  associado a  $F_{(q|Q)}(q|Q) = 95\%$  e  $F_{(q|Q)}(q|Q) = 5\%$ , respectivamente.

Além da probabilidade de cobertura, um bom indicativo da representação da realidade do processo estocástico é a largura do intervalo de confiança, apresentada na equação (25):


$$IC = q \left( F_{(q|Q)}(q|Q) = 95\% \right) - q \left( F_{(q|Q)}(q|Q) = 5\% \right) \quad (25)$$

A largura do intervalo de confiança indica a medida de incerteza para ajudar a avaliar a precisão e a confiabilidade das estimativas. Quanto mais largo, maior é a incerteza associada ao fenômeno.

#### 4.5 Projeções climáticas

Conforme citado neste trabalho, os dados dos GCM utilizados para obtenção dos dados do período histórico e projeções foram obtidos do NEX-GDDP-CMIP6. Como os dados são disponíveis em *grids* de dimensões 27,8 km x 27,8 km, foi necessária a obtenção de dados diários de mais de um *grid* – 21 ao todo. Os valores dos *grids* foram ponderados pelo valor de área da RMBH interseccionada com a área do *grid*. A Figura 31 apresenta a distribuição dos *grids* sobre a RMBH.

**Figura 31 – Distribuição espacial dos *grids* considerados no modelo**



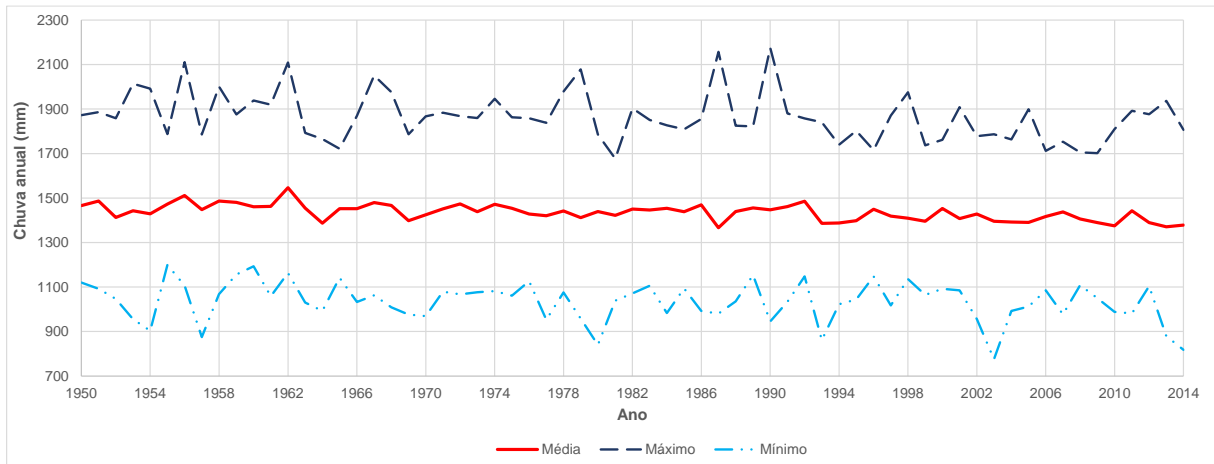
Na prática, costuma-se trabalhar com um “conjunto” (do inglês *ensemble*) de modelos, pois, de acordo com o IPCC (2007), isso aumenta a confiança nos resultados, fornecendo uma melhor representação da incerteza do modelo.

Uma vez que os quantis do intervalo de confiança do modelo determinístico (modelo-D) serão determinados pelo método Bluecat, a média dos resultados históricos e projeções dos GCMs será empregada na construção da amostra do modelo-D, pois todos os modelos possuem trajetórias semelhantes, como será visto nos capítulos seguintes.


#### 4.5.1 Chuva

Apenas como forma ilustrativa, as figuras 32, 33, 34 e 35, respectivamente, apresentam os valores máximo, mínimo e médio de chuva anual para o período histórico, cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5. Nota-se que, em média, as projeções indicam um leve decréscimo das chuvas anuais.


**Figura 32 – Valores de chuva anual de cada modelo climático e valor médio do período histórico (1950 – 2014)**




**Figura 33 – Valores de chuva anual de cada modelo climático e valor médio – projeções do cenário SSP1-2.6 (2015 – 2100)**



**Figura 34 – Valores de chuva anual de cada modelo climático e valor médio – projeções do cenário SSP2-4.5 (2015 – 2100)**



**Figura 35 – Valores de chuva anual de cada modelo climático e valor médio – projeções do cenário SSP5-8.5 (2015 – 2100)**




#### 4.5.2 Temperatura média

Da mesma forma que a chuva, as figuras 36, 37, 38 e 39 apresentam, respectivamente, os valores de temperatura máxima, mínima e média anual para o período histórico, projeções nos cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5. De uma forma bem mais acentuada, todos os resultados dos GCM seguem a mesma trajetória de crescimento. Dessa forma, tal qual a chuva, os dados de temperatura do modelo-D utilizados para aplicação do método Bluecat foram os dados médios diários dos modelos.


Notou-se no período histórico que dois GCMs destoam no período histórico, quais sejam, TaiESM1 e CMCC-CM2-SR5. Já na projeção dos cenários SSP2-4.5 e SSP5-8.5, apenas os dados do modelo CMCC-CM2-SR5 destoam dos demais. Portanto, os dados desses GCMs não foram considerados para o estudo.

A partir dos modelos e da média, é notável a indicação de um aumento anual de temperatura mais acentuado a partir dos anos 1990. Nas projeções do cenário SSP2-4.5, verifica-se um aumento mais acentuado da temperatura anual entre 2015 e meados de 2055, e um aumento menos acentuado entre meados de 2055 e 2100. Para as projeções do cenário SSP5-8.5, os GCMs apresentam resultados de crescimento acentuado em todo o período de 2015 e 2100.


**Figura 36 – Valores de temperatura média anual de cada modelo climático e valor médio do período histórico (1950 – 2014)**




**Figura 37 – Valores de temperatura média anual de cada modelo climático e valor médio – projeções do cenário SSP1-2.6 (2015 – 2100)**



**Figura 38 – Valores de temperatura média anual de cada modelo climático e valor médio – projeções do cenário SSP2-4.5 (2015 – 2100)**



**Figura 39 – Valores de temperatura média anual de cada modelo climático e valor médio – projeções do cenário SSP5-8.5 (2015 – 2100)**




#### 4.6 Correção de viés

A correção do viés será feita através da aproximação da trajetória do modelo-D para a medida de valor central de  $q$ , neste caso, para  $F_{(q|Q)}(q|Q) = 50\%$  (mediana). Desta forma, procura-se trazer o estimador do modelo-D para dentro do intervalo de confiança obtido pelo método Bluecat.


São definidos  $Q$  e  $q_{50}$  como, respectivamente, a variável do GCM e o quantil equivalente à mediana obtida no método Bluecat. Ambos foram subtraídos de suas médias mensais, ou seja, representam apenas as parcelas de aleatoriedade e tendência. As séries de  $Q$  e  $q_{50}$  possuem uma trajetória suavizada, no intervalo de tempo  $\tau$ , definida por  $\omega(\tau)$  e  $\omega_{50}(\tau)$ , respectivamente. A Figura 40 ilustra a situação descrita neste parágrafo.

Figura 40 – Trajetórias suavizadas de  $Q$  e  $q_{50}$



Conforme apresentado na Figura 41, denomina-se  $d$  a distância entre  $Q$  e  $Q^\omega$ , sendo  $Q^\omega$  o valor de  $\omega$  no mesmo instante de tempo  $\tau$  de  $Q$ . Considera-se o estimador corrigido  $W$  o valor com distância  $d$  da variável  $q^{\omega_{50}}$ , sendo  $q^{\omega_{50}}$  o valor de  $\omega_{50}$  no mesmo instante de tempo  $\tau$  de  $Q$ . Com isso, os valores do modelo determinístico passam a variar aleatoriamente em torno da mediana obtida pelo método Bluecat. A trajetória suavizada foi obtida com auxílio da ferramenta `lowess()`, disponível no R Studio (CLEVELAND, 1979; CLEVELAND, 1981; BECKER et al. 1988).

Figura 41 – Correção de  $Q$  para  $W$ .



## 5 APLICAÇÃO DO MÉTODO BLUECAT PARA DIFERENTES CENÁRIOS DO IPCC

Este capítulo apresenta os principais resultados do método Bluecat, aplicado para correção de viés dos modelos climáticos e obtenção dos quantis com probabilidades de excedência de 95%, 50% e 5% (ou seja, intervalo de confiança de 90% e mediana).


### 5.1 Resultados da validação do método

Para os últimos 10 anos do período histórico foi obtida a probabilidade de cobertura (mínimo de 90%), e os resultados para os limites inferior ( $F = 0,05$ ) e superior ( $F = 0,95$ ) para o intervalo de confiança dos quantis de chuva mensal subtraídos da média são apresentados na Figura 42. As probabilidades de cobertura no período histórico (1961-2011), período projetado (2012-2021) e período completo (1961 – 2021) são apresentadas na Tabela 1.

**Tabela 1 – Probabilidades de cobertura no período teste – chuva mensal**

Período	$N_{q < q_5} + N_{q > q_{95}}$	$N_q$	% de cobertura
Histórico	81	612	86,8
Projetado	17	120	85,8
Completo	98	732	86,6

**Figura 42 – Probabilidade de cobertura (90%) do período histórico (1961 – 2011) e do período teste (2012 – 2021) – chuva mensal**




Os resultados da probabilidade de cobertura para a temperatura média mensal sem sazonalidade são apresentados na Figura 43. As probabilidades de cobertura no

período histórico (1961 – 2011), período projetado (2012 – 2021) e período completo (1961 – 2021) são apresentados na Tabela 2:

**Tabela 2 – Probabilidades de cobertura no período teste – temperatura média mensal**

Período	$N_{q < q_5} + N_{q > q_{95}}$	$N_q$	% de cobertura
Histórico	74	612	87,8
Projetado	17	120	85,8
Completo	91	732	87,6

**Figura 43 – Probabilidade de cobertura (90%) do período histórico (1961 – 2011) e do período teste (2012 – 2021) – temperatura média mensal**



Sobre o período de validação da temperatura, destaca-se que, embora a probabilidade de cobertura calculada seja inferior a 90%, estas são próximas ao limite teórico.

Com relação à largura dos intervalos de confiança (IC), a largura média para o período completo é de 6,47 mm/dia no caso da chuva e de 2,81 °C no caso da temperatura. Já para o período projetado, a largura do IC aumenta para 6,93 mm/dia para a chuva e uma redução para 2,71 °C no caso temperatura. Ou seja, no caso da chuva, a incerteza é maior no período projetado, pelo fato o intervalo de confiança no período projetado ser mais largo.

Verifica-se na Figura 43 que os resultados para os quantis de  $q$  associados a  $F_{(q|Q)}(q|Q) = 95\%$ , a partir de meados do ano 2000, não apresentam a mesma dispersão observada no período histórico. Em termos gerais, esses resultados se dão

peelo fato de a extrapolação buscar uma faixa específica de  $Q$  dentro do intervalo  $Q_{(m+1:m)} < Q < Q_{(n-m:n)}$ , ou seja, os valores  $cQ$  são aproximados para uma mesma faixa de valores próximos de  $Q$ . A sequência de Figuras 44 a 46 ilustra esta questão.

A Figura 44 apresenta os valores de  $q$  versus  $Q$ , e as regiões fora do intervalo  $Q_{(m+1:m)} < Q < Q_{(n-m:n)}$  onde é necessário realizar a aproximação indicada pela equação (20). Já a Figura 45 apresenta os valores de  $Q$  no período histórico e período de teste. Nota-se, na Figura 46, que, ao aplicar a constante  $c$  para os valores de  $Q > Q_{(n-m:n)}$  e alguns valores de  $Q$  no período de teste, as aproximações  $cQ$  se concentram em uma faixa específica entre 0,25 e 0,50. Portanto, ao aplicar a aproximação da equação (20), as funções de densidade acumulada condicional também serão similares. Esse comportamento pode ser mitigado com duas alternativas: aumento da amostra ou modificação do valor de  $m$ .

**Figura 44 – Valores de  $q$  e  $Q$  no período de validação – as linhas tracejadas indicam o limite onde a expansão deverá ser aplicada**




Figura 45 – Valores  $Q$  no período de validação





Figura 46 – Aproximação dos valores de  $cQ$  para amostra  $Q_{(m+1:m)} < Q < Q_{(n-m:n)}$ .




## 5.2 Tratamento dos dados observados e dos modelos determinísticos

Para se trabalhar com o maior número de informações possíveis, para ambas as variáveis, cada valor mensal foi subtraído pela correspondente média mensal como forma de extrair a sazonalidade. Com a sazonalidade a amostra de dados observados reduziria a 1/12.


No caso da temperatura, observa-se que não há assimetria significativa para os dados do histórico observado (ERA5) – Figura 47. No cenário de emissão média, nota-se um

histograma bimodal (Figura 50). Para o cenário de maior emissão, verifica-se uma assimetria à esquerda (Figura 49) e, no cenário de menor emissão, observa-se uma assimetria à direita (Figura 48). A aplicação da transformação sugerida na equação (23) não trouxe grandes ganhos com relação à normalização da série para um valor de  $\lambda = 10,96 \text{ }^\circ\text{C}$ .

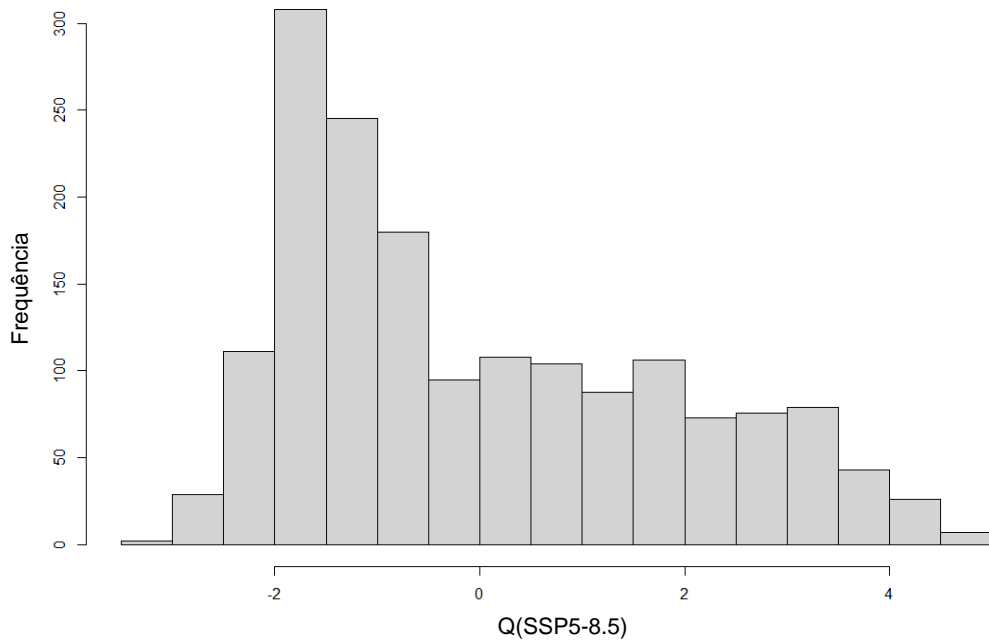
**Figura 47 – Histograma dos dados mensais de temperatura (q) subtraídos da média**




**Figura 48 – Histograma dos dados mensais de temperatura (QSSP1-2.6) subtraídos da média**



**Figura 49 – Histograma dos dados mensais de temperatura (QSSP5-8.5) subtraídos da média**



**Figura 50 – histograma dos dados mensais de temperatura (QSSP2-4.5) subtraídos da média**



Os dados mensais de chuva também foram extraídos de sua média mensal, ou seja, sua sazonalidade, com o objetivo de se trabalhar com o maior número de informação possível. Caso fosse trabalhar com dados mensais, as amostras se reduziram a pelo menos 1/12 da amostra estudada. Observou-se, no entanto, que os dados de chuva


apresentam assimetria acentuada, ao contrário dos dados de temperatura. Para tanto, esses dados foram transformados com  $\lambda = 21,07$  mm.

### 5.3 Resultados sem sazonalidade

Além da probabilidade de cobertura, outra forma de avaliar o quão bem os modelos se ajustam aos dados reais é traçar a projeção estocástica versus a predição do modelo determinístico, como demonstrado para a temperatura na Figura 51. A projeção estocástica é apresentada em termos de  $q(F_{(q|Q)}(q|Q) = 95\%)$  e  $q(F_{(q|Q)}(q|Q) = 5\%)$ , representando um intervalo de confiança de 90%.

Conforme Koutsoyannis e Montanari (2022), o modelo determinístico representa a realidade se a linha mediana estiver próxima à linha de igualdade e o intervalo de confiança for estreito. Por outro lado, um modelo completamente irrelevante resultaria em uma linha reta horizontal com uma ampla faixa de confiança. No caso da temperatura, os modelos determinísticos não são muito eficazes, pois a linha de igualdade não é completamente abrangida pelo intervalo de confiança.

Os capítulos 5.3.1, 5.3.2 e 5.3.3 a seguir apresentam os resultados para o período histórico e período projetado em termos de intervalo de confiança de 90% ( $F_{(q|Q)}(q|Q) = 95\%$  e  $F_{(q|Q)}(q|Q) = 5\%$ ), além da mediana ( $F_{(q|Q)}(q|Q) = 50\%$ ).

**Figura 51 – q e projeção estocástica versus modelo determinístico – cenários SSPs**

### 5.3.1 Constantes de extrapolação

A expansão descrita nos itens 3.6.3 e 4.3 é feita em função das constantes de extrapolação  $c_H$ ,  $c_L$ ,  $a_H$  e  $a_L$ . As constantes  $a_H$  e  $a_L$  foram obtidas para o período histórico de 1961 (início do período histórico) a 2021 (final do período histórico) através de uma regressão linear entre  $q$  e  $Q$ , conforme apresentado na descrição da metodologia no capítulo 3.6. O Quadro 5 apresenta os resultados das constantes encontradas para cada cenário. Essas constantes foram definidas com os dados subtraídos da média mensal e transformados pela equação (23). As Figuras 52 a 57 apresentam as regressões feitas no primeiro e último 1/4 do conjunto  $q \times Q$ , para todos os cenários de chuva e temperatura.

**Quadro 5 – Constantes de extrapolação encontradas para cada cenário**

Variável	Cenário	$a_L$	$a_H$	$c_L$	$c_H$	$Q_{(m+1:n)}$	$Q_{(n-m:n)}$	$Q_L$	$Q_H$
Chuva	SSP1-2.6	1,430	0,662	0,15	0,29	-0,45	0,46	-3,03	1,59
	SSP2-4.5	1,160	0,168	0,30	0,29	-0,50	0,44	-1,66	1,52
	SSP5-8.5	1,058	0,008	0,18	0,29	-0,48	0,44	-2,65	1,52
Temperatura	SSP1-2.6	-0,444	0,140	0,38	0,32	-0,52	0,75	-1,37	2,36
	SSP2-4.5	-0,393	-0,336	0,38	0,19	-0,52	0,68	-1,37	3,50
	SSP5-8.5	-0,444	-0,058	0,38	0,12	-0,52	0,69	-1,37	5,54

**Figura 52 –  $q \times Q$  – Chuva – cenário: SSP1-2.6**




Figura 53 – q x Q – Chuva – cenário: SSP2-4.5





Figura 54 – q x Q – Chuva – cenário: SSP5-8.5






**Figura 55 – q x Q – Temperatura – cenário: SSP1-2.6****Figura 56 – q x Q – Temperatura – cenário: SSP2-4.5.**


Figura 57 – q x Q – Temperatura – cenário: SSP5-8.5




### 5.3.2 Período histórico

As figuras 58 e 59 apresentam os resultados dos intervalos de confiança de 90%, obtidos para as estimativas de chuva e temperatura, respectivamente. Nota-se a diferença nítida entre a variabilidade do modelo determinístico com os dados observados, tanto para chuva quanto para temperatura. As figuras 60 a 61 apresentam a dispersão dos dados do intervalo de confiança atenuada substituindo pela média móvel dos valores aleatórios com passo de tempo de 12 meses.


Figura 58 – Resultados do método Bluecat para o período histórico de chuva mensal (mm/d).




**Figura 59 – Resultados do método Bluecat para o período histórico de temperatura mensal (°C)**



**Figura 60 – Resultados do método Bluecat para o período histórico de chuva mensal – média móvel de 12 meses (mm/d)**



**Figura 61 – Resultados do método Bluecat para o período histórico de temperatura mensal – média móvel de 12 meses (°C)**



Nota-se que a série observada de chuva não apresenta tendência clara em torno dos dados subtraídos da média mensal. Os valores do modelo determinístico se mantêm muito próximos da mediana calculada pelo método Bluecat. Já no caso da temperatura subtraída da média, observa-se claramente uma que o método Bluecat capta a variabilidade da temperatura no período histórico. A Tabela 3 apresenta a probabilidade de cobertura calculada no período histórico, tanto para chuva quanto para temperatura mensal. Nota-se que as probabilidades de cobertura ficaram próximas ao encontrado na validação do estudo (capítulo 5.1), ou seja, considerando o período histórico completo, a probabilidade de cobertura se alterou pouco comparado ao apresentado no período de validação do método.


**Tabela 3 – Probabilidades de cobertura no período histórico de chuva e temperatura**

Variável	$N_{q < q_{5}} + N_{q > q_{95}}$	$N_q$	% Cobertura
Chuva (mm/dia)	91	732	87,57
Temperatura (°C)	88	732	87,98


### 5.3.3 Período projetado

As Figuras 62, 63 e 64 apresentam, respectivamente, os resultados da aplicação do método Bluecat nas projeções dos cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5 para chuva. Os resultados para o intervalo de confiança de 90% seguem comportamento muito próximo do período observado justamente pelo fato de as estimativas do modelo determinístico de chuva não indicarem grandes variações nos dados de chuva. Os resultados com a média móvel de 12 meses são apresentados nas figuras 65, 66 e 67 para os cenários, respectivamente, SSP1-2.6, SSP2-4.5 e SSP 5-8.5.


**Figura 62 – Resultados método Bluecat para a projeção de chuva no cenário de menor emissão (SSP1-2.6)**




**Figura 63– Resultados do método Bluecat para a projeção de chuva no cenário mediano (SSP2-4.5)**




**Figura 64 – Resultados do método Bluecat para a projeção de chuva no cenário maior emissão (SSP5-8.5)**




**Figura 65 – Resultados do método Bluecat para a projeção de chuva no cenário mediano (SSP1-2.6) – média móvel de 12 meses**



**Figura 66 – Resultados do método Bluecat para a projeção de chuva no cenário mediano (SSP2-4.5) – média móvel de 12 meses**



**Figura 67 – Resultados do método Bluecat para a projeção de chuva no cenário de maior emissão (SSP5-8.5) – média móvel de 12 meses**




Os resultados para as projeções de temperatura dos modelos determinísticos para os cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5 são apresentados, respectivamente, nas Figuras 68, 69 e 70. É nítida a tendência do intervalo de confiança e da mediana captada pelo *Bluecat*. Os intervalos de confiança considerando a média móvel de 12 meses mostram que a tendência indicada pelo método *Bluecat* não é tão significativa. Os resultados com a média móvel de 12 meses para os SSP1-2.6, SSP2-4.5, SSP5-8.5 são apresentados, respectivamente, nas Figuras 71, 72 e 73.


**Figura 68 – Resultados do método *Bluecat* para a projeção de temperatura no cenário de menor emissão (SSP1-2.6)**




**Figura 69 – Resultados do método *Bluecat* para a projeção de temperatura no cenário mediano (SSP2-4.5)**




**Figura 70 – Resultados do método Bluecat para a projeção de temperatura no cenário de maior emissão (SSP5-8.5)**




**Figura 71 – Resultados do método Bluecat para a projeção de temperatura no cenário mediano (SSP1-2.6) – média móvel de 12 meses**



**Figura 72 – Resultados do método Bluecat para a projeção de temperatura no cenário mediano (SSP2-4.5) – média móvel de 12 meses**



**Figura 73 – Resultados do método Bluecat para a projeção de temperatura no cenário de maior emissão (SSP5-8.5) – média móvel de 12 meses**



Diferentemente dos resultados para a precipitação, a temperatura mostra tendências características para os três cenários. Verificou-se que os valores de  $Q$  fora do intervalo de confiança para os cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5 são de 24%, 15% e 78%, respectivamente. A Tabela 4 apresenta os intervalos de confiança médios para o período histórico e para o período projetado para os três cenários. No caso da chuva, o intervalo de confiança médio é maior no período projetado, o que denota uma faixa maior de incerteza. No caso da temperatura, os intervalos de confiança são praticamente iguais no período histórico e no período projetado.

**Tabela 4 – Intervalo de confiança médio para período histórico e projeção dos três cenários – chuva e temperatura**

Variável	Cenário	IC médio	
		período histórico	período projetado
Temperatura (°C)	SSP1-2.6	2,8	2,8
	SSP2-4.5	2,8	2,9
	SSP5-8.5	2,9	2,9

#### 5.4 Resultados com sazonalidade

Uma vez obtidos os resultados para os dados subtraídos de sua média mensal, somou-se aos quantis o valor da média mensal, de modo a retomar a sazonalidade das observações e do modelo determinístico. No caso da chuva, em que houve a normalização pela transformação logarítmica, faz-se o inverso da transformação e esse valor é somado à média mensal. Os resultados para a chuva nos cenários SSP1-

2.6, SSP2-4.5 e SSP5-8.5 são apresentados nas Figuras 74, 75 e 76, respectivamente. Para a temperatura, os resultados para os cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5 são apresentados, respectivamente, pelas Figuras 77, 78 e 79.

Os meses do período de estiagem apresentaram maior largura no intervalo de confiança de 90%, ou seja, maior incerteza atrelada ao modelo. Além de resultados fisicamente inconsistentes:  $q(F_{(q|Q)}(q|Q) = 5\%) < 0$ . Os intervalos de confiança nos meses chuvosos apresentaram intervalo de confiança mais próximo e resultados consistentes do ponto de vista físico.

No caso das projeções da temperatura, o cenário de menor emissão (SSP1-2.6) não apresentou tendências de aumento até 2100, ao contrário dos cenários médio (SSP2-4.5) e de maior emissão (SSP5-8.5), os quais apresentaram tendências de aumento da temperatura até 2100, porém com taxas de aumentos menores do que o indicado pelos modelos globais (GCM).

Os resultados mensais para projeção de chuva ilustram o aumento do intervalo de confiança no período projetado apontado na Tabela 4, principalmente nos meses de menor pluviosidade (maio, junho, julho, agosto e setembro).

Ao contrário dos resultados para chuva, a temperatura não apresentou grandes diferenças entre a largura do intervalo de confiança no período projetado e período histórico. No entanto, as trajetórias dos cenários não são mantidas. Recentemente, esse comportamento foi denominado *the “hot model” problem* (HAUSFATHER et al. 2022). De acordo com os autores, trata-se de uma questão reconhecida pelo IPCC.

A maior fonte de incerteza nas temperaturas globais daqui a 50 ou 100 anos é a quantidade de emissões futuras de gases de efeito estufa, que são em grande parte controladas por ações humanas. No entanto, mesmo que soubéssemos exatamente qual seria esta taxa de emissão, ainda assim não saberíamos com precisão o quão quente o planeta se tornaria (HAUSFATHER et al. 2022) pelo fato de o aquecimento global causado por ações antrópicas ser um experimento enorme e sem precedentes.

Figura 74 – Resultados mensais – Chuva – SSP1-2.6



Figura 75 – Resultados mensais – Chuva – SSP2-4.5



Figura 76 – Resultados mensais – Chuva – SSP5-8.5

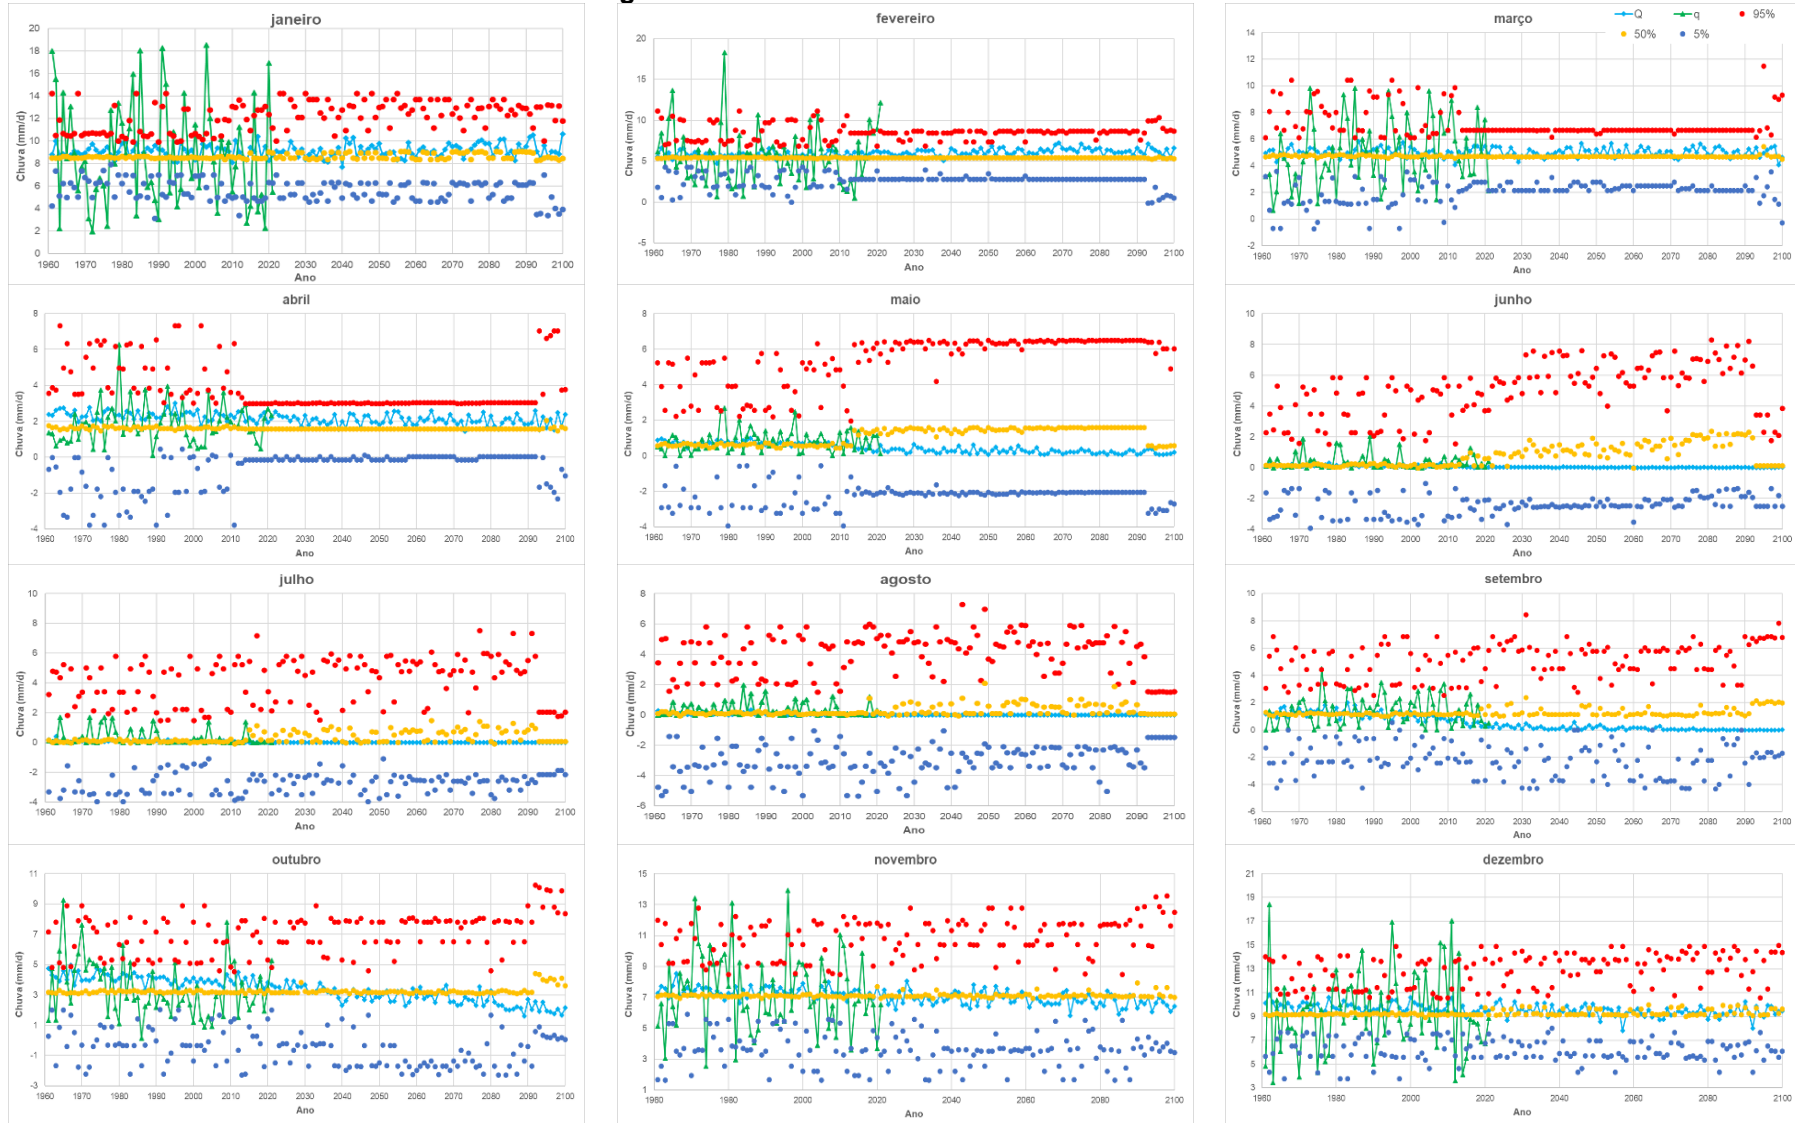


Figura 77 – Resultados mensais – Temperatura – SSP1-2.6

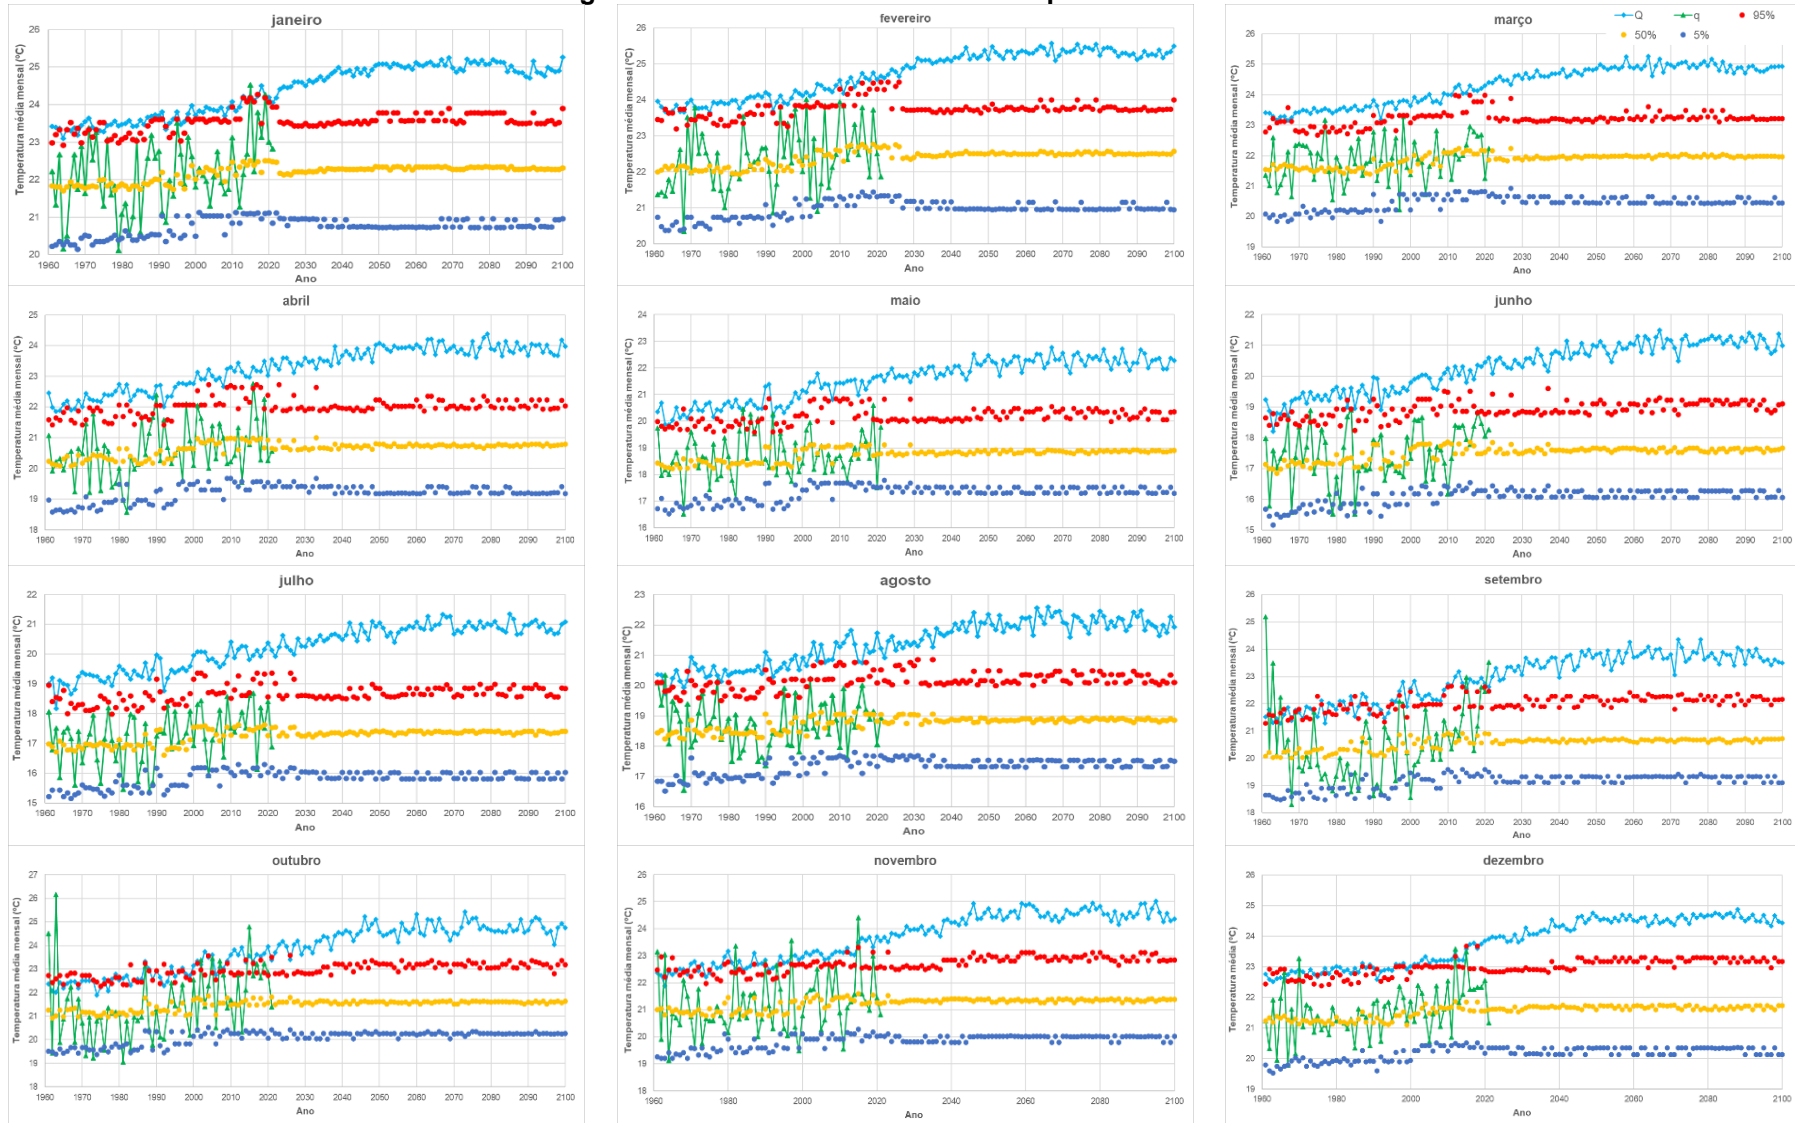


Figura 78 – Resultados mensais – Temperatura – SSP2-4.5

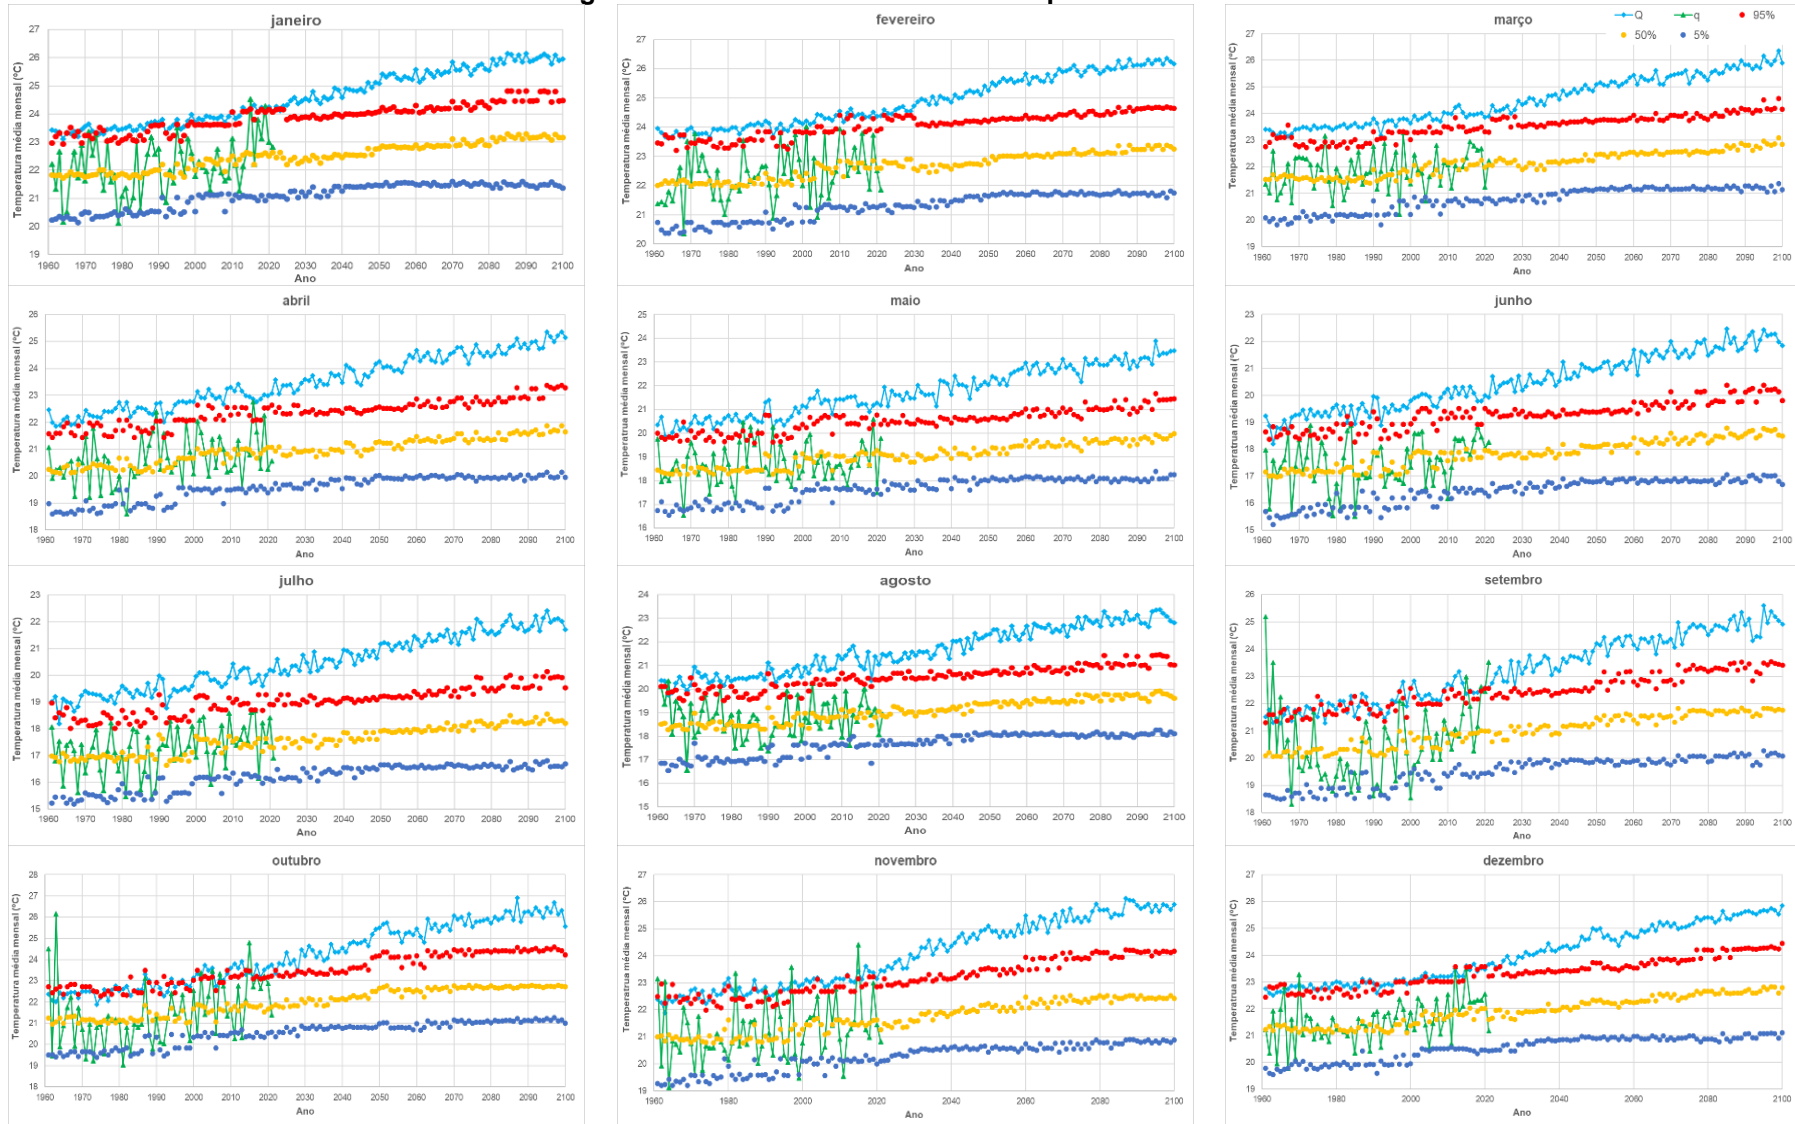
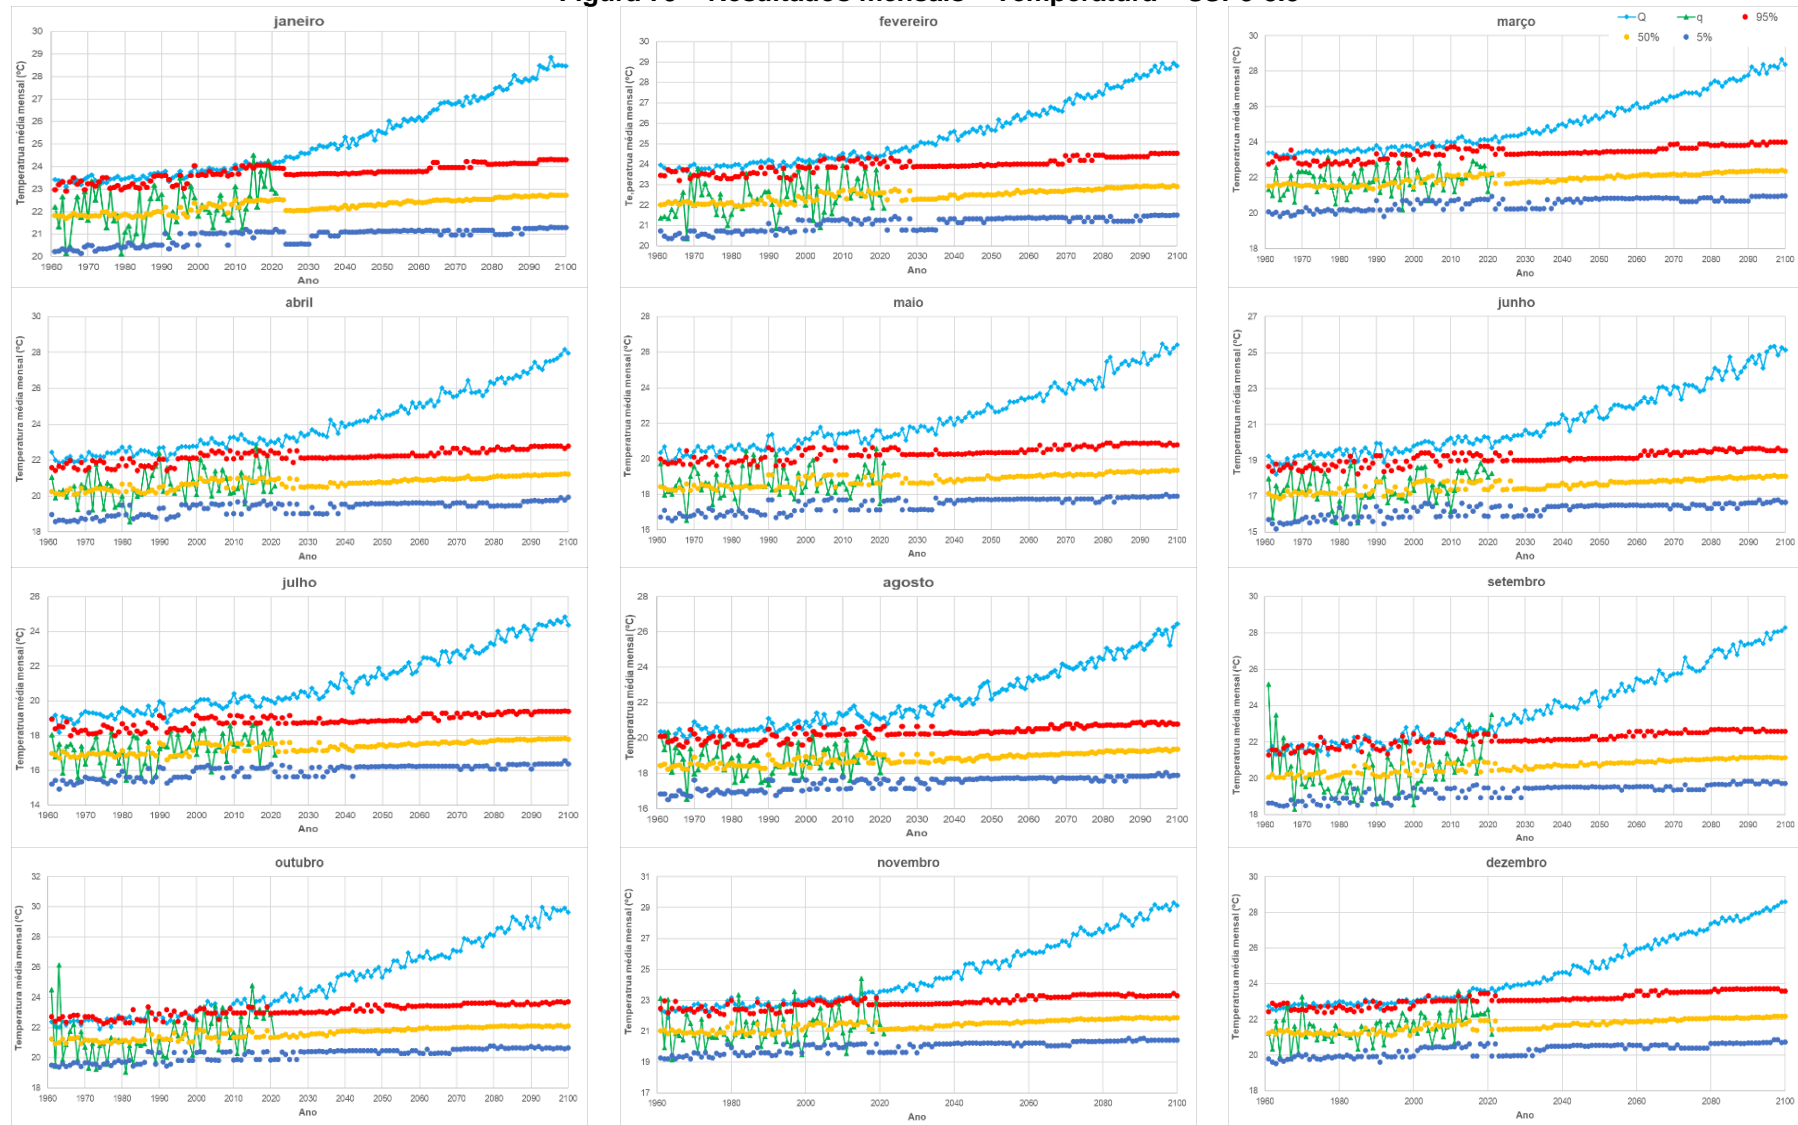


Figura 79 – Resultados mensais – Temperatura – SSP5-8.5




## 5.5 Correção de viés das projeções

Uma vez que os intervalos de confiança para os cenários de chuva apresentaram inconsistências físicas e intervalos de confiança largos nos períodos de estiagem, a correção de viés só foi feita para os cenários de temperatura, conforme procedimento apresentado no item 4.6, sendo W o modelo corrigido. As Figuras 80, 81 e 82 apresentam, respectivamente, os resultados nos cenários SSP1-2.6, SSP2-4.5 e SSP5-8.5 em termos de temperatura média anual.


No cenário de menor emissão (SSP1-2.6), a diferença entre Q e W é próxima a 1 °C. Já para o cenário médio (SSP2-4.5) é de aproximadamente 1,5 °C e o cenário de maior emissão apresenta uma diferença próxima de 5 °C em 2100.

A Figura 83 apresenta o comparativo entre modelos corrigidos. Nota-se que o cenário de emissão média (SSP2-4.5) corrigido apresentou taxa de aumento de temperatura muito próxima ao de maior emissão (SSP5-8.5). Por sua vez, o cenário de menor emissão (SSP1-2.6) não apresentou aumento de temperatura.


Figura 80 – Viés do modelo corrigido: temperatura – SSP1-2.6




**Figura 81 – Viés do modelo corrigido: temperatura – SSP2-4.5**



**Figura 82 – Viés do modelo corrigido: temperatura – SSP5-8.5**



**Figura 83 – Temperatura média anual – histórico observado e projeções corrigidas**



## 6 CONCLUSÕES E RECOMENDAÇÕES

Corrigir o viés de modelos/estimadores utilizando métodos estatísticos é fundamental uma vez que os processos físicos que governam o ciclo hidrológico envolvem aleatoriedade inerente (MONTANARI; KOUTSOYIANNIS, 2012); por exemplo, processos meteorológicos, conforme introduzido no capítulo 3.2, são governados por leis da termodinâmica que, em sua essência, são leis da física estatística.

O método Bluecat foi aplicado de modo a se obter as distribuições condicionais  $F_{(q|Q)}(q|Q)$  de forma empírica e, em função dos quantis empíricos, corrigir as estatísticas e fornecer o intervalo de confiança dos GCMs. A respeito da aplicação do método Bluecat sobre a chuva mensal e a temperatura média mensal, destacam-se os seguintes pontos a respeito do período histórico:

- Embora Koutsoyiannis e Montanari (2022) indiquem que a extrapolação com o método Bluecat é exata se tais variáveis forem normalmente distribuídas, caso a normalidade não seja atingida pela transformação, é possível se obter uma aproximação. Neste trabalho, as variáveis transformadas não apresentaram a normalidade, ou seja, a relação apresentada pela equação (20), utilizada para os modelos de chuva e temperatura neste trabalho, segue apenas uma aproximação;
- No período de validação do método (capítulo 5.1), verificou-se que, embora a probabilidade de cobertura não tenha sido exatamente de 90%, para o intervalo de confiança especificado, os valores ficaram próximos. Quando da aplicação do método Bluecat no período histórico, os valores da probabilidade de cobertura também ficaram próximos dos 90%;

A aplicação do método Bluecat foi realizada para três cenários propostos pelo CMIP6, cada qual representando: um cenário mais otimista com relação à redução da taxa de emissão de Gases do Efeito Estufa (GEE) e políticas de desenvolvimento sustentável (SSP1-2.6); um cenário mediano (SSP2-4.5); e um cenário pessimista do ponto de vista de altas taxas de GEE, além de ausência de políticas de desenvolvimento sustentável (SSP5-8.5). A respeito da correção de viés e obtenção do intervalo de confiança sobre as projeções climáticas, observa-se que:

- Em todos os cenários para a chuva mensal, avaliando os valores mensais, não são observadas tendências significativas nos modelos determinísticos, principalmente quando comparado à temperatura. Apenas foi observado que os meses nos períodos de estiagem foram se tornando cada vez menos chuvosos. Justamente os meses de pouca pluviosidade (maio a agosto) apresentaram intervalos de confiança largos no período projetado (2022 – 2100), em comparação com o período histórico (1961 – 2021), além de estimativas de chuva negativas, ou seja, fisicamente inconsistentes. Quando da aplicação do método Koutsoyiannis e Montanari (2022) sobre a chuva mensal, a escala de aplicação (todo território da Itália) apresenta uma chuva sem sazonalidade proeminente. Aparentemente, a escala de aplicação na RMBH e a sazonalidade marcante da região têm uma influência nos resultados da aplicação do método Bluecat quando se tem meses menos chuvosos;
- Ao contrário da chuva mensal, o *Bluecat* apresentou um intervalo de confiança menos largo tanto no período histórico quanto no período projetado. Todos os cenários apresentam tendências e, apesar de o método Bluecat ter sido desenvolvido assumindo estacionariedade do processo estocástico, em todos os cenários foram captadas tendências no período projetado (2022 – 2100). É válido ressaltar que a hipótese de estacionariedade permanece válida, uma vez que as distribuições condicionais não são postas como função do tempo. Esta conclusão é importante pelo fato de os modelos de projeções de cenários do IPCC serem, via de regra, não estacionários e, portanto, os parâmetros serem variáveis com o tempo. Através o método Bluecat, é possível traçar trajetórias possíveis sem necessariamente alterar os parâmetros em função do tempo;
- Os resultados do Bluecat não apresentaram a mesma taxa de aumento de temperatura deflagrada nas projeções nos dados dos GCMs desagregados espacialmente;
- Para o cenário mais otimista (SSP1-2.6), observou-se que a taxa de aumento de temperatura até 2050 do modelo-D não é preservada, e que a temperatura média anual do modelo-D corrigido estabiliza já em 2030 em torno de 20,5 °C;
- Conforme apresentado nos resultados aplicados ao cenário mediano (SSP2-4.5) – subitem Resultados com sazonalidade – as tendências futuras de aumento de temperatura média mensal do modelo-D ficaram evidentes. No

entanto, devido ao fato de o modelo-D possuir médias mensais superiores aos dados observados obtidos por reanálise, a aplicação de correção de viés indicou estimativas pontuais mais baixas e uma taxa de aumento bem menor; e

- Em contrapartida aos demais cenários, o cenário mais crítico em termos de emissão e política de desenvolvimento sustentável – SSP5-8.5 – apresentou, além da média mensal maior no período histórico, uma diferença significativa em termos de tendência. De acordo com a própria referência técnica do NEX-GDDP-CMIP6, quantitativamente a tendência futura imposta pelos cenários de mudança linear em si pode não ser realista porque o sistema climático é de natureza não linear. Ainda, a própria referência técnica destaca que os usuários desse conjunto de dados devem estar cientes dessa limitação, especialmente ao usar cenários de GCMs;

Logo, conclui-se que os resultados do método Bluecat mostram que as projeções não conversam com as observações. Para os três cenários, as taxas de aumento de temperatura não foram tão significativas. Além da correção de viés das taxas de emissão, o Bluecat permitiu a correção das médias mensais de temperatura.

Após aplicar a correção do viés, verificou-se, ao final do período projetado (2100), uma diferença entre  $Q$  e  $W$  de aproximadamente 1 °C no cenário de menor emissão (SSP1-2.6); já para o cenário médio (SSP2-4.5) é de aproximadamente 1,5 °C; e o cenário de maior emissão apresenta uma diferença próxima de 5 °C.

Portanto, sobre a correção de viés dos modelos determinísticos pode-se concluir que:

- As simulações futuras e cenários críticos de chuva podem ser mais consistentes fisicamente desenvolvendo séries sintéticas com geradores estocásticos paramétricos ou não paramétricos (item 3.3.3), uma vez que não se tem indícios claros de variabilidade, além de as projeções dos modelos GCM não indicarem grandes tendências para a chuva, independente do cenário. Ressalta-se que para outras regiões do Brasil com sazonalidade de chuva menos significativa (e.g. região amazônica), a aplicação do método Bluecat pode ser mais efetiva devido ao alto índice de chuva em todos os meses do ano;

- A aplicação do método Bluecat para a temperatura pode ser considerada vantajosa, pelo fato de, além de correção de viés, o método Bluecat permite criar trajetórias sintéticas através das equações condicionais obtidas pelo método;
- Caso haja necessidade de se utilizar escalas diárias e subdiárias, uma desagregação temporal deverá ser aplicada, uma vez que, no âmbito desta dissertação, o método Bluecat foi aplicado para dados mensais.

Em contrapartida à aplicação de *ensembles* para estudos em que se exige projeções climáticas futuras, o método Bluecat fornece a distribuição empírica da distribuição condicional  $F_{(q|Q)}(q|Q)$ , ou seja, para um dado valor de  $Q$ , obtém-se uma FAP correspondente de  $F_{(q|Q)}(q|Q)$ , o que nos permite aplicar aos cenários futuros uma probabilidade do evento (e.g. 5%, 50%, 95% etc.). Destaca-se que as estimativas dos GCMs não têm relação probabilística, ou seja, os resultados da aplicação de *ensembles* não são associados a uma frequência de evento. Com o método *Bluecat*, essa necessidade é sanada pelas distribuições empíricas e correção de viés empregados.

Como sugestão de estudos futuros, seria interessante verificar a aplicação desse método empírico para dados subdiários e em locais com índice pluviométrico maior (sem meses secos), além de verificar a influência da tendência da temperatura corrigida sobre outras variáveis hidroclimáticas (e.g. evapotranspiração, Precipitação Máxima Provável etc.). Além das verificações sobre as variáveis hidroclimáticas, a influência do tamanho da amostra sobre os resultados, a abrangência da vizinhança  $m$  e a aplicação sobre projeções de GCMs específicos indicariam contribuição ao meio científico no âmbito da aplicação desse método.

## 7 REFERÊNCIAS

- ALVARES, C.A., STAPE, J.L., SENTELHAS, P.C., GONÇALVES, J.L.M.; SPAROVEK, G. **Köppen's climate classification map for Brazil. Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ANN ARBOR, MI. Briley, L., Dougherty, R., Wells, K., Hercula, T., Notaro, M., Rood, R., Andresen, J., Marsik, F., Prospero, A., Jorns, J., Channell, K., Hutchinson, S., Kemp, C., and O. Gates. **A Practitioner's Guide to Climate Model Scenarios**. Great Lakes Integrated Sciences and Assessments (GLISA), 2021.
- AWOTWI, A.; KUMI, M.; JANSSON, Pe.; YEBOAH, F.; NTI, Ik.. Predicting Hydrological Response to Climate Change in the White Volta Catchment, West Africa. *Journal Of Earth Science & Climatic Change*, [S.L.], v. 06, n. 01, 2015. OMICS Publishing Group. <http://dx.doi.org/10.4172/2157-7617.1000249>.
- BARRY, R. G.; CHORLEY, R. J.. **Atmosfera, tempo e clima**. [S.L.]: Bookman, 2013.
- BECKER, R. A.; CHAMBERS, J. M; WILKS, A. R.. **The New S Language**. [S. L.]: Wadsworth & Brooks/Cole, 1988.
- BERG, Alexis; FINDELL, Kirsten; LINTNER, Benjamin; GIANNINI, Alessandra; SENEVIRATNE, Sonia I.; HURK, Bart van Den; LORENZ, Ruth; PITMAN, Andy; HAGEMANN, Stefan; MEIER, Arndt. Land–atmosphere feedbacks amplify aridity increase over land under global warming. **Nature Climate Change**, [S.L.], v. 6, n. 9, p. 869-874, 16 maio 2016. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/nclimate3029>.
- BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C.; LJUNG, Greta M.. **Time Series Analysis: forecasting and control**. 5. ed. New Jersey: Wiley, 2016. ISBN 978-1-118-67502-1.
- BRASIL. AGÊNCIA NACIONAL DE MINERAÇÃO. Produção Bruta de Minério. Disponível em: <https://app.powerbi.com/view?r=eyJrljoiZTRkNjl3MWEtMGI3My00ZTgzLWlyN2YtMzNjNDhjNTViM2Q2liwidCI6ImEzMDgzZTIxLTc0OWItNDUzNC05YWZhLTU0Y2MzMT>

g4OTdiOCJ9&pageName=ReportSection99c5eaca1c0e9e21725a.Acesso em: 11 out. 2023a.

BRASIL. Instituto Nacional de Meteorologia. Inmet. **NORMAIS CLIMATOLÓGICAS DO BRASIL**. Disponível em: <https://portal.inmet.gov.br/normais>. Acesso em: 30 out. 2023.

BRASIL. MINISTÉRIO DA CIÊNCIA TECNOLOGIA E INOVAÇÃO. **Modelagem Climática e Vulnerabilidades Setoriais à Mudança do Clima no Brasil**. Brasília: Ministério da Ciência, Tecnologia e Inovação, 2016. 590 p.

CAO, Long; BALA, Govindasamy; CALDEIRA, Ken. Climate response to changes in atmospheric carbon dioxide and solar irradiance on the time scale of days to weeks. **Environmental Research Letters**, [S.L.], v. 7, n. 3, p. 1-7, 24 ago. 2012. IOP Publishing. <http://dx.doi.org/10.1088/1748-9326/7/3/034015>.

CANNON, Alex J.; SOBIE, Stephen R.; MURDOCK, Trevor Q.. **Bias Correction of GCM Precipitation by Quantile Mapping: how well do methods preserve changes in quantiles and extremes?**. *Journal Of Climate*, [S.L.], v. 28, n. 17, p. 6938-6959, 1 set. 2015. American Meteorological Society. <http://dx.doi.org/10.1175/jcli-d-14-00754.1>.

CHOKKAVARAPU, Nagaveni; MANDLA, Venkata Ravibabu. Comparative study of GCMs, RCMs, downscaling and hydrological models: a review toward future climate change impact estimation. *Sn Applied Sciences*, [S.L.], v. 1, n. 12, p. 1-15, 27 nov. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s42452-019-1764-x>.

CLERIDOU, N.; BENAS, N.; MATSOUKAS, C.; CROKE, B.; VARDAVAS, I.. Water resources of Cyprus under changing climatic conditions: modelling approach, validation and limitations. *Environmental Modelling & Software*, [S.L.], v. 60, n. 1, p. 202-218, out. 2014.

CLEVELAND, William S.. **LOWESS: a program for smoothing scatterplots by robust locally weighted regression**. *The American Statistician*, [S.L.], v. 35, n. 1, p. 54, fev. 1981. JSTOR. <http://dx.doi.org/10.2307/2683591>.

CLEVELAND, William S.. **Robust Locally Weighted Regression and Smoothing Scatterplots**. Journal Of The American Statistical Association, [S.L.], v. 74, n. 368, p. 829-836, dez. 1979. Informa UK Limited.

<http://dx.doi.org/10.1080/01621459.1979.10481038>.

DAGAN, Guy; STIER, Philip; WATSON-PARRIS, Duncan. Analysis of the Atmospheric Water Budget for Elucidating the Spatial Scale of Precipitation Changes Under Climate Change. **Geophysical Research Letters**, [S.L.], v. 46, n. 17-18, p. 10504-10511, set. 2019. American Geophysical Union (AGU).

<http://dx.doi.org/10.1029/2019gl084173>.

DAGAN, Guy; STIER, Philip. Constraint on precipitation response to climate change by combination of atmospheric energy and water budgets. **Npj Climate And Atmospheric Science**, [S.L.], v. 3, n. 1, p. 10.504-10.511, 3 set. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41612-020-00137-8>.

DOUVILLE, Hervé; RAGHAVAN, Krishnan; RENWICK, James (org.). Water Cycle Changes. In: VALÉRIE MASSON-DELMOTTE (United Kingdom And New York). Intergovernmental Panel On Climate Change (ed.). *Climate Change 2021: the physical science basis*. Cambridge: Cambridge University Press, 2021. p. 1055-1210. doi:10.1017/9781009157896.

DONG, Buwen; SUTTON, Rowan T.; HIGHWOOD, Ellie; WILCOX, Laura. The Impacts of European and Asian Anthropogenic Sulfur Dioxide Emissions on Sahel Rainfall. **Journal Of Climate**, [S.L.], v. 27, n. 18, p. 7000-7017, 10 set. 2014. American Meteorological Society. <http://dx.doi.org/10.1175/jcli-d-13-00769.1>.

EDEN, Jonathan M.; WIDMANN, Martin; GRAWE, David; RAST, Sebastian. Skill, Correction, and Downscaling of GCM-Simulated Precipitation. **Journal Of Climate**, [S.L.], v. 25, n. 11, p. 3970-3984, jun. 2012. American Meteorological Society. <http://dx.doi.org/10.1175/jcli-d-11-00254.1>.

ENGEL, Max. **Paleoclimate Relevance to Global Warming**. Reference Module In Earth Systems And Environmental Sciences, [S.L.], p. 1-15, 2018. Elsevier. <http://dx.doi.org/10.1016/b978-0-12-409548-9.11264-3>.

HASSLER, Uwe. **Stochastic Processes and Calculus**: an elementary introduction with applications. Switzerland: Springer, 2016. ISBN 978-3-319-23428-1 (eBook)

HAUSFATHER, Zeke; MARVEL, Kate; SCHMIDT, Gavin A.; NIELSEN-GAMMON, John W.; ZELINKA, Mark. Climate simulations: recognize the 'hot model' problem. *Nature*, [S.L.], v. 605, n. 7908, p. 26-29, 4 maio 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/d41586-022-01192-2>.

HESS, Philipp; LANGE, Stefan; SCHÖTZ, Christof; BOERS, Niklas. Deep Learning for Bias-Correcting CMIP6-Class Earth System Models. **Earth'S Future**, [S.L.], v. 11, n. 10, p. 1-17, out. 2023. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2023ef004002>.

HERSBACH H, BELL B, BERRISFORD P, HIRAHARA S, HORÁNYI A, Muñoz-Sabater J. et al. 2020. The ERA5 Global Reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146:1999-2049. doi: 10.1002/qj.3803.

HIRSCH, R. M.; HELSEL, D. R.; COHN, T. A.; GILROY, E. J.. **Statistical Treatment of Hydrologic Data**. In: MAIDMENT, David R.. *Handbook of Hydrologic*. [S. L.]: McGraw-Hill, 1992. p. 17-1.

HOVENDEN, Mark J.; NEWTON, Paul C. D.; WILLS, Karen E.. Seasonal not annual rainfall determines grassland biomass response to carbon dioxide. **Nature**, [S.L.], v. 511, n. 7511, p. 583-586, 28 maio 2014. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/nature13281>.

ICMM, The International Council On Mining And Metals; (UNEP), United Nations Environment Programme; (PRI), Responsible Investment. **Global Industry Standard on Tailings Management (GISTM)**. 2020. Disponível em: <https://globaltailingsreview.org/global-industry-standard/>. Acesso em: 11 out. 2023.

Intergovernmental Panel on Climate Change (IPCC). *Climate Change 2001: impacts, adaptation, and vulnerability*. Cambridge: Cambridge University Press, 2001. 1042 p. Contribution of Working Group II to the Third Assessment Report of the Intergovernmental Panel on Climate Change.

Intergovernmental Panel on Climate Change (IPCC). 2007. **Climate Change 2007: The Physical Science Basis**. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 996 pp.

IPCC, 2013: **Climate Change 2013: The Physical Science Basis**. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 pp.

IPCC, 2014: **Summary for policymakers. em: Climate Change 2014: Impacts, Adaptation, and Vulnerability**. Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Field, C.B., V.R. Barros, D.J. Dokken, K.J. Mach, M.D. Mastrandrea, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp. 1-32.

IPCC, 2021: **Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change** [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2391 pp. doi:10.1017/9781009157896.

IPCC, 2022: **Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change** [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Lösche, V. Möller, A. Okem, B. Rama (eds.)]. Cambridge University Press. Cambridge University Press, Cambridge, UK and New York, NY, USA, 3056 pp., doi: 10.1017/9781009325844.

JAKOB, C.; SINGH, M. S.; JUNGANDREAS, L.. Radiative Convective Equilibrium and Organized Convection: an observational perspective. **Journal Of Geophysical Research: Atmospheres**, [S.L.], v. 124, n. 10, p. 5418-5430, 27 maio 2019. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2018jd030092>.

KHINTCHINE, A., 1934. **Korrelationstheorie der stationären stochastischen Prozesse**. *Mathematische Annalen*, 109 (1), 604–615.

KING, Leanna M.; MCLEOD, A. Ian; SIMONOVIC, SLOBODAN P. **Improved Weather Generator Algorithm for Multisite Simulation of Precipitation and Temperature**. *Jawra Journal Of The American Water Resources Association*, [S.L.], v. 51, n. 5, p. 1305-1320, 10 jun. 2015. Wiley. <http://dx.doi.org/10.1111/1752-1688.12307>.

KOLMOGOROV, A.N., 1931. **Über die analytischen Methoden in der Wahrscheinlichkeitsrechnung**. *Math. Ann.*, 104, 415-458. (English translation: On analytical methods in probability theory, In: Kolmogorov, A.N., *Selected Works of A. N. Kolmogorov - Volume 2, Probability Theory and Mathematical Statistics*, ed. by A.N. Shiriyayev, Kluwer, Dordrecht, The Netherlands, 62-108, 1992).

KOLMOGOROV, A.N., 1938. **A simplified proof of the Birkhoff-Khinchin ergodic theorem**. *Uspekhi Mat. Nauk*, 5, 52-56. (English edition: Kolmogorov, A.N., 1991, *Selected Works of A. N. Kolmogorov - Volume 1, Mathematics and Mechanics*, ed. by Tikhomirov, V.M., Kluwer, Dordrecht, The Netherlands, 271-276).

KOUTSOYIANNIS D, MONTANARI A. **Climate Extrapolations in Hydrology: The Expanded Bluecat Methodology**. *Hydrology*. 2022; 9(5):86. <https://doi.org/10.3390/hydrology9050086>.

KOUTSOYIANNIS, D.; MONTANARI, A.. **Bluecat: a local uncertainty estimator for deterministic simulations and predictions**. *Water Resources Research*, [S.L.], v. 58, n. 1, p. 1-20, jan. 2021. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2021wr031215>.

KOUTSOYIANNIS, Demetris. **Stochastics of Hydroclimatic Extremes: a cool look at risk**. Athens: Kallipos, 2021. ISBN: 978-618-85370-0-2.

KUSCH, Erik; DAVY, Richard. **KrigR—a tool for downloading and statistically downscaling climate reanalysis data**. Environmental Research Letters, [S.L.], v. 17, n. 2, p. 024005, 21 jan. 2022. IOP Publishing. <http://dx.doi.org/10.1088/1748-9326/ac48b3>.

MARAUN, Douglas. **Bias Correcting Climate Change Simulations - a Critical Review**. Current Climate Change Reports, [S.L.], v. 2, n. 4, p. 211-220, 10 out. 2016. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s40641-016-0050-x>.

MILLY, P. C. D.; BETANCOURT, Julio; FALKENMARK, Malin; HIRSCH, Robert M.; KUNDZEWICZ, Zbigniew W.; LETTENMAIER, Dennis P.; STOUFFER, Ronald J.. **Stationarity Is Dead: whither water management?**. Science, [S.I.], v. 319, p. 573-574, 1 fev. 2008.

MONTANARI, Alberto; KOUTSOYIANNIS, Demetris. **A blueprint for process-based modeling of uncertain hydrological systems**. Water Resources Research, [S.L.], v. 48, n. 9, p. 15, set. 2012. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2011wr011412>.

MONTANARI, Alberto; KOUTSOYIANNIS, Demetris. **Modeling and mitigating natural hazards: stationarity is immortal!**. Water Resources Research, [S.L.], v. 50, n. 12, p. 9748-9756, dez. 2014. American Geophysical Union (AGU). <http://dx.doi.org/10.1002/2014wr016092>.

NAGHETTINI, Mauro; PINTO, Éber José de Andrade. Hidrologia Estatística. Belo Horizonte: CPRM, 2007. 552 p.

NASA, Rama Nemani /. **NASA Earth Exchange Global Daily Downscaled Projections - CMIP6**. [S.L.], p. 1-17, ago. 2023. NASA Center for Climate Simulation. <http://dx.doi.org/10.7917/OFSG3345>.

O'Neil B.C., Kriegler E., Riahi K., Ebi K.L., Hallegatte S., et al. (2014). **A new scenario framework for climate change research: the concept of shared socioeconomic pathways**. Climatic Change, 122: 387-400. doi: 10.1007/s10584-013-0905-2.

O'NEILL, Brian C. et al. **The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6**. Geoscientific Model Development, [S.L.], v. 9, n. 9, p. 3461-3482, 28 set. 2016. Copernicus GmbH. <http://dx.doi.org/10.5194/gmd-9-3461-2016>. Disponível em: [www.geosci-model-dev.net/9/3461/2016/](http://www.geosci-model-dev.net/9/3461/2016/). Acesso em: 31 jan. 2023.

PIANI, C.; WEEDON, G.P.; BEST, M.; GOMES, S.M.; VITERBO, P.; HAGEMANN, S.; HAERTER, J.O.. **Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models**. Journal Of Hydrology, [S.L.], v. 395, n. 3-4, p. 199-215, dez. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2010.10.024>.

PINTO, Nelson L. de Souza; HOLTZ, Antônio Carlos Tatit; MARTINS, José Augusto; GOMIDE, Francisco Luiz Sibut. **Hidrologia Básica**. São Paulo: Blucher, 1976.

QI, S.; SUN, G.; WANG, Y.; MCNULTY, S. G.; MYERS, J. A. Moore. Streamflow Response to Climate and Landuse Changes in a Coastal Watershed in North Carolina. Transactions Of The Asabe, [S.L.], v. 52, n. 3, p. 739-749, 2009. American Society of Agricultural and Biological Engineers (ASABE). <http://dx.doi.org/10.13031/2013.27395>.

RAVURI, S., Lenc, K., WILLSON, M., KANGIN, D., LAM, R., MIROWSKI, P., *et al.* (2021). **Skilful precipitation nowcasting using deep generative models of radar**. Nature, 597(7878), 672–677. <https://doi.org/10.1038/s41586-021-03854-z>.

SALAS, J. D.. **Analysis and Modeling of Hydrologic Time Series**. In: MAIDMENT, David R.. HANDBOOK OF HYDROLOGIC. [S. L.]: McGraw-Hill, 1993. p. 19-1.

SALAS, J. D.; DELLEUR, J. W.; YEVJEVICH, V.; LANE, W. L.. **Applied modeling of hydrologic time series**. Michigan: Water Resources Publications, 1980. 484 p. ISBN-0-918334-37-3.

SHERWOOD, Steven C.; BONY, Sandrine; BOUCHER, Olivier; BRETHERTON, Chris; FORSTER, Piers M.; GREGORY, Jonathan M.; STEVENS, Bjorn. Adjustments in the Forcing-Feedback Framework for Understanding Climate Change. **Bulletin Of**

**The American Meteorological Society**, [S.L.], v. 96, n. 2, p. 217-228, 1 fev. 2015. American Meteorological Society. <http://dx.doi.org/10.1175/bams-d-13-00167.1>.

SILVA, Talita F. G., NASCIMENTO, Nilo O., MOURA, Priscilla M., COSTA Veber A. F., RODRIGUES, André F. Projeto de Pesquisa Financiado pelo CNPq: Urbanização e mudanças climáticas: avaliação de impactos e estratégias de adaptação para bacias e reservatórios urbanos. 2022.

SKINNER, Christopher B.; POULSEN, Christopher J.. The role of fall season tropical plumes in enhancing Saharan rainfall during the African Humid Period. **Geophysical Research Letters**, [S.L.], v. 43, n. 1, p. 349-358, 7 jan. 2016. American Geophysical Union (AGU). <http://dx.doi.org/10.1002/2015gl066318>.

TAYLOR, Karl E.; STOUFFER, Ronald J.; MEEHL, Gerald A.. **An Overview of CMIP5 and the Experiment Design**. Bulletin Of The American Meteorological Society, [S.L.], v. 93, n. 4, p. 485-498, 1 abr. 2012. American Meteorological Society. <http://dx.doi.org/10.1175/bams-d-11-00094.1>.

THIESSEN, Alfred H.. DISTRICT No. 10, GR'EAT BASIN. Monthly Weather Review: CLIMATOLOGICAL DATA FOR JULY, 1911. [S.I.], p. 1082-1084. Julho, 1911.

THRASHER, B., MAURER, E. P., MCKELLAR, C., DUFFY, P. B., 2012: **Technical Note: Bias correcting climate model simulated daily temperature extremes with quantile mapping**. Hydrology and Earth System Sciences, 16 (9), 3309-3314, <https://doi.org/10.5194/hess-16-3309-2012>.

THRASHER, B., WANG, W., MICHAELIS, A. *et al.* **NASA Global Daily Downscaled Projections**, CMIP6. Sci Data 9, 262 (2022). <https://doi.org/10.1038/s41597-022-01393-4>.

TUCCI, Carlos Eduardo Morelli; BRAGA, Benedito (org.). **Clima e Recursos Hídricos no Brasil**. Porto Alegre: ABRH, 2003. 348 p. ISBN 978-85-88686-11-3.

UNITED STATES OF AMERICA. National Aeronautics and Space Administration (NASA). **NASA Earth Exchange Global Daily Downscaled Projections (NEX-**

**GDDP**). Disponível em: <https://www.nccs.nasa.gov/services/data-collections/land-based-products/nex-gddp>. Acesso em: 01 set. 2023.

VAN VUUREN, DP, EDMONDS J and KAINUMA M et al. 2011. **The Representative Concentration Pathways: An Overview**. Climatic Change 109: 531. doi: 10.1007/s10584 011 0148 z.

XU, Yuanchao. hyfo: Hydrology and Climate Forecasting R Package for Data Analysis and Visualization. Disponível em: <http://yuanchao-xu.github.io/hyfo/>. Acesso em: 08/10/2023.

XU, Zhongfeng; HAN, Ying; TAM, Chi-Yung; YANG, Zong-Liang; FU, Congbin. Bias-corrected CMIP6 global dataset for dynamical downscaling of the historical and future climate (1979–2100). Scientific Data, [S.L.], v. 8, n. 1, p. 1-11, 4 nov. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41597-021-01079-3>.

WANG, F., TIAN, D. (2022). **On deep learning-based bias correction and downscaling of multiple climate models simulations**. Climate Dynamics, 59(11–12), 3451–3468. <https://doi.org/10.1007/s00382-022-06277-2>.

WILBY, Robert L.; HAY, Lauren E.; GUTOWSKI, William J.; ARRITT, Raymond W.; TAKLE, Eugene S.; PAN, Zaitao; LEAVESLEY, George H.; CLARK, Martyn P.. Hydrological responses to dynamically and statistically downscaled climate model output. Geophysical Research Letters, [S.L.], v. 27, n. 8, p. 1199-1202, 15 abr. 2000. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/1999gl006078>.

WMO. World Meteorological Organization. **International meteorological vocabulary**. Geneva: WMO/IOMM/BMO, 1992. 802 p. (No.182). ISBN 92-63-02182-1.

WOOD, A.W., E.P. Maurer, A. Kumar, and D.P. Lettenmaier, 2002: **Long-range experimental hydrologic forecasting for the eastern United States**. J. Geophysical Research-Atmospheres, 107, 4429, <https://doi.org/10.1029/2001JD000659>.