

UNIVERSIDADE FEDERAL DE PELOTAS
Instituto de Física e Matemática
Programa de Pós-Graduação em Modelagem Matemática



Dissertação de Mestrado

**APLICAÇÃO DA MODELAGEM MATEMÁTICA NO COMPORTAMENTO DA
TENDÊNCIA DA PRECIPITAÇÃO NA GUINÉ-BISSAU**

Danildo José Nhaga

Pelotas, 2026

Danildo José Nhaga

**APLICAÇÃO DA MODELAGEM MATEMÁTICA NO COMPORTAMENTO DA
TENDÊNCIA DA PRECIPITAÇÃO NA GUINÉ-BISSAU**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Modelagem Matemática do Instituto de Física e Matemática da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Modelagem Matemática.

Orientador: Prof. Dr. Douglas da Silva Lindemann
Coorientador: Profa. Dra. Daniela Buske

Pelotas, 2026

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação da Publicação

N111a Nhaga, Danilo José

Aplicação da modelagem matemática no comportamento da
tendência da precipitação na Guiné-Bissau [recurso eletrônico] / Danilo
José Nhaga ; Douglas da Silva Lindemann, orientador ; Daniela Buske,
coorientadora. — Pelotas, 2026.
227 f.

Dissertação (Mestrado) — Programa de Pós-Graduação em
Modelagem Matemática, Instituto de Física e Matemática, Universidade
Federal de Pelotas, 2026.

1. Catió. 2. Polinômio de terceira ordem. 3. Modelagem matemática.
4. Período chuvoso. I. Lindemann, Douglas da Silva, orient. II. Buske,
Daniela, coorient. III. Título.

CDD 511.8096657

Danildo José Nhaga

**APLICAÇÃO DA MODELAGEM MATEMÁTICA NO COMPORTAMENTO DA
TENDÊNCIA DA PRECIPITAÇÃO NA GUINÉ-BISSAU**

Dissertação de Mestrado aprovada, como requisito parcial, para obtenção do grau de Mestre em Modelagem Matemática, Programa de Pós-Graduação em Modelagem Matemática, Instituto de Física e Matemática, Universidade Federal de Pelotas.

Data da Defesa: 25 de fevereiro de 2026

Banca Examinadora:

Prof. Dr. Douglas da Silva Lindemann (Orientador)

Doutor em Meteorologia Aplicada pela Universidade Federal de Viçosa

Profa. Dra. Daniela Buske (Coorientador)

Doutora em Engenharia Mecânica pelo Universidade Federal do Rio Grande do Sul

Dr. Mateus Dias Nunes

Doutor em Meteorologia pela Instituto Nacional de Pesquisas Espaciais

Prof. Dr. Jackson Martins Rodrigues

Doutor em Mathematics and Natural Sciences pela Universidade de Goettigen –
Alemanha

Prof. Dr. Régis Sperotto de Quadros

Doutor em Matemática Aplicada pela Technische Universität Darmstadt.

Dedico este trabalho, com profundo amor e gratidão, à memória dos meus pais, José Nhaga e Paulina António Quadé, cuja presença permanece viva em meus valores, em meus sonhos e em cada conquista da minha vida.

À minha família, especialmente aos meus primos-irmãos Silvino Queni e Catarina Sami, e à minha namorada, Eugênia André Martins da Silva, pelo amor, apoio e incentivo incondicionais durante toda esta caminhada.

AGRADECIMENTOS

"Tudo posso naquele que me fortalece."(Filipenses 4:13);

A trajetória acadêmica é, antes de tudo, um caminho de fé, persistência e amor, e seria impossível percorrê-lo sozinho.

A realização deste trabalho é fruto de muitos abraços estendidos, palavras ditas no tempo certo e silêncios acolhedores.

Principalmente, agradeço a Deus e aos meus ancestrais, por ter me concedido forças nos momentos de fraqueza, luz nos períodos de dúvidas e paz nos dias mais turbulentos, saúde e perseverança para seguir até aqui. Sem Eles, nada disso seria possível.

À minha família, especialmente às memórias dos meus pais José Nhaga e Paulina Antônio Quadé, minha eterna gratidão e aos meus primos-irmãos que hoje são os meus encarregados de educação Silvino Queni e Catarina Carlos Sami, e também as Lucia J. Nhaga, Celeste J. Nhaga, N'duba J. Nhaga, Carina J. Nhaga, Romana J. Nhaga, Libania J. Nhaga, José Nhaga Júnior, Nuria J. Nhaga, minha prima Jaklin Indequê e o meu querido sobrinho Gerson Sanca. Obrigado por serem porto seguro e fonte de amor incondicional. Por acreditarem em mim mesmo quando meus olhos hesitaram. Cada gesto, cada oração, cada silêncio compreensivo ajudou a edificar esta conquista. O apoio incondicional e pelos valores que me ensinaram e que sustentam minha caminhada.

À minha namorada Eugenia André Martins da Silva, meu amor e minha companheira de jornada: obrigado por caminhar ao meu lado com ternura, paciência, compreensão, carinho e fé. Pela tua presença doce nos dias cansativos, pelas palavras que me reergueram e pela tua alegria que me inspirou a continuar mesmo quando tudo parecia estagnado. Você é a parte essencial desta vitória.

Ao meu magnífico orientador Professor Doutor Douglas da Silva Lindemann e a coorientadora Professora Doutora Daniela Buske, e junto do meu Professor Doutor Regis S. de Quadros, agradeço pela dedicação, orientação firme, precisa e generosa, pela escuta atenta e incentivo constante e por acreditar na qualidade deste trabalho. Sua dedicação e confiança no processo de contribuições foram fundamental para o meu crescimento acadêmico e pessoal.

Aos meus colegas do grupo de pesquisa de Interação Oceano-Atmosfera e Climatologia (GOAC), meu reconhecimento e apreço. Especialmente na pessoa de Raquel M. Machado e Juan P. G. Escalante, o caminho foi exigente, mas também cheio de trocas ricas, companheirismo e aprendizado mútuo. Cada desafio vencido em conjunto reforçou em mim a importância da colaboração e da empatia.

Aos meus amigos Karol Maria Oringa Simões, Mikail Vitória Oringa Simões, Momente Basílio Lima, Romilson Albat Gomes Cabi, Manfinanpul Armando Blez, Nel-

son Nghalé, Sabino Tobana Intanquê, Felisberto Júnior Pedro Bacurim, Aua Sila, que mesmo à distância ou no dia a dia, acompanharam essa jornada com apoio sincero, sempre torceram por mim, oferecendo, conselhos boas e risadas, cafés partilhados nos momentos certos e simples palavras de encorajamento: vocês foram o alívio em muitos dias difíceis.

Por fim, a todos aqueles que, direta ou indiretamente, contribuíram para a concretização deste trabalho, o meu mais profundo agradecimento. Que esta conquista não seja apenas minha, mas um reflexo de todas as mãos e corações que nela habitaram.

Só sei que nada sei.

— SÓCRATES

O reconhecimento da própria ignorância não é fraqueza, mas o princípio da verdadeira sabedoria. É na dúvida que floresce a busca que reside o saber.

RESUMO

JOSÉ NHAGA, Danildo. **APLICAÇÃO DA MODELAGEM MATEMÁTICA NO COMPORTAMENTO DA TENDÊNCIA DA PRECIPITAÇÃO NA GUINÉ-BISSAU.** Orientador: Douglas da Silva Lindemann. 2026. 227 f. Dissertação (Mestrado em Modelagem Matemática) – Instituto de Física e Matemática, Universidade Federal de Pelotas, Pelotas, 2026.

O presente trabalho detalha sobre a precipitação na Guiné-Bissau, o país que fica situado na costa Ocidental da África. Este estudo tem como objetivo geral analisar o comportamento espaço-temporal da precipitação na Guiné-Bissau nas últimas décadas e avaliar o desempenho de dados oriundos de modelagem numérica através do uso de técnicas de modelagem para o período de 1990 a 2022. Foram utilizados dados observados de estações meteorológicas do Instituto Nacional de Meteorologia da Guiné-Bissau, bem como três conjuntos de reanálises que são MSWEP v2, ERA5 e ERA5-LAND em teste estatístico de fator de dois. Os resultados indicam que a estação meteorológica de Catió apresenta os maiores valores de precipitação durante o período de junho a outubro. Além disso, a aplicação do modelo de um polinômio de terceira ordem se demonstrou adequado para identificar os meses mais chuvosos: julho, agosto e setembro. A partir do cálculo da tendência das séries temporais, evidencia-se que as estações da regiões litorâneas, apresentam os maiores volumes de precipitação para todo país. A modelagem e os testes estatísticos indicam que as reanálises conseguem representar de modo geral um bom desempenho os dados observados, apresentam boa capacidade de reproduzir a variabilidade temporal e a sazonalidade da precipitação, com correlações elevadas em relação aos dados observados, O MSWEP V2 apresentou o melhor desempenho global, com maiores valores de correlação e R^2 , e também a inclinações mais próximas da unidade. A reanálise ERA5 apresentou o segundo melhor desempenho e capturou bem a variabilidade temporal, mas com tendência à subestimação e menor aderência aos extremos. ERA5-LAND mostrou desempenho inferior, com menor valores do R^2 , e maiores limitações na representação da magnitude dos eventos intensos. Assim com as projeções até 2030 indica a manutenção de valores elevados das máximas anuais de precipitação em todas as estações e nas áreas costeiras projeta-se persistência de extremos elevados, com tendência à estabilização. Em geral, os resultados mantêm coerência com os padrões estatísticos observados.

Palavras-chave: Catió; polinômio de terceira ordem; modelagem matemática; período chuvoso.

ABSTRACT

JOSÉ NHAGA, Danilo. **APPLICATION OF MATHEMATICAL MODELING IN GUINEA-BISSAU PRECIPITATION BEHAVIOR FOR PAST AND FUTURE SCENARIOS**. Advisor: Douglas da Silva Lindemann. 2026. 227 f. Dissertation (Masters in Mathematical Modeling) – Institute of Physics and Mathematics, Federal University of Pelotas, Pelotas, 2026.

The present study provides a detailed analysis of precipitation in Guinea-Bissau, a country located on the west coast of Africa. The main objective is to analyze the spatiotemporal behavior of precipitation in Guinea-Bissau over recent decades and to evaluate the performance of data derived from numerical modeling through the use of modeling techniques for the period from 1990 to 2022. Observed data from the meteorological station of the National Institute of Meteorology of Guinea-Bissau were used, along with three reanalysis datasets MSWEP v2, ERA5, and ERA5-LAND applied in a statistical factor-of-two test. The results indicate that the Catió meteorological station presents the highest precipitation values during the period from June to October. In addition, the application of a third-order polynomial model proved adequate for identifying the rainiest months: July, August, and September. The calculation of temporal trends in the time series shows that stations in coastal regions record the highest precipitation volumes across the country. Modeling and statistical tests indicate that the reanalyses generally demonstrate good performance in representing observed data, showing a strong ability to reproduce temporal variability and precipitation seasonality, with high correlations relative to observations. MSWEP v2 presented the best overall performance, with higher correlation and R^2 values, as well as slopes closer to unity. ERA5 showed the second-best performance and captured temporal variability well, but with a tendency toward underestimation and lower adherence to extreme events. ERA5-LAND exhibited lower performance, with smaller R^2 values and greater limitations in representing the magnitude of intense events. Projections up to 2030 indicate the maintenance of high values of annual maximum precipitation at all stations, and in coastal areas the persistence of high extremes is projected, with a tendency toward stabilization. Overall, the results remain consistent with the observed statistical patterns.

Keywords: Catió; third order polynomial; mathematical modeling; rainy season.

LISTA DE FIGURAS

Figura 1	Comportamento da monção africana (regiões em verde), as setas pretas indicam o sentido predominante dos ventos, a figura da esquerda representa o período de verão e da direita o inverno . Fonte: https://www.clivar.org/african-monsoon	25
Figura 2	Subdivisão das regiões de acordo com o regime pluviométrico. Fonte: (Tanimoune et al., 2024).	26
Figura 3	Acumulado anual de 2020 (mm) para Guiné-Bissau (A), Anomalia da precipitação de 2020 em relação ao período climatológico de 1981-2020 (B). Fonte: (Mendes; Fragoso, 2023).	27
Figura 4	Localização da região de estudo e das estações meteorológicas existentes. Fonte: dos autores (2025).	33
Figura 5	Comparação entre os ajustes polinomiais de grau 2, grau 3 e grau 4 aplicados às máximas anuais de precipitação nas diferentes estações meteorológicas analisadas.	50
Figura 6	Séries temporais mensais dos acumulados de precipitação (mm) observados para os meses de maio a novembro para as estações apresentadas na Tabela 1: a) maio; b) junho; c) julho; d) agosto; e) setembro; f) outubro; e g) novembro. Fonte: dos autores (2025). . .	57
Figura 7	Boxplot de séries mensais ao longo do anual dos acumulados de precipitação (mm), para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).	66
Figura 8	Boxplot séries mensais ao longo do anual dos acumulados de precipitação (mm), para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá e)Suzana. Fonte: dos autores (2025).	67
Figura 9	Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).	80
Figura 10	Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)	81
Figura 11	Distribuição mensal da precipitação na estação de Bafatá para os meses de maio a novembro.	100
Figura 12	Série temporal de distribuição mensal dos extremos da precipitação na estação de Bafatá para os meses de maio a novembro.	101

Figura 13	Comparação mensal dos dados de reanálise MSWEP V2 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).	102
Figura 14	Comparação mensal dos dados de reanálise MSWEP V2 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)	103
Figura 15	Comparação mensal dos dados de reanálise ERA5 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).	116
Figura 16	Comparação mensal dos dados de reanálise ERA5 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)	117
Figura 17	Comparação mensal dos dados de reanálise ERA5-LAND sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bolama; d)Catió. Fonte: dos autores (2025).	130
Figura 18	Comparação mensal dos dados de reanálise ERA5-LAND sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)	131
Figura 19	Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).	142
Figura 20	Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)	143
Figura 21	Total anual da precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).	146
Figura 22	Total anual da precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)	147
Figura 23	Total anual de precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bolama; d)Catió. Fonte: dos autores (2025).	151
Figura 24	Total anual de precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)	152
Figura 25	Distribuição mensal da precipitação na estação de Bigene para os meses de maio a novembro.	171
Figura 26	Série temporal de distribuição mensal dos extremos da precipitação na estação de Bigene para os meses de maio a novembro.	172

Figura 27	Distribuição mensal da precipitação na estação de Bissau para os meses de maio a novembro.	173
Figura 28	Série temporal de distribuição mensal dos extremos da precipitação na estação de Bissau para os meses de maio a novembro.	174
Figura 29	Distribuição mensal da precipitação na estação de Bolama para os meses de maio a novembro.	175
Figura 30	Série temporal de distribuição mensal dos extremos da precipitação na estação de Bolama para os meses de maio a novembro.	176
Figura 31	Distribuição mensal da precipitação na estação de Bigene para os meses de maio a novembro.	177
Figura 32	Série temporal de distribuição mensal dos extremos da precipitação na estação de Catió para os meses de maio a novembro.	178
Figura 33	Distribuição mensal da precipitação na estação de Farim para os meses de maio a novembro.	179
Figura 34	Série temporal de distribuição mensal dos extremos da precipitação na estação de Farim para os meses de maio a novembro.	180
Figura 35	Distribuição mensal da precipitação na estação de Gabú para os meses de maio a novembro.	181
Figura 36	Série temporal de distribuição mensal dos extremos da precipitação na estação de Gabú para os meses de maio a novembro.	182
Figura 37	Distribuição mensal da precipitação na estação de Mansabá para os meses de maio a novembro.	183
Figura 38	Série temporal de distribuição mensal dos extremos da precipitação na estação de Mansabá para os meses de maio a novembro. . . .	184
Figura 39	Distribuição mensal da precipitação na estação de Suzana para os meses de maio a novembro.	185
Figura 40	Série temporal de distribuição mensal dos extremos da precipitação na estação de Suzana para os meses de maio a novembro.	186
Figura 41	Distribuição mensal da precipitação de ERA5 na estação de Bafatá para os meses de maio a novembro.	190
Figura 42	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bafatá para os meses de maio a novembro.	191
Figura 43	Distribuição mensal da precipitação de ERA5 na estação de Bigene para os meses de maio a novembro.	192
Figura 44	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bigene para os meses de maio a novembro.	193
Figura 45	Distribuição mensal da precipitação de ERA5 na estação de Bissau para os meses de maio a novembro.	194
Figura 46	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bissau para os meses de maio a novembro.	195
Figura 47	Distribuição mensal da precipitação de ERA5 na estação de Bolama para os meses de maio a novembro.	196
Figura 48	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bolama para os meses de maio a novembro.	197
Figura 49	Distribuição mensal da precipitação de ERA5 na estação de Catió para os meses de maio a novembro.	198
Figura 50	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Catió para os meses de maio a novembro.	199

Figura 51	Distribuição mensal da precipitação de ERA5 na estação de Farim para os meses de maio a novembro.	200
Figura 52	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Farim para os meses de maio a novembro.	201
Figura 53	Distribuição mensal da precipitação de ERA5 na estação de Gabú para os meses de maio a novembro.	202
Figura 54	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Gabú para os meses de maio a novembro.	203
Figura 55	Distribuição mensal da precipitação de ERA5 na estação de Mansabá para os meses de maio a novembro.	204
Figura 56	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Mansabá para os meses de maio a novembro.	205
Figura 57	Distribuição mensal da precipitação de ERA5 na estação de Suzana para os meses de maio a novembro.	206
Figura 58	Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Suzana para os meses de maio a novembro.	207
Figura 59	Distribuição mensal da precipitação de ERA5-LAND na estação de Bafatá para os meses de maio a novembro.	211
Figura 60	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Bafatá para os meses de maio a novembro.	212
Figura 61	Distribuição mensal da precipitação de ERA5-LAND na estação de Bigene para os meses de maio a novembro.	213
Figura 62	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Bigene para os meses de maio a novembro.	214
Figura 63	Distribuição mensal da precipitação de ERA5 na estação de Bissau para os meses de maio a novembro.	215
Figura 64	Distribuição mensal da precipitação de ERA5-LAND na estação de Bolama para os meses de maio a novembro.	216
Figura 65	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Bolama para os meses de maio a novembro.	217
Figura 66	Distribuição mensal da precipitação de ERA5-LAND na estação de Catió para os meses de maio a novembro.	218
Figura 67	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Catió para os meses de maio a novembro.	219
Figura 68	Distribuição mensal da precipitação de ERA5-LAND na estação de Farim para os meses de maio a novembro.	220
Figura 69	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Farim para os meses de maio a novembro.	221
Figura 70	Distribuição mensal da precipitação de ERA5-LAND na estação de Gabú para os meses de maio a novembro.	222

Figura 71	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Gabú para os meses de maio a novembro.	223
Figura 72	Distribuição mensal da precipitação de ERA5-LAND na estação de Mansabá para os meses de maio a novembro.	224
Figura 73	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Mansabá para os meses de maio a novembro.	225
Figura 74	Distribuição mensal da precipitação de ERA5-LAND na estação de Suzana para os meses de maio a novembro.	226
Figura 75	Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Suzana para os meses de maio a novembro.	227

LISTA DE TABELAS

Tabela 1	Coordenadas geográficas das estações Meteorológicas da Guiné-Bissau. Fonte: dos autores (2025).	32
Tabela 2	Métricas de desempenho dos modelos polinomiais	49
Tabela 3	Valores mínimos para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).	54
Tabela 4	Valores médios para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).	55
Tabela 5	Valores máximos para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).	58
Tabela 6	Valores de desvios padrões para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).	60
Tabela 7	Resultados da ANOVA de dois fator com interação	87
Tabela 8	Resumo comparativo do desempenho da reanálise em relação MSWEP V2 aos dados observados para as estações analisadas.	107
Tabela 9	Resumo comparativo dos indicadores estatísticos da relação entre precipitação observada e reanálise ERA5 nas estações analisadas.	119
Tabela 10	Resumo estatístico da relação entre precipitação observada e reanálise ERA5-LAND nas estações da séries temporais mensais.	135
Tabela 11	Métricas estatísticas mensais de MSWEP v2 para a estação de Bafatá.	168
Tabela 12	Métricas estatísticas mensais de MSWEP v2 para a estação de Bogene.	168
Tabela 13	Métricas estatísticas mensais de MSWEP v2 para a estação de Bissau.	169
Tabela 14	Métricas estatísticas mensais de MSWEP v2 para a estação de Bolama.	169
Tabela 15	Métricas estatísticas mensais de MSWEP v2 para a estação de Catió.	169
Tabela 16	Métricas estatísticas mensais de MSWEP v2 para a estação de Farim.	170
Tabela 17	Métricas estatísticas mensais de MSWEP v2 para a estação de Gabú.	170
Tabela 18	Métricas estatísticas mensais de MSWEP v2 para a estação de Mansabá.	170
Tabela 19	Métricas estatísticas mensais de MSWEP v2 para a estação de Suzana.	171

Tabela 20	Métricas estatísticas mensais de ERA5 para estação de Bafatá. . .	187
Tabela 21	Métricas estatísticas mensais de ERA5 para estação de Bigene. . .	187
Tabela 22	Métricas estatísticas mensais de ERA5 para estação de Bissau. . .	187
Tabela 23	Métricas estatísticas mensais de ERA5 para estação de Bolama. . .	188
Tabela 24	Métricas estatísticas mensais de ERA5 para estação de Catió. . . .	188
Tabela 25	Métricas estatísticas mensais de ERA5 para estação de Farim. . . .	188
Tabela 26	Métricas estatísticas mensais de ERA5 para estação de Gabú. . . .	189
Tabela 27	Métricas estatísticas mensais de ERA5 para estação de Mansabá. .	189
Tabela 28	Métricas estatísticas mensais de ERA5 para estação de Suzana. .	189
Tabela 29	Métricas estatísticas mensais do ERA5-LAND na estação de Bafatá.	207
Tabela 30	Métricas estatísticas mensais do ERA5-LAND na estação de Bigene.	208
Tabela 31	Métricas estatísticas mensais do ERA5-LAND na estação de Bissau.	208
Tabela 32	Métricas estatísticas mensais do ERA5-LAND na estação de Bolama.	208
Tabela 33	Métricas estatísticas mensais do ERA5-LAND na estação de Catió.	209
Tabela 34	Métricas estatísticas mensais do ERA5-LAND na estação de Farim.	209
Tabela 35	Métricas estatísticas mensais do ERA5-LAND na estação de Gabú.	209
Tabela 36	Métricas estatísticas mensais do ERA5-LAND na estação de Mansabá.	210
Tabela 37	Métricas estatísticas mensais do ERA5-LAND na estação de Suzana.	210

LISTA DE ABREVIATURAS E SIGLAS

MAO	Monção da África Ocidental
ZCIT	Zona de Convergência Intertropical
CMORPH	Climate Prediction Center Morphing Technique
CPC	Climate Prediction Center
NOAA	National Oceanic and Atmospheric Administration
TRMM	Tropical Rainfall Measuring Mission
ARC2	African Rainfall Climatology version 2
NCEP	National Centers for Environmental Prediction
GPCC	Global Precipitation Climatology Centre
CHIRPS	Climate Hazards Group InfraRed Precipitation with Station Data
CRU	Climatic Research Unit – University of East Anglia
CP4A	Convection-Permitting Climate Model for Africa
R25	Número de dias por ano com precipitação diária ≥ 25 mm
ETCCDI	Expert Team on Climate Change Detection and Indices
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
WCRP	World Climate Research Programme
CMIP	Coupled Model Intercomparison Project
SSP	Shared Socioeconomic Pathways
PIB	Produto Interno Bruto
MCGAs	Modelos Climáticos Globais Atmosféricos
MCGs	Modelos Climáticos Globais
MSWEP v2	Multi-Source Weighted-Ensemble Precipitation, version 2
INMGB	Instituto Nacional de Meteorologia da Guiné-Bissau
N	North (Norte)
W	West (Oeste)

SUMÁRIO

1	INTRODUÇÃO	21
2	REVISÃO BIBLIOGRÁFICA	24
2.1	O Clima da Guiné-Bissau e as Chuvas na Região	24
2.2	Modelos Climáticos	28
2.3	Modelagem Matemática	30
3	METODOLOGIA	32
3.1	Área de Estudo e Dados Observados	32
3.2	Reanálise	33
3.2.1	MSWEP V2	33
3.2.2	ERA5	34
3.2.3	ERA5-LAND	35
3.3	Métricas Estatísticas de Avaliação	37
3.3.1	Métricas Descritivas	37
3.3.2	Métricas de Desempenho	39
3.3.3	Testes Estatísticos	40
3.4	ANOVA de Dois Fatores	42
3.4.1	Análise de Variância (ANOVA) de Dois Fatores com Interação	43
3.5	Modelagem Matemática	45
3.5.1	Aproximações por Mínimos Quadrados Discretos: Ajuste por um Polinômio de grau n	45
3.5.2	Extrapolação até 2030	50
4	RESULTADOS	53
4.1	Estatística Descritiva da Precipitação da Guiné-Bissau	53
4.2	A Aplicação da Modelagem Matemática	60
4.2.1	Estação de Bafatá	60
4.2.2	Estação de Bigene	62
4.2.3	Estação de Bissau	63
4.2.4	Estação de Bolama	64
4.2.5	Estação de Catió	67
4.2.6	Estação de Farim	69
4.2.7	Estação de Gabú	70
4.2.8	Estação de Mansabá	72
4.2.9	Estação de Suzana	73
4.3	Curvas de Tendência e Extrapolação	75

4.4	Resultados da (ANOVA) Análise de Variância de Dois Fatores com Interação	87
4.4.1	Interpretação das Hipóteses Estatísticas e dos Pressupostos da ANOVA	88
4.5	Relação de Fator de Dois nas Comparações dos dados de Reanálises sobre Observados para as Estações	91
4.5.1	Reanálise MSWEP V2	91
4.5.2	Reanálise ERA5	108
4.5.3	Reanálise ERA5-LAND	123
4.6	Desempenho das Reanálises para Curvas de Tendência e Extrapolação	140
4.6.1	MSWEP V2	140
4.6.2	ERA5	144
4.6.3	ERA5-LAND	148
4.7	Discussão: Comparação do desempenho das reanálises MSWEP V2, ERA5 e ERA5-LAND	154
5	CONCLUSÃO	157
	REFERÊNCIAS	161
6	UM ANEXO	168
6.1	TABELA E GRÁFICOS DE REANÁLISE MSWEP V2	168
6.2	TABELA E GRÁFICOS DE REANÁLISE ERA5	187
6.3	TABELA E GRÁFICOS DE REANÁLISE ERA5-LAND	207

1 INTRODUÇÃO

O país Guiné-Bissau está localizado na região da África Ocidental, onde as condições de tempo e clima têm um grande impacto na produção agrícola, nos recursos hídricos e na saúde da população, assim como em outros setores econômicos, como a produção de energia, transportes e pesca, especialmente em Guiné-Bissau. O país faz parte do grupo dos países mais pobres e mais frágeis do mundo, e a sua economia baseia-se essencialmente na agricultura não mecanizada de sequeiro, na pesca, no comércio não formal e na ajuda externa (Fao, 2018).

A agricultura é o setor econômico dominante, contribuindo para 70% do PIB, para mais de 90% das exportações e empregando 84% da população ativa. Estes elementos revelam um contexto de forte dependência do setor. Cerca de 75% da população vive em zonas rurais e depende principalmente da agricultura para a sua subsistência. À semelhança de outros países da África Ocidental, o impacto da variabilidade climática manifesta-se pela redução da produção agrícola, pelo agravamento das crises alimentares e pelo aumento das importações (Mendes; Fragoso, 2023; Sylla et al., 2018).

A precipitação na Guiné-Bissau é um dos fatores que mais influenciam no rendimento da agricultura. Atualmente, o país apresenta dois períodos bastante distintos em relação à precipitação: um período chuvoso de maio até novembro e um período seco de dezembro a abril, com ventos dominantes do nordeste. O clima da Guiné-Bissau segundo a classificação climática de Köppen é do tipo Aw, com estação chuvosa no verão e estação seca no inverno. A zona costeira é caracterizada por precipitação média anual entre 1500 e 2500 mm e a parte continental com precipitação entre 1000 e 1500 mm. Os meses mais chuvosos ao longo do ano são os meses de julho, agosto e setembro (Sambú, 2003).

Os impactos das alterações climáticas são bastante visíveis em Guiné-Bissau. A maior irregularidade no início e no final da estação chuvosa, bem como em relação à variabilidade interanual da precipitação, são evidências que ressaltam a influência destes fenômenos nos países da África Ocidental (Mendes; Fragoso, 2023). Por exemplo, o ano de 2020 foi caracterizado como muito chuvoso em comparação com a média

climatológica de 1981-2020, com anomalias positivas em todo o país, apesar da chegada tardia da estação chuvosa, que geralmente ocorre em Maio (Mendes; Fragoso, 2023).

Julho, Agosto e Setembro de 2020 foram os meses mais chuvosos, registrando-se uma frequência acima da normal de dias com precipitação superior a 50 mm. Bissau, a capital, registou uma precipitação anual recorde e valores mensais superiores aos percentis 90 e 95 em julho e agosto, respectivamente. Esta forte chuva acompanhada de fortes ventos causou inundações em diversas áreas urbanas e agrícolas, e a destruição de estradas, casas e infraestruturas em diversas cidades do país (Mendes; Fragoso, 2023).

Por estar localizado na região Tropical, a climatologia da temperatura média mensal em Guiné-Bissau indica valores que oscilam de 25° C a 30° C ao longo do ano, sendo maio o mês mais quente (29° C) e janeiro o mais frio (25° C). Porém, cenários climáticos futuros sugerem aumento nas chuvas intensas em muitas regiões da África, essa condição causará uma exposição crescente da população à inundações pluviais, com previsão de aumento do deslocamento humano em aproximadamente 200% para um aquecimento de 1,6°C acima da média pré-industrial e até 600% para um aquecimento de 2,6°C. Estas variações extremas têm consequências graves para as populações e o desenvolvimento, e estão associadas a eventos climáticos, como inundações e secas extremas, que muitas vezes levam à perda de vidas, a danos nas infra-estruturas e a perturbações desastrosas na gestão da água e agricultura. Além dos eventos extremos, a variabilidade anual da precipitação é uma grande preocupação para a África Ocidental no que diz respeito ao calendário das atividades agrícolas (Diedhiou et al., 2018; IPCC, 2021).

Considerando que Guiné-Bissau possui um período chuvoso bem definido e como o país apresenta características agrícolas, que é altamente dependente das condições climáticas, se faz importante alguns questionamentos e hipóteses a serem consideradas: como o período chuvoso tem se comportado nas últimas décadas na Guiné-Bissau? Há tendências de aumento ou redução mensal das chuvas durante este período? Como os eventos de chuva têm se comportado, estão mais concentrados ou bem distribuídos ao longo do período chuvoso? E finalmente, como os dados oriundos de modelos climáticos e reanálises podem estar representando tais variações? Uma vez que há uma falta de representação espaço/temporal de dados observados, e essa carência pode ser corrigida pela modelagem matemática.

Desta forma, o objetivo geral deste trabalho será analisar o comportamento espaço-temporal da precipitação na Guiné-Bissau nas últimas décadas e avaliar o desempenho de dados oriundos de modelagem numérica através do uso de técnicas de modelagem. Para atender ao objetivo geral do trabalho, alguns objetivos específicos são estipulados:

1. determinar os valores médios e tendências da precipitação em Guiné-Bissau nas últimas 3 décadas;
2. avaliar o desempenho de reanálises em relação à dados observados em diferentes regiões do país através de técnicas de modelagem matemática;
3. estimar o comportamento da precipitação nos próximos anos para Guiné-Bissau através de técnicas de modelagem matemática.

2 REVISÃO BIBLIOGRÁFICA

2.1 O Clima da Guiné-Bissau e as Chuvas na Região

A precipitação é, sem dúvida, o fator mais importante do ciclo hidrológico, mas também um dos mais difíceis de estimar (Beck et al., 2017; Daly et al., 2008; Michaelides et al., 2009; Kidd; Levizzani, 2011; Tapiador et al., 2012). Os conjuntos de dados diferem em termos do objetivo do projeto (homogeneidade temporal "verifica se a série histórica é consistente", acurácia "mostra se os valores estimados são próximos dos observados" ou ambos), fontes de dados (radar, pluviômetro, satélite, análise ou reanálise, ou combinações dos mesmos), resolução espacial (de 0.05 a 2.5°), cobertura espacial (de continental a totalmente global), resolução temporal (de 30 minutos a mensal) e abrangência temporal (de ~1 a 115 anos) (Beck et al., 2017).

Na região da África Ocidental a monção é uma circulação em escala global que é dominada por uma reversão sazonal dos ventos originados pela diferença de aquecimento entre a terra e o oceano (Tanimoune et al., 2024; Sylla et al., 2009). O que causa uma mudança sazonal dos sistemas de vento em grande escala durante o verão boreal e resulta na migração da Zona de Convergência Intertropical (ZCIT) sobre o continente (linha curvilíneo preta na Figura 1) (Klein et al., 2015; Mendes; Fragoso, 2023). Ventos sazonais caracterizam o sistema Monção da África Ocidental (MAO) (Figura 1): o vento nordeste, que sopra ar frio para a região no inverno (Figura 1 da direita); e o vento sudoeste, que traz ar quente e úmido sobre a região no verão (Figura 1 da esquerda) (Tanimoune et al., 2024; Krishnamurthy; Ajayamohan, 2010). O vento de sudoeste transporta umidade do Oceano Atlântico para África Ocidental e causa chuvas sazonais sobre o continente. As chuvas sazonais são essenciais para milhões de pessoas da África Ocidental, cujas culturas e estilos de vida dependem do comportamento das chuvas de monções e da estação de crescimento das culturas agrícolas associada (Tanimoune et al., 2024; Sivakumar et al., 2014; Omotosho; Abiodun, 2007).




Figura 1 – Comportamento da monção africana (regiões em verde), as setas pretas indicam o sentido predominante dos ventos, a figura da esquerda representa o período de verão e da direita o inverno . Fonte: <https://www.clivar.org/african-monsoon>.

O regime pluviométrico unimodal (caracteriza-se pela ocorrência de um único máximo anual de precipitação, associado a um período chuvoso principal seguido por uma estação seca bem definida) mais ao sul centra-se no mês de agosto, com uma precipitação anual variando entre 400 e 600 mm. Os regimes de precipitação bimodais (é associado pela presença de dois máximos de precipitação ao longo do ano, geralmente separados por um período relativamente seco) da zona sudano-guineense e da costa da Guiné (Figura 2) centram-se em junho e outubro, o que representa os picos da estação chuvosa maior e menor, respectivamente. Os valores anuais de precipitação atingem 900-1200 mm na zona sudano-guineense. Os regimes de chuvas seguem a migração sazonal da ZCIT e também estão associados à migração para o norte do fluxo de monções sobre o continente (Ta et al., 2016; Nicholson; Palao, 1993; Sultan; Janicot; Drobinski, 2007).

Os dados provenientes de satélites (CMORPH e TRMM) mostram as fases oceânica e costeira da monção de abril a junho, seguidas por um “salto da monção” no final de junho, quando as chuvas mais intensas começam na região do Sahel (Figura 2), com precipitação máxima em torno de 12° N continuando até o final de agosto. A monção recua gradualmente para sul em meados de setembro até o final de outubro. A frequência e intensidade da precipitação são máximas em abril-junho sobre o oceano e perto da costa. A frequência da precipitação também é grande entre 9° N e

12.5° N na zona sudanesa de julho a setembro. Durante este período, a intensidade da precipitação é maior em torno de 12.5° N com valores atingindo 11-17 mm/dia para o CMORPH e 14-17 mm/dia para o caso do TRMM. A intensidade da precipitação é o principal ponto de discordância entre os dois conjuntos de dados, sendo o CMORPH mais confiável para esta região (Berthou et al., 2019).




Figura 2 – Subdivisão das regiões de acordo com o regime pluviométrico. Fonte: (Tanimoune et al., 2024).

Em Guiné-Bissau, o início tardio e o fim precoce da estação chuvosa são fatores de preocupação para o setor agrícola quanto ao sucesso da safra agrícola (Mendes; Fragoso, 2023; Mendes, 2018). Essa situação pode ser ainda mais agravada pela ocorrência de secas ou chuvas excessivas durante o desenvolvimento das culturas. Por exemplo, o ano de 2020 foi caracterizado como um ano anormalmente chuvoso (Mendes; Fragoso, 2023). Apesar da chegada tardia das precipitações (início de junho), os meses de julho, agosto e setembro foram muito chuvosos, o que teve grandes consequências relacionadas com inundações nas lavouras de arroz da região (Mendes; Fragoso, 2023).

A MAO é a característica mais proeminente do clima da África Ocidental. Ela é responsável pela maior parte da precipitação anual e, portanto, é de suma importância para a população. O ar úmido relativamente frio do Golfo da Guiné é advectado para o continente quente e seco, onde a faixa de chuva resultante viaja da Costa da Guiné para o Sahel e vice-versa, seguindo o movimento da ZCIT (Klein et al., 2015; Mendes;

Fragoso, 2023).

A precipitação anual em 2020 ficou acima da média em todo o território da Guiné-Bissau. Em geral, as zonas costeiras a sul de Bissau e as ilhas foram as zonas mais chuvosas do país, com valores superiores a 2000 mm (Figura 3a). As anomalias correspondentes variaram entre 1000 e 1500 mm nessas regiões (Figura 3b). A área menos chuvosa foi o leste, especialmente a região de Gabú que fica na zona leste do país, apresentando valores totais variando entre 1300-1650 mm, porém bastante acima dos valores normais. O norte e o centro do país apresentaram valores intermediários de precipitação anual, registrando entre 1650 e 1950 mm (Mendes; Fragoso, 2023). O regime de precipitação na Guiné-Bissau é caracterizado pela sua concentração em julho, agosto e setembro, sendo agosto geralmente considerado o mês mais chuvoso do ano em termos de totais mensais de precipitação e frequência de dias chuvosos.




Figura 3 – Acumulado anual de 2020 (mm) para Guiné-Bissau (A), Anomalia da precipitação de 2020 em relação ao período climatológico de 1981-2020 (B). Fonte: (Mendes; Fragoso, 2023).

Segundo os serviços de proteção civil de Guiné-Bissau, 4617 pessoas foram vítimas de cheias (os danos foram mais significativos nas casas construídas com materiais e estruturas precárias) causadas pelas fortes chuvas observadas em julho e

agosto de 2020, tendo a capital Bissau que fica no centro-litoral do país registrado mais de 50% destas vítimas (Mendes; Fragoso, 2023). Além das fortes chuvas que atingiram infraestruturas sociais, como escolas, postos de saúde e estradas. Os ventos também vitimaram 1374 famílias (causando danos estruturais e o destelhamento de diversas residências), com o maior número de vítimas registradas na região de Cacheu, localizada na zona norte, o Setor Autónomo de Bissau, situado na região central, e a região de Gabú, localizada na zona leste do país. Devido aos impactos causados pelas fortes chuvas, enchentes e ventos fortes, o número de casas destruídas em todo o país foi expressivo. Os bairros da periferia da capital Bissau não escaparam das enchentes causadas pelas chuvas intensas que causaram danos materiais e interromperam o fornecimento de bens e serviços (Mendes; Fragoso, 2023). Como resultado, o governo disponibilizou um fundo de 100 milhões de francos CFA (6,5 milhões de euros), através do Ministério da Solidariedade, para ajudar as vítimas do mau tempo em diferentes regiões.

2.2 Modelos Climáticos

A utilização de modelos climáticos globais é uma ferramenta útil para análises espaço-temporais de determinadas variáveis meteorológicas, entre elas a precipitação. Além das condições climáticas atuais, também é possível avaliar as condições climáticas passadas e as projetadas para as próximas décadas.

O clima da África Ocidental é desafiador em se reproduzir usando modelos climáticos de resolução padrão (um modelo regional com convecção parametrizada, denominado R25), pois uma grande proporção da precipitação vem de convecção profunda organizada, ou seja, influenciada por fatores locais (Berthou et al., 2019).

A capacidade de um modelo atmosférico de simular processos convectivos é crucial e, ao mesmo tempo, um fator limitante para a qualidade da representação da precipitação do modelo nos trópicos e subtropicais (Klein et al., 2015). As diferenças entre os grupos de parametrização na precipitação levantam a questão se elas podem estar relacionadas a mudanças na dinâmica e se essas mudanças correspondem a mecanismos conhecidos por causar variabilidade interanual de monções (Klein et al., 2015).

Por sua vez, os modelos são sustentados por dados observados *in situ* ou de forma remota. Estudos que avaliaram diferentes conjuntos de dados de satélite (CMORPH e ARC2) indicam que estes conjuntos representam valores de precipitação muito abaixo na região de Guiné, Serra Leoa e Libéria (África Ocidental), em claro desacordo com todos os outros conjuntos de dados nesta região. A baixa representação da precipitação nestes dados de satélite vem da tentativa de correção de viés, mas abaixo do esperado quando confrontado contra a análise de pluviômetros, que são utilizados,

por exemplo, pelo NCEP-CPC (Berthou et al., 2019; Xie et al., 2017) e GPCC (o qual o TRMM é corrigido). Os conjuntos ARC2 e CPC usam pluviômetros de uma rede mais limitada, enquanto GPCC, CHIRPS e CRU têm fontes extras de dados. A documentação do ARC2 relata que as estações em Gâmbia, Guiné-Bissau, Guiné, Serra Leoa e Nigéria relataram menos de 30% do tempo de 1983 a 2009 (Berthou et al., 2019; Novella; Thiaw, 2013).

Berthou et al. (2019) apresentaram uma comparação de um modelo de convecção de 4.5 km para 10 anos (CP4A), com uma simulação regional de 25 km x 40 km, usando uma parametrização convectiva (R25), em termos da representação da monção da África Ocidental. No CP4A, a frequência da precipitação é muito mais próxima das observações ao longo das estações e latitudes, embora seja 10-30% subestimada. Sobre o continente, o CP4A é geralmente mais úmido do que o R25. Próximo de 7° - 8° N. O CP4A mostra o conhecido pico duplo na precipitação (maio-junho e outubro) tanto em termos de média e frequência de precipitação quanto nas observações, enquanto o R25 tem uma amplitude mais fraca. Em maio e outubro, a superestimação da precipitação sobre o continente ao norte de 9° no CP4A é principalmente devido a uma superestimação da frequência de precipitação. De junho a setembro, o CP4A tem uma intensidade de precipitação muito forte entre 7° e 12.5° N (Berthou et al., 2019).

No geral, o CP4A é mais capaz de reproduzir a forma (da variação temporal da precipitação ao longo do dia), o tempo e a amplitude do ciclo diurno do que o R25 longe da orografia. Ele é capaz de reproduzir a estrutura espacial da fase ao redor da orografia e em países costeiros, mas não no Sahel (Berthou et al., 2019). Ambas as simulações foram conduzidas por um modelo climático global somente da atmosfera atual a 25 km x 40 km e cobrem um domínio pan-africano. No geral, o CP4A mostra melhorias substanciais em comparação ao R25 em termos de precipitação. O CP4A é mais adequado do que R25 na representação de precipitação em escalas de tempo e espaço, o que é muito importante da perspectiva do usuário. Portanto, espera-se que o CP4A forneça informações mais confiáveis e relevantes sobre mudanças climáticas para o usuário, sobre chuvas intensas, períodos de chuvas/seca (Berthou et al., 2019).

Além da análise das chuvas ocorridas nas últimas décadas, também há uma preocupação em representar possíveis padrões futuros de precipitação. Os modelos climáticos que subsidiam os cenários climáticos do IPCC (Painel Intergovernamental sobre Mudanças Climáticas) foram desenvolvidos pela primeira vez pelo *World Climate Research Programme* (WCRP) em 1990. O *Coupled Model Intercomparison Project* (CMIP) cria padrões e estabelece protocolos experimentais para os modelos climáticos. Esses protocolos garantem que aqueles que contribuem para o CMIP sigam padrões, coordenação, infraestrutura e documentação comuns. Todos os modelos no CMIP seguem diretrizes semelhantes sobre quais variáveis de entrada devem ser uti-

lizadas e quais variáveis de saída devem ser incluídas. A fase mais recente e mais utilizada dos modelos climáticos é a sexta fase do CMIP (CMIP6) (Eyring et al., 2016a).

Os modelos climáticos são executados sob vários cenários com diferentes emissões de gases do efeito estufa, que representam diferentes cenários futuros possíveis. Os cenários especificados pelo CMIP fornecem a todos os grupos a mesma informação para utilizar nos seus modelos climáticos.

Nooni et al. (2023) utilizaram modelos que compõem o CMIP6 para representar o comportamento espaço-temporal da precipitação no continente africano, os autores encontraram que todos os modelos reproduziram a precipitação nas regiões climáticas áridas da África, no entanto, o regime de precipitação nas regiões mais úmidas (isto é, de maio a novembro) os modelos indicaram um desempenho fraco na replicação da precipitação. De acordo com os autores esse fator pode estar relacionado com as configurações dos modelos. Porém, mesmo com algumas deficiências, os autores ressaltam que há melhorias em relação a geração de modelos anterior e que são ferramentas úteis para análises climáticas de longo prazo.

Klutse et al. (2021) avaliaram uma série de modelos que compõem o CMIP6 na representação das características e valores extremos de precipitação no setor ocidental da África durante o período de junho a setembro. Os autores encontraram discrepâncias em alguns modelos em comparação com os dados observados, com uma tendência de superestimação nos valores médios e índices extremos calculados.

2.3 Modelagem Matemática

A técnica de mínimos quadrados discretos pode ser aplicada aos dados mensais de precipitação de estações meteorológicas, com o objetivo de suavizar flutuações aleatórias e reduzir o ruído presente nas séries temporais. Esse método possibilita o ajuste de modelos matemáticos que facilitam a identificação de tendências de longo prazo e padrões sazonais, contribuindo para uma compreensão mais clara das variações climáticas regionais. A comparação dos ajustes entre as estações permite avaliar diferenças nas tendências e na variabilidade da precipitação, auxiliando na caracterização das particularidades climáticas de cada região.

A ausência de um ajuste preciso dos dados é, possivelmente, decorrente da presença de erros e incertezas no próprio método de ajuste ou na função utilizada para representar a série, e não necessariamente nos dados observacionais. Além disso, pode exigir que a função de aproximação coincida exatamente com todos os pontos da série não é adequado (na maioria das vezes, os dados observados podem conter ruído, erros de medição. Se o modelo não for ajustado com grau adequado e pode passar exatamente por todos os pontos, ele pode acabar ajustando também o ruído, e não apenas o comportamento real do fenômeno), pois isso introduziria oscilações que

não estavam presentes originalmente. Em vez disso, a abordagem mais apropriada consiste em determinar a melhor reta de ajuste (no sentido de minimizar os desvios), ainda que ela não passe exatamente por cada ponto da série temporal.

Diferentes técnicas são utilizadas em diferentes regiões do globo para a identificação de tendências de conjuntos de dados, além de identificação do padrão de ocorrências (frequência e magnitude) de eventos extremos. Madsen et al. (2002) utilizaram o modelo de regressão de mínimos quadrados generalizados para uma rede pluviométrica da Dinamarca. Este modelo considera explicitamente a correlação entre locais e as incertezas amostrais, e foi aplicado para avaliar a heterogeneidade regional dos parâmetros. Os autores observaram que o modelo resultante pode ser usado para estimar curvas de intensidade-duração-frequência da precipitação em um local arbitrário em uma região.

Treppiedi et al. (2021) utilizaram o método de regressão quantílica para identificar as tendências de precipitação para a ilha italiana da Sicília. Os resultados mostraram que muitos pluviômetros são caracterizados por uma tendência crescente na intensidade de precipitação sub-horária, especialmente nos quantis mais altos, sugerindo que, de 2002 a 2019, os eventos sub-horários se tornaram mais intensos na maior parte da ilha.

A aplicação de diferentes tipos de regressão são usadas também, Portuguese-maurtua et al. (2022) utilizaram diferentes métodos de preenchimento de lacunas em dados diários de precipitação usando técnicas de modelo de regressão e aprendizado de máquina. O modelo de regressão incluiu algoritmos de regressão linear e regressão múltipla. Os resultados mostraram que os modelos otimizados de aprendizado de máquina apresentaram a menor variabilidade nos erros de estimativa e a melhor aproximação dos dados reais da área de estudo no Peru. Além disso, o trabalho mostrou que o aprendizado de máquina interpreta e analisa relações não lineares entre pluviômetros em escala diária e pode ser usado como um método eficiente para preencher lacunas em séries diárias de precipitação.

No continente africano estudos também buscaram entender o comportamento da precipitação e seus extremos, Hession; Moore (2011) se concentraram na aplicação da regressão por mínimos quadrados ordinários para testar hipóteses relacionadas a múltiplas variáveis preditivas, em uma tentativa de melhor compreender os mecanismos físicos que impulsionam a precipitação, ou no uso de modelos espacialmente explícitos no Quênia.

3 METODOLOGIA

3.1 Área de Estudo e Dados Observados

Os dados de precipitação utilizados foram fornecidos pelo Instituto Nacional de Meteorologia da Guiné-Bissau (INMGB) e consistem em séries temporais mensais coletadas em estações meteorológicas situadas nas principais cidades do país (Tabela 1), abrangendo o período de 1990 a 2022 (Figura 4).

Nº	Nome da Estação	Região	Latitude(N)	Longitude(W)
1	Bissau	SAB (Capital)	11.86°	-15.6°
2	Gabú	Gabú (Leste)	12.28°	-14.21°
3	Bafatá	Bafatá (Leste)	12.17°	-14.65°
4	Bigene	Cacheu (Norte)	12.44°	-15.54°
5	Bolama	Bolama (Sul)	11.50°	-15.02°
6	Catió	Tombali (Sul)	11.28°	-15.25°
7	Farim	Oio (Norte)	12.48°	-15.21°
8	Mansabá	Oio (Norte)	12.29°	-15.18°
9	Suzana	Cacheu (Norte)	12.30°	-16.47°

Tabela 1 – Coordenadas geográficas das estações Meteorológicas da Guiné-Bissau.
Fonte: dos autores (2025).

Os dados foram disponibilizados sem falhas, garantindo sua integridade e confiabilidade para a realização das análises.




Figura 4 – Localização da região de estudo e das estações meteorológicas existentes. Fonte: dos autores (2025).

3.2 Reanálise

3.2.1 MSWEP V2

O conhecimento sobre a distribuição espaço-temporal da precipitação é importante para uma infinidade de estudos científicos e aplicações operacionais, incluindo previsão de inundações, monitoramento agrícola e rastreamento de doenças (Beck et al., 2019; Tapiador et al., 2012; Kucera et al., 2013; Kirschbaum et al., 2017). A precipitação é altamente variável no espaço e no tempo e, portanto, extremamente difícil de estimar, especialmente em regiões topograficamente complexas e dominadas por convecção (Beck et al., 2019; Stephens et al., 2010; Tian; Peters-lidard, 2010; Herold et al., 2016; Prein; Gobiet, 2017).

Para superar as limitações decorrentes do escasso número de estações meteorológicas com longas séries de dados em Guiné-Bissau, também necessário explorar, como fonte de informação a reanálise *Multi-Source Weighted-Ensemble Precipitation, versão 2* (MSWEP V2) é um conjunto de dados de precipitação distribuído em formato de grade, abrangendo o período de 1990 até os dias atuais e em diferentes escalas temporais. Desde o lançamento da versão 1 do MSWEP (MSWEP V1), melhorias consideráveis foram implementadas, resultando nesta nova versão 2 do MSWEP (Beck et al., 2017, 2019; Gebrechorkos et al., 2023). O MSWEP V2 é um conjunto de dados único em vários aspectos: possui uma cobertura global completa; alta resolução espacial (0.1°); fusão de diversas estimativas de precipitação, tomando como base

dados oriundos de observação, satélites e outras reanálises. O MSWEP possui um sistema de correção de viés para melhorar a frequência e a representação da precipitação a nível global, além da correção de vieses sistemáticos de precipitação usando observações de vazão fluvial de 13.762 estações em todo o mundo e a incorporação de observações diárias de 76.747 medidores globais (Beck et al., 2017, 2019; Gebrechorkos et al., 2023).

Quando comparado outros conjuntos de dados de precipitação globais, o MSWEP V2 é substancialmente melhor, demonstrando a eficácia da metodologia. Outras comparações globais sugerem que o MSWEP V2 exibe padrões espaciais mais realistas em média, magnitude e frequência. O MSWEP V2 oferece oportunidades únicas para explorar variações espaço-temporais de precipitação, melhorando a compreensão dos processos hidrológicos, as parametrizações e contribuindo para melhorar o desempenho de modelos hidrológicos (Beck et al., 2019; Sun et al., 2022; Gebrechorkos et al., 2023).

3.2.2 ERA5

Segundo Hersbach et al. (2020), a quinta geração de reanálise atmosférica global produzida pelo European Centre for Medium-Range Weather Forecasts (ECMWF) no âmbito do Copernicus Climate Change Service (C3S). A ERA5 fornece um registro climático consistente e detalhado da atmosfera, superfície terrestre e ondas oceânicas em escala global, cobrindo o período desde 1950, substituindo a reanálise ERA-Interim, que teve início em 1979 (Hersbach et al., 2020).

A ERA5 é baseada no Integrated Forecasting System (IFS) Cy41r2, que esteve operacional em 2016, incorporando aproximadamente uma década de avanços em pesquisa e desenvolvimento em física de modelos, dinâmica atmosférica, operadores de observação e técnicas de assimilação de dados. O desenvolvimento da ERA5 também se beneficiou de reanálises oceânicas, como a ORAS5, e de reanálises acopladas centenárias, como a CERA-20C, o que possibilitou a extensão temporal do conjunto até meados do século XX (Hersbach et al., 2020).

Uma das principais melhorias da ERA5 em relação a ERA-Interim é o aumento significativo da resolução espacial e temporal, com resolução horizontal de aproximadamente 31 km, em contraste com os 80 km da ERA-Interim, além de saída horária dos dados. Essa maior resolução permite a representação de detalhes muito mais finos dos fenômenos atmosféricos, tanto no espaço quanto no tempo, contribuindo para uma melhor descrição da variabilidade climática e de eventos extremos (Hersbach et al., 2020).

O conjunto ERA5 também se beneficia da assimilação de diversos dados de satélite reprocessados, incluindo vetores de vento derivados do movimento atmosférico (AMVs). Além disso, incorpora forçantes radiativas de longo prazo do CMIP5, tais

como irradiação solar total, aerossóis e concentrações de gases de efeito estufa, representando um avanço importante em relação a ERA-Interim (Hersbach et al., 2020).

Os principais pontos fortes da ERA5 incluem a resolução espacial e temporal significativamente superior, a assimilação de um volume muito maior de observações reprocessadas, e a inclusão de uma estimativa explícita de incerteza por meio de ensemble, tornando-o uma das reanálises mais completas e robustas atualmente disponíveis para estudos climáticos e meteorológicos (Hersbach et al., 2020).

3.2.3 ERA5-LAND

O trabalho de Muñoz-sabater et al. (2021) mostrou que a ERA5-LAND, um conjunto de dados global aprimorado voltado para a superfície terrestre, desenvolvido como parte da reanálise europeia de quinta geração (ERA5). Produzido pelo Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF) no âmbito do Serviço de Alterações Climáticas Copernicus (C3S), a ERA5-LAND cobre o período de 1950 até o presente, sendo atualizado continuamente de forma operacional (Muñoz-sabater et al., 2021).

A ERA5-LAND descreve a evolução dos ciclos de água e energia na superfície terrestre com resolução horizontal de 9 km, superior à da ERA5 (31 km), e resolução temporal horária. Essa maior resolução espacial constitui um fator crucial para a simulação precisa da variabilidade espacial e temporal do ciclo hidrológico, especialmente em regiões de orografia complexa (Muñoz-sabater et al., 2021).

As avaliações indicam que a ERA5-LAND aprimora significativamente a representação do ciclo hidrológico, com melhorias notáveis na umidade do solo, na descrição de lagos e na descarga de rios, quando comparado às versões anteriores. Embora o desempenho na profundidade da neve seja misto em relação a ERA5, a maior resolução horizontal da ERA5-LAND resulta em estimativas mais realistas em áreas montanhosas, como as Montanhas Rochosas nos Estados Unidos (Muñoz-sabater et al., 2021).

O conjunto de dados disponibiliza cerca de 50 variáveis que descrevem os ciclos de água e energia na superfície terrestre, globalmente, em escala horária e com resolução espacial de 9 km. Sua produção é organizada em três fluxos independentes, exigindo um cuidadoso procedimento de inicialização, particularmente para variáveis de longa memória, como a umidade profunda do solo, a fim de evitar descontinuidades temporais (Muñoz-sabater et al., 2021).

A ERA5-LAND não assimila observações diretamente. A evolução da superfície terrestre é determinada por forçamentos atmosféricos derivados da ERA5, interpolados para a resolução de 9 km e corrigidos para diferenças de altitude. Variáveis como temperatura do ar, umidade e pressão atmosférica são ajustadas utilizando uma taxa de lapso ambiental (Environmental Lapse Rate – ELR) diária, derivada da ERA5, pro-

cedimento essencial em regiões com relevo complexo (Muñoz-sabater et al., 2021).

As variáveis analisadas incluem umidade do solo, profundidade da neve, temperatura da superfície da água dos lagos, descarga de rios, fluxos de calor sensível e latente, razão de Bowen e temperatura da pele (skin temperature). De modo geral, a ERA5-LAND apresenta menor erro quadrático médio (RMSE) e menor viés em regiões de altitude moderada e áreas de floresta boreal, refletindo a melhor representação orográfica. Em montanhas extremamente elevadas e regiões com densa rede observacional de neve, como a Escandinávia, a ERA5 apresenta desempenho ligeiramente superior (Muñoz-sabater et al., 2021).

A ERA5-LAND representa um conjunto de dados de última geração, combinando alta resolução espacial, consistência temporal multidecadal e desempenho aprimorado na representação do ciclo hidrológico. Essas características o tornam uma ferramenta fundamental para aplicações terrestres, monitoramento ambiental e análises de tendências climáticas em escala regional e global (Muñoz-sabater et al., 2021).

A estação de Bissau não foi incluída na presente análise com base nos dados de reanálise ERA5-LAND em função de limitações associadas à sua localização geográfica e às características do próprio produto. A ERA5-LAND é uma reanálise de superfície terrestre baseada em dados em grade regular, com resolução espacial de aproximadamente 9 km, não sendo estruturada a partir de estações meteorológicas pontuais, mas sim de células de grade que representam médias espaciais das variáveis climáticas.

Bissau encontra-se situada em uma zona costeira-estuarina, caracterizada por forte influência oceânica, presença de manguezais e mistura terra-água dentro de uma mesma célula de grade. Nessa configuração, a célula correspondente tende a ser classificada como mista ou predominantemente oceânica, o que leva a ERA5-LAND a mascarar ou não disponibilizar valores estritamente terrestres para esse ponto. Como consequência, a extração direta de séries temporais representativas da superfície continental torna-se inadequada ou indisponível para a localidade.

A inclusão de um ponto costeiro com forte influência marinha poderia introduzir incertezas adicionais e comprometer a comparabilidade espacial entre as estações analisadas, especialmente no contexto de uma abordagem focada na variabilidade e nos extremos de precipitação sobre áreas continentais. Assim, optou-se por excluir Bissau da análise com ERA5-LAND e priorizar estações costeiras com maior representatividade terrestre (como Bolama e Catió), estações de transição (Bigene e Suzana) e estações do interior (Bafatá, Gabú, Farim e Mansabá).

3.3 Métricas Estatísticas de Avaliação

Para avaliar o desempenho dos produtos de precipitação em relação aos dados observados, foram utilizadas métricas estatísticas descritivas e de desempenho amplamente aplicadas em estudos climatológicos (Wilks, 2011; Moriasi et al., 2007). Essas métricas permitem quantificar tendência central, dispersão, variabilidade, erros, associação linear e capacidade explicativa dos modelos.

3.3.1 Métricas Descritivas

3.3.1.1 Média

A média aritmética representa o valor médio da precipitação observada ou reanálise, sendo utilizada para descrever a tendência central dos dados (Wilks, 2011).

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

onde:

- $\bar{x}$ = média aritmética;
- x_i = valor observado;
- n = número total de observações.

3.3.1.2 Mediana

A mediana corresponde ao valor central da distribuição dos dados ordenados, dividindo a amostra em duas partes iguais (Zar, 2010).

$$Mediana = x_{(\frac{n+1}{2})} \quad (2)$$

Para amostras com número par de observações:

$$Mediana = \frac{x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}}{2} \quad (3)$$

A mediana é menos sensível à influência de valores extremos quando comparada à média.

3.3.1.3 Variância

A variância mede o grau de dispersão dos dados em relação à média (Montgomery, 2017).

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1} \quad (4)$$

onde:

- s^2 = variância amostral;
- x_i = observações;
- $\bar{x}$ = média amostral.

3.3.1.4 Desvio Padrão

O desvio padrão representa a dispersão média dos dados em torno da média e corresponde à raiz quadrada da variância (Montgomery, 2017).

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}} \quad (5)$$

Valores elevados indicam maior variabilidade pluviométrica e maior ocorrência de extremos climáticos.

3.3.1.5 Valor Mínimo

O valor mínimo representa a menor observação registrada na série de precipitação.

$$x_{min} = \min(x_1, x_2, \dots, x_n) \quad (6)$$

3.3.1.6 Valor Máximo

O valor máximo corresponde à maior observação registrada na série.

$$x_{max} = \max(x_1, x_2, \dots, x_n) \quad (7)$$

O máximo é importante para caracterizar eventos extremos e precipitações severas.

3.3.1.7 Primeiro Quartil (Q_1)

O primeiro quartil representa o valor abaixo do qual se encontram 25% das observações (Montgomery, 2017).

$$Q_1 = P_{25} \quad (8)$$

3.3.1.8 Segundo Quartil (Q_2)

O segundo quartil corresponde à mediana da distribuição.

$$Q_2 = P_{50} \quad (9)$$

3.3.1.9 Terceiro Quartil (Q_3)

O terceiro quartil representa o valor abaixo do qual estão 75% das observações.

$$Q_3 = P_{75} \quad (10)$$

Os quartis são amplamente utilizados na construção de boxplots, permitindo avaliar dispersão, assimetria e ocorrência de valores extremos na distribuição pluviométrica.

3.3.2 Métricas de Desempenho

3.3.2.1 Erro Médio Absoluto (MAE)

O Erro Médio Absoluto MAE (*Mean Absolute Error*) mede a média das diferenças absolutas entre os valores observados e reanálises (Montgomery, 2017).

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i^{rean} - P_i^{obs}| \quad (11)$$

onde:

- P_i^{rean} = precipitação reanalisadas;
- P_i^{obs} = precipitação observada;
- n = número total de observações.

Valores menores de MAE indicam melhor desempenho do modelo.

3.3.2.2 Viés (Bias)

O Bias representa a tendência média do modelo em superestimar ou subestimar os valores observados (Montgomery, 2017).

$$Bias = \frac{1}{n} \sum_{i=1}^n (P_i^{rean} - P_i^{obs}) \quad (12)$$

Valores positivos indicam superestimação, enquanto valores negativos indicam subestimação da precipitação.

3.3.2.3 Raiz do Erro Quadrático Médio (RMSE)

O RMSE (*Root Mean Square Error*) mede a magnitude média dos erros, atribuindo maior peso aos erros extremos (Montgomery, 2017).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i^{rean} - P_i^{obs})^2} \quad (13)$$

3.3.2.4 Raiz do Erro Quadrático Médio Normalizado (NRMSE)

O NRMSE corresponde ao RMSE normalizado pela média observada (Jamieson et al., 1991).

$$NRMSE = \frac{RMSE}{\bar{P}^{obs}} \quad (14)$$

onde:

$$\bar{P}^{obs} = \frac{1}{n} \sum_{i=1}^n P_i^{obs} \quad (15)$$

A classificação do desempenho foi definida como:

- $NRMSE < 1$: desempenho bom;
- $1 \leq NRMSE < 1.5$: desempenho moderado;
- $NRMSE \geq 1.5$: desempenho fraco.

3.3.2.5 Coeficiente de Correlação de Pearson (r)

O coeficiente de correlação de Pearson mede o grau de associação linear entre os valores observados e reanálise (Montgomery, 2017).

$$r = \frac{\sum_{i=1}^n (P_i^{obs} - \bar{P}^{obs})(P_i^{rean} - \bar{P}^{rean})}{\sqrt{\sum_{i=1}^n (P_i^{obs} - \bar{P}^{obs})^2} \sqrt{\sum_{i=1}^n (P_i^{rean} - \bar{P}^{rean})^2}} \quad (16)$$

3.3.2.6 Coeficiente de Determinação (R^2)

O coeficiente de determinação representa a proporção da variabilidade observada explicada pelo modelo (Montgomery, 2017).

$$R^2 = r^2 \quad (17)$$

3.3.3 Testes Estatísticos

Além das métricas descritivas e de desempenho, foram aplicados testes estatísticos para verificar os principais pressupostos das análises, incluindo normalidade, homogeneidade das variâncias e independência dos resíduos. A verificação desses pressupostos contribui para aumentar a confiabilidade das interpretações estatísticas realizadas neste estudo.

3.3.3.1 Teste de Shapiro-Wilk

O teste de Shapiro-Wilk foi utilizado para verificar a normalidade das séries de precipitação observada, reanalisada e dos resíduos (Shapiro; Wilk, 1965). Esse teste

é amplamente recomendado para amostras pequenas e médias devido ao seu elevado poder estatístico quando comparado a outros testes de normalidade, sendo amplamente empregado em estudos climatológicos (Razali; Wah, 2011; Arnastauskaitė; Ruzgas; Bražėnas, 2021; Lee, 2022).

$$W = \frac{(\sum_{i=1}^n a_i x_{(i)})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (18)$$

em que $x_{(i)}$ representa os valores ordenados da amostra, $\bar{x}$ corresponde à média amostral e a_i são coeficientes obtidos a partir da matriz de covariância dos valores ordenados de uma distribuição normal.

3.3.3.2 Teste de Levene

A homogeneidade das variâncias entre os grupos foi avaliada por meio do teste de Levene (Levene, 1960). Neste estudo, foi utilizada a implementação da função `scipy.stats.levene` da biblioteca SciPy, que emprega, por padrão, a modificação proposta por Brown e Forsythe (Brown; Forsythe, 1974), utilizando a mediana como medida de tendência central. Essa abordagem apresenta maior robustez frente à presença de valores extremos e desvios da normalidade, sendo amplamente recomendada na literatura recente (Wang et al., 2017).

$$W = \frac{(N - k) \sum_{i=1}^k n_i (\bar{Z}_i - \bar{Z})^2}{(k - 1) \sum_{i=1}^k \sum_{j=1}^{n_i} (Z_{ij} - \bar{Z}_i)^2} \quad (19)$$

em que N representa o número total de observações, k o número de grupos, n_i o número de observações do grupo i , $\bar{Z}_i$ a média dos valores transformados do grupo i e $\bar{Z}$ a média global desses valores. Considerando a implementação utilizada no SciPy, os valores transformados são definidos por

$$Z_{ij} = |Y_{ij} - \tilde{Y}_i| \quad (20)$$

em que Y_{ij} representa a j -ésima observação do grupo i e $\tilde{Y}_i$ corresponde à mediana do grupo i .

3.3.3.3 Teste de Durbin-Watson

O teste de Durbin-Watson foi utilizado para verificar a presença de autocorrelação serial de primeira ordem nos resíduos (Durbin; Watson, 1950, 1951). Esse teste é amplamente empregado na validação de modelos estatísticos e de regressão, permitindo avaliar a independência dos resíduos (Montgomery; Peck; Vining, 2012; Weisberg,

2014; Yin, 2020).

$$DW = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (21)$$

em que e_t representa o resíduo correspondente à observação t . Valores de DW próximos de 2 indicam ausência de autocorrelação; valores inferiores a 2 sugerem autocorrelação positiva, enquanto valores superiores a 2 indicam autocorrelação negativa.

3.4 ANOVA de Dois Fatores

As referências associadas ao critério do fator de dois utilizadas neste trabalho estão relacionadas a estudos que empregam a análise de variância (ANOVA) com dois fatores na avaliação de sistemas ambientais. Esses estudos fornecem o embasamento conceitual necessário para a compreensão e aplicação dos critérios adotados, conforme os conceitos apresentados a seguir.

A técnica ANOVA foi originalmente definida por R. A. Fisher como a “separação da variância atribuível a um grupo de causas da variância atribuível a outros grupos”. Essa técnica tem sido aplicada em ciências atmosféricas de diversas maneiras no passado. Zwiers (1996) a aplicou recentemente, utilizando modelos de um e dois fatores, para analisar a variabilidade interanual e a previsibilidade de variáveis de circulação, tanto no conjunto de simulações climáticas Projeto de Intercomparação de Modelos Atmosféricos (AMIP) do Centro Canadense de Modelagem e Análise Climática (CC-CMA) quanto no clima observado relevante. Da mesma forma, o modelo de efeitos mistos de dois fatores é adotado neste estudo para analisar as variabilidades da intensidade média sazonal e da acumulação sazonal de precipitação no conjunto (Zwiers, 1996).

Na ANOVA de dois fatores, existem dois fatores diferentes que podem ser considerados influenciadores da variável resposta, cada um com um certo número de níveis. Para cada combinação dos níveis dos dois fatores, existe uma amostra com o mesmo tamanho. Nessa situação, utilizando testes de hipóteses, estuda-se a influência de cada fator na variável de resposta, bem como se existe interação entre ambos os fatores (Moreira; Augusto, 2024).

A Análise de Variância (ANOVA) de dois fatores é utilizada para avaliar simultaneamente a influência de dois fatores sobre uma variável resposta, permitindo identificar o efeito de um fator enquanto se controla estatisticamente o efeito do outro (Helsel et al., 2020).

3.4.1 Análise de Variância (ANOVA) de Dois Fatores com Interação

A ANOVA de dois fatores com interação foi utilizada para avaliar os efeitos dos diferentes produtos de precipitação e das estações meteorológicas sobre a variabilidade da precipitação observada em Guiné-Bissau. O modelo estatístico geral da ANOVA de dois fatores com interação é representado por:

$$Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk} \quad (22)$$

onde:

- Y_{ijk} = valor observado da variável resposta;
- μ = média geral;
- α_i = efeito do fator A (Produto);
- β_j = efeito do fator B (Estação);
- $(\alpha\beta)_{ij}$ = efeito da interação entre os fatores A e B;
- ε_{ijk} = erro aleatório associado à observação.

A soma total dos quadrados é dada por:

$$SQ_T = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (Y_{ijk} - \bar{Y}_{...})^2 \quad (23)$$

A decomposição da variabilidade total é expressa por:

$$SQ_T = SQ_A + SQ_B + SQ_{AB} + SQ_E \quad (24)$$

onde:

- SQ_A = soma dos quadrados do fator A;
- SQ_B = soma dos quadrados do fator B;
- SQ_{AB} = soma dos quadrados da interação;
- SQ_E = soma dos quadrados do erro.

As somas dos quadrados dos fatores são calculadas por:

$$SQ_A = bn \sum_{i=1}^a (\bar{Y}_{i..} - \bar{Y}_{...})^2 \quad (25)$$

$$SQ_B = an \sum_{j=1}^b (\bar{Y}_{.j} - \bar{Y}_{...})^2 \quad (26)$$

A soma dos quadrados da interação é dada por:

$$SQ_{AB} = n \sum_{i=1}^a \sum_{j=1}^b (\bar{Y}_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j.} + \bar{Y}_{...})^2 \quad (27)$$

A soma dos quadrados do erro é calculada por:

$$SQ_E = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (Y_{ijk} - \bar{Y}_{ij.})^2 \quad (28)$$

Os quadrados médios são obtidos por:

$$QM = \frac{SQ}{GL} \quad (29)$$

onde:

- QM = quadrado médio;
- SQ = soma dos quadrados;
- GL = graus de liberdade.

Os testes estatísticos da ANOVA utilizam a estatística F:

$$F_A = \frac{QM_A}{QM_E} \quad (30)$$

$$F_B = \frac{QM_B}{QM_E} \quad (31)$$

$$F_{AB} = \frac{QM_{AB}}{QM_E} \quad (32)$$

Os graus de liberdade são definidos por:

$$GL_A = a - 1 \quad (33)$$

$$GL_B = b - 1 \quad (34)$$

$$GL_{AB} = (a - 1)(b - 1) \quad (35)$$

$$GL_E = ab(n - 1) \quad (36)$$

$$GL_T = abn - 1 \quad (37)$$

onde:

- a = número de níveis do fator A;
- b = número de níveis do fator B;
- n = número de observações por grupo.

A ANOVA de dois fatores sem replicação é a alternativa paramétrica ao teste de Friedman em delineamentos em blocos completos. Nesse caso, existe apenas uma observação por combinação fator–bloco, sendo o efeito de bloco considerado apenas para a remoção do ruído experimental (Helsel et al., 2020).

3.5 Modelagem Matemática

3.5.1 Aproximações por Mínimos Quadrados Discretos: Ajuste por um Polinômio de grau n

A razão provável para que nenhuma curva ajuste precisamente os dados está associada à presença de erros, que podem decorrer do método de ajuste utilizado ou de um possível subajuste do modelo (Burden; Faires, 1989). Portanto, não é razoável exigir que a função de aproximação coincida exatamente com os dados. Na realidade, tal função introduziria oscilações que não estavam presentes originalmente (Burden; Faires, 1989).

Uma abordagem mais acertada seria encontrar a “melhor” (em algum sentido) curva de aproximação, mesmo que ela não coincida precisamente com os dados em nenhum ponto (Burden; Faires, 1989).

Denote por $a_1x_1 + a_0$ o i -ésimo valor na reta de aproximação e por y_i o i -ésimo valor dado de y .

$$E_\infty(a_0, a_1) = \sum_{i=1}^n \{|y_i - (a_1x_1 + a_0)|\} \quad (38)$$

A abordagem minimax geralmente atribui muito peso a uma pequena parte dos dados que possui erros grandes, ao passo que o método de desvio absoluto não dá peso suficiente a um ponto que se encontre consideravelmente fora da reta de aproximação (Burden; Faires, 1989). O método de mínimos quadrados atribui substancialmente

mais peso a um ponto que esteja desalinhado com o resto dos dados, mas permitirá que tal ponto domine completamente a aproximação (Burden; Faires, 1989).

Neste estudo voltado ao nosso objetivo, buscou-se analisar o comportamento da precipitação no período chuvoso entre 1990 e 2022 da Guiné-Bissau, utilizando dados observados de estações meteorológicas. Para avaliar o desempenho dos dados obtidos, aplicou-se a modelagem matemática baseada no ajuste por polinômio de grau n , permitindo capturar tendências e variações ao longo do tempo de maneira mais flexível do que modelos lineares simples.

O ajuste polinomial é uma ferramenta que permite representar padrões de longo prazo, como tendências de aumento ou diminuição da precipitação, além de identificar oscilações sazonais e ciclos climáticos. Um polinômio de grau adequado pode suavizar os dados, reduzindo o impacto de flutuações aleatórias e realçando comportamentos significativos da série temporal. No entanto, a escolha do grau n deve ser criteriosa: um grau muito baixo pode não representar adequadamente a variabilidade dos dados, enquanto um grau muito alto pode resultar em um sobreajuste, modelando o ruído em vez de tendências reais. Para este estudo, foi utilizado um polinômio de grau 3, pois ele apresentou o melhor ajuste dos dados, garantindo um equilíbrio entre suavização das flutuações aleatórias e a fidelidade às séries temporais.

O problema geral de aproximar um conjunto de dados $\{(x_i, y_i) \mid i = 1, 2, \dots, m\}$, por um polinômio algébrico

$$P_n(x) = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0 \quad (39)$$

de grau $n < m - 1$, utilizando o procedimento dos números cúbicos, é tratado de maneira análoga. Escolhemos as constantes $a_0, a_1, \dots, a_n$ para minimizar o erro dos mínimos quadrados

$$\begin{aligned} E &= \sum_{i=1}^m (y_i - P_n(x_i))^2 = \sum_{i=1}^m y_i^2 - 2 \sum_{i=1}^m P_n(x_i) y_i + \sum_{i=1}^m (P_n(x_i))^2 \\ &= \sum_{i=1}^m y_i^2 - 2 \sum_{i=1}^m \left(\sum_{j=0}^n a_j x_i^j \right) y_i + \sum_{i=1}^m \left(\sum_{j=0}^n a_j x_i^j \right)^2 \\ &= \sum_{i=1}^m y_i^2 - 2 \sum_{j=0}^n a_j \left(\sum_{i=1}^m y_i x_i^j \right) + \sum_{j=0}^n \sum_{k=0}^n a_j a_k \left(\sum_{i=1}^m x_i^{j+k} \right) \end{aligned} \quad (40)$$

Como no caso linear, para que E seja minimizado é necessário que $\frac{\partial E}{\partial a_j} = 0$, para cada $j = 0, 1, \dots, n$. Desse modo, para cada j ,

$$0 = \frac{\partial E}{\partial a_j} = -2 \sum_{i=1}^m y_i x_i^j + 2 \sum_{k=0}^n a_k \sum_{i=1}^m x_i^{j+k} \quad (41)$$

Isso fornece as $n + 1$ Equações normais nas $n + 1$ incógnitas a_j ,

$$\sum_{k=0}^n a_k \sum_{i=1}^m x_i^{j+k} = \sum_{i=1}^m y_i x_i^j, \quad \text{para cada } j = 0, 1, \dots, n. \quad (42)$$

É útil escrever as Equações conforme segue:

$$\begin{aligned} a_0 \sum_{i=1}^m x_i^0 + a_1 \sum_{i=1}^m x_i^1 + a_2 \sum_{i=1}^m x_i^2 + \dots + a_n \sum_{i=1}^m x_i^n &= \sum_{i=1}^m y_i x_i^0, \\ a_0 \sum_{i=1}^m x_i^1 + a_1 \sum_{i=1}^m x_i^2 + a_2 \sum_{i=1}^m x_i^3 + \dots + a_n \sum_{i=1}^m x_i^{n+1} &= \sum_{i=1}^m y_i x_i^1 \\ &\vdots \\ a_0 \sum_{i=1}^m x_i^n + a_1 \sum_{i=1}^m x_i^{n+1} + a_2 \sum_{i=1}^m x_i^{n+2} + \dots + a_n \sum_{i=1}^m x_i^{2n} &= \sum_{i=1}^m y_i x_i^n \end{aligned} \quad (43)$$

Estas Equações normais possuem uma única solução contanto que os x_i sejam distintos (Burden; Faires, 1989).

$$\begin{bmatrix} \sum_{i=1}^n x_i^0 & \sum_{i=1}^n x_i^1 & \sum_{i=1}^n x_i^2 & \cdots & \sum_{i=1}^n x_i^n \\ \sum_{i=1}^n x_i^1 & \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i^3 & \cdots & \sum_{i=1}^n x_i^{n+1} \\ \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i^3 & \sum_{i=1}^n x_i^4 & \cdots & \sum_{i=1}^n x_i^{n+2} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \sum_{i=1}^n x_i^n & \sum_{i=1}^n x_i^{n+1} & \sum_{i=1}^n x_i^{n+2} & \cdots & \sum_{i=1}^n x_i^{2n} \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_n \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n y_i x_i^0 \\ \sum_{i=1}^n y_i x_i^1 \\ \sum_{i=1}^n y_i x_i^2 \\ \vdots \\ \sum_{i=1}^n y_i x_i^n \end{bmatrix}$$

O sistema normal pode ser resolvido pelo método de eliminação de Gauss $A^T A x = A^T b$.

Para Lapponi (2005) e Ruggiero; Rocha lopes (1998), o método da Eliminação de Gauss consiste em transformar o sistema linear original num sistema linear equivalente com matriz de coeficientes triangular superior, pois estes são de resolução imediata.

3.5.1.1 Ajuste Polinomial

O ajuste polinomial foi utilizado para representar a variabilidade temporal das máximas anuais de precipitação nas diferentes estações meteorológicas analisadas. Entre os modelos testados, Na Figura 5 o polinômio de grau 3 apresentou o melhor compromisso entre flexibilidade, estabilidade e capacidade de generalização, sendo suficientemente complexo para capturar padrões não lineares sem introduzir instabilidades associadas a modelos de maior grau (Montgomery, 2017).

Por exemplo, na estação de Gabú, o modelo cúbico apresentou $RMSE = 82.66mm$ e $MAE = 58.70mm$, valores inferiores ao modelo de grau 2 ($RMSE = 84.28mm$) e (MAE superior), evidenciando melhor desempenho tanto na penalização de erros extremos ($RMSE$) quanto na magnitude média dos desvios absolutos (MAE). Resultados semelhantes foram observados em outras estações, como Bissau e Catió, indicando consistência do modelo cúbico.

3.5.1.2 Comparação entre Graus

A comparação entre os modelos evidencia três comportamentos distintos:

- *Grau 2 (quadrático)*: apresenta tendência excessivamente suavizada na Figura 5, caracterizando subajuste (*underfitting*), incapaz de representar adequadamente a variabilidade dos dados. Isso se reflete em valores relativamente elevados tanto de $RMSE$ quanto de MAE (Hastie; Tibshirani; Friedman, 2009).
- *Grau 3 (cúbico)*: na Figura 5 apresenta desempenho equilibrado, com redução consistente de $RMSE$ e MAE , indicando melhor ajuste global e menor erro médio absoluto.
- *Grau 4 (quártico)*: apresenta pequenas melhorias nas métricas de erro em alguns casos, porém com comportamento instável e oscilações artificiais, o que compromete a interpretabilidade física do modelo Figura 5.

3.5.1.3 Métricas de Erro

O $RMSE$ é mais sensível a erros de grande magnitude, penalizando fortemente eventos extremos, enquanto o MAE fornece uma medida mais robusta do erro médio absoluto, sendo menos influenciado por outliers.

Os resultados indicam redução consistente de ambas as métricas do grau 2 para o grau 3, evidenciando melhora tanto na representação dos extremos quanto na precisão média do modelo. Por outro lado, os ganhos do grau 4 são marginais, especialmente em termos de MAE , indicando que a complexidade adicional não resulta em melhoria substancial do desempenho médio.

Por exemplo, em estações como Farim (Tabela 2), os valores elevados de $RMSE$ (≈ 151 mm) refletem a alta variabilidade climática da região, enquanto os valores de MAE , embora menores, confirmam a presença de desvios médios significativos.

Estação	RMSE G2	RMSE G3	RMSE G4	MAE G2	MAE G3	MAE G4
Bafatá	68.08	67.70	65.47	53.44	53.52	50.82
Bissau	95.38	92.72	90.81	76.82	73.47	72.27
Bigene	83.70	80.06	71.23	63.30	61.80	52.13
Bolama	115.17	112.98	105.32	91.33	89.67	83.27
Catió	144.58	131.98	131.98	122.52	106.94	106.94
Farim	151.94	151.12	150.64	99.90	98.96	101.74
Gabú	84.28	82.66	82.50	60.68	58.70	58.64
Mansabá	143.68	142.77	142.55	94.81	93.21	92.69
Suzana	142.26	142.08	142.05	114.01	113.16	113.39

Tabela 2 – Métricas de desempenho dos modelos polinomiais

3.5.1.4 Discussão sobre Overfitting

Apesar do modelo de grau 4 apresentar, em alguns casos, menores valores de *RMSE*, observa-se que essa redução nem sempre é acompanhada por diminuições relevantes no *MAE*. Esse comportamento sugere que o modelo passa a ajustar eventos específicos, possivelmente extremos, sem melhorar substancialmente o erro médio geral.

Além disso, o modelo de grau 4 introduz oscilações artificiais, especialmente nas extremidades da série temporal, caracterizando o fenômeno de sobreajuste (*overfitting*), no qual o modelo passa a ajustar o ruído dos dados em vez da tendência real (Hastie; Tibshirani; Friedman, 2009). Esse efeito é visível em estações como Bolama, Bissau e Bigene, onde o grau 4 apresenta curvaturas excessivas.

Por outro lado, o modelo de grau 2 apresenta subajuste (*underfitting*), não sendo capaz de capturar adequadamente a variabilidade interanual, o que se reflete em valores elevados tanto de *RMSE* quanto de *MAE*.

Dessa forma, o modelo de grau 3 apresenta o melhor compromisso entre complexidade e capacidade de generalização, com desempenho consistente em ambas as métricas de erro.

3.5.1.5 Equação Geral do Modelo

O modelo adotado pode ser representado por:

$$P(x) = ax^3 + bx^2 + cx + d \quad (44)$$

onde:

- $P(x)$ = precipitação máxima anual no tempo x ;
- a , b , c e d = coeficientes ajustados pelo método dos mínimos quadrados.

A análise conjunta das estações indica elevada variabilidade da precipitação, característica típica de regiões tropicais influenciadas por sistemas atmosféricos como a Zona de Convergência Intertropical (ZCIT) (IPCC, 2021).




Figura 5 – Comparação entre os ajustes polinomiais de grau 2, grau 3 e grau 4 aplicados às máximas anuais de precipitação nas diferentes estações meteorológicas analisadas.

Os resultados confirmam que o modelo cúbico é o mais adequado, pois equilibra precisão estatística e coerência física. Esse desempenho é evidenciado tanto pela redução do $RMSE$, associada à melhor representação de extremos, quanto pela diminuição do MAE , indicando maior precisão média das estimativas, tornando-o uma abordagem robusta para análise de séries temporais climáticas.

3.5.2 Extrapolação até 2030

3.5.2.1 Limitações da Extrapolação Polinomial

Apesar da utilidade do ajuste polinomial para descrever tendências dentro do intervalo observado, sua aplicação em extrapolações apresenta limitações importantes. Conforme discutido por Montgomery; Peck; Vining (2012), modelos polinomiais podem produzir comportamentos irrealistas fora do domínio dos dados, especialmente nas extremidades da série, onde pequenas variações nos coeficientes podem resultar em grandes divergências nas projeções.

Nesse sentido, as projeções até 2030 devem ser interpretadas com cautela, pois refletem a continuação matemática da tendência ajustada, e não necessariamente a evolução física real do sistema climático.

3.5.2.2 *Diferença em Relação às Projeções Climáticas (CMIP)*

É importante destacar que os resultados apresentados não correspondem a projeções climáticas baseadas em modelos físicos, como aqueles desenvolvidos no âmbito do *Coupled Model Intercomparison Project* (CMIP) (Eyring et al., 2016b).

Diferentemente dos modelos climáticos globais, que consideram interações complexas entre atmosfera, oceanos e forçantes externas, como emissões de gases de efeito estufa, o ajuste polinomial utilizado neste estudo é puramente estatístico e baseado apenas em dados históricos.

Assim, as extrapolações aqui apresentadas não devem ser interpretadas como cenários climáticos futuros, mas sim como tendências matemáticas condicionadas ao comportamento passado da série temporal.

3.5.2.3 *Intervalo de Confiança e Incerteza*

Os gráficos incluem o intervalo de confiança de 95%, que fornece uma estimativa da incerteza associada às projeções. Observa-se que a largura do intervalo aumenta significativamente à medida que se avança no tempo, especialmente após o período observado (pós-2022).

Esse comportamento é esperado e está associado à propagação do erro do modelo, conforme descrito por Weisberg (2014), indicando que a confiabilidade das estimativas diminui progressivamente fora do intervalo de calibração.

Nas estações Catió, Bissau e Bigene, observa-se uma expansão mais acentuada do intervalo de confiança, refletindo maior variabilidade dos dados históricos. Já em estações como Mansabá e Bafatá, embora a tendência seja mais estável, a incerteza ainda cresce de forma relevante na extrapolação.

3.5.2.4 *Avaliações Estatísticas*

O estudo da correlação tem por objetivo medir e avaliar o grau de relação existente entre duas ou mais variáveis aleatórias. O coeficiente de correlação (r), é um índice que varia entre -1 e $+1$, indicando o quanto às diversas medidas obtidas a partir da amostra se ajustam ao modelo matemático proposto. Quanto maior o valor absoluto de r , maior a concordância entre os dados e a curva de regressão Lapponi (2005).

Segundo Lapponi (2005), se o coeficiente de correlação for igual a $+1$, os pares de valores das variáveis fazem parte de uma reta com declividade positiva. À medida que os pares de valores se afastam dessa reta, o coeficiente de correlação diminuirá de $+1$ em direção a -1 , passando pelo valor 0 . O coeficiente de determinação (R^2)

indica o percentual da variância da variável dependente que pode ser explicado pela variável independente.

$$R^2 = \frac{\sum_{i=1}^n (\hat{\mu}_i - \bar{\mu})}{\sum_{i=1}^n (\mu_i - \hat{\mu}_i)}, \quad \text{em que} \quad \bar{\mu} = \frac{1}{n} \sum_{i=1}^n \mu_i. \quad (45)$$

No entanto, o cancelamento parcial dos erros positivos com os negativos pode ocorrer, mascarando o resultado. Para evitar este cancelamento trabalha-se com o quadrado do resíduo e exige-se que $\sum_x r^2(x)$ seja mínimo, o que corresponde ao método dos mínimos quadrados (Quadros; Buske; Cezimbra, 2006).

3.5.2.5 Tendência

Além da correlação, também foi avaliada o comportamento da tendência das séries temporais, e neste caso temos que (Palit; Popovic, 2006): O componente de tendência de uma série temporal, é sua característica de longo prazo se manifesta através do aumento ou diminuição, local ou global dos valores de dados, como consequência de sobreposição de valores verdadeiros de séries temporais, e um componente perturbador, é detectável perseguindo as mudanças nos valores médios em certos intervalos de tempos sucessivos, através do padrão da série temporal (Palit; Popovic, 2006).

A análise de tendências é importante na previsão de séries temporais. Na prática, é realizada usando a técnica de regressão linear e não linear que ajuda satisfatoriamente na identificação do componente de tendência não monótono na série temporal (Palit; Popovic, 2006). Por exemplo, para identificar o caráter da tendência presente em uma série temporal, em nosso estudo usamos caso polinomial de grau $n = 3$, com o objetivo de analisar o comportamento da série e identificar sua tendência, verificando se há aumento ou diminuição ao longo do período analisado (Palit; Popovic, 2006).

$$P_n(x) = ax^n + bx^{n-1} + cx + d \quad \text{tal que} \quad \alpha \neq 0, \quad (46)$$

Isto para garantir que o polinômio é de terceiro grau (Palit; Popovic, 2006).

Para previsão de tendência, a regressão linear ou não linear é mais usada. Isso é baseado no ajuste de linha de tendência de dados de séries temporais usando uma função de terceiro grau (Palit; Popovic, 2006).

$$P_3(x) = ax^3 + bx^2 + cx + d \quad (47)$$

4 RESULTADOS

4.1 Estatística Descritiva da Precipitação da Guiné-Bissau

O mês de maio é caracterizado pelo início do período chuvoso em Guiné-Bissau, como pode ser observado na Figura 6a, predominantemente os volumes mensais acumulados de precipitação não ultrapassam 100 mm. A principal exceção é Catió, onde os acumulados se mantêm acima dos 100 mm entre o período de 1990 até 2010, alcançando valores acima de 350 mm em 1997 e 2001. Após o período de 2010, os valores são coerentes com as demais estações.

Alguns acumulados mais elevados são observados em anos específicos, como 160 mm em Bolama (1999), e anos onde o mês de maio foi mais chuvoso, como por exemplo em 2010 e 2014. Ao avaliar os padrões médios dos valores de precipitação, se observa que os valores mínimos para maio se mantêm em 0.0 mm (Tabela 3), enquanto que os valores médios oscilam entre 6 e 27 mm (Tabela 4) e máximos entre 44 e 360 mm (Tabela 5). Esse padrão da precipitação contribui para que os valores de desvio padrão flutuam entre 11 e 100 mm (Tabela 6).

Junho, segundo mês do período chuvoso em Guiné-Bissau, é visto como o mês onde a chuva já começa a intensificar (Figura 6b), predominantemente os volumes mensais acumulados de precipitação não ultrapassam 400 mm. Tendo visto algumas exceções como no caso de Catió e Bissau, no caso de Catió os acumulados se mantêm acima dos 400 mm entre o período de 1990 até 2010, alcançando valor de 800 mm em 1993 e acima de 800 mm em 2003. E já no caso de Bissau os acumulados superam o valor de 400 mm no ano de 1997. Após o período de 2009 para o caso de Catió e 1997 no caso de Bissau, os valores são coerentes com as demais estações.

Estação	maio	junho	julho	agosto	setembro	outubro	novembro
Bafatá	0.0	0.0	118.6	186.1	192.0	39.4	0.0
Bigene	0.0	11.3	44.6	80.2	48.1	13.4	0.0
Bissau	0.0	29.4	137.7	242.4	122.0	32.1	0.0
Bolama	0.0	33.1	259.5	402.1	230.2	67.4	0.0
Catió	0.0	32.9	97.5	195.3	88.5	0.0	0.0
Farim	0.0	10.0	49.0	195.5	146.6	0.0	0.0
Gabú	0.0	67.4	56.2	186.2	165.4	24.2	0.0
Mansabá	0.0	0.0	0.0	187.0	108.4	49.1	0.0
Suzana	0.0	3.5	182.1	277.6	144.3	53.8	0.0

Tabela 3 – Valores mínimos para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).

É possível observar alguns acumulados mais elevados especificamente, também com o valor que atingem 400 mm em Bolama (2008), enquanto os demais anos que se mantêm abaixo dos 400 mm. Ao avaliar os padrões médios dos valores de precipitação, observa-se que os valores mínimos para junho oscilam entre 0.0 (Bafatá e Mansabá) e 67 mm (Gabú) (Tabela 3), enquanto que os valores médios oscilam entre 40 (Suzana) e 362 mm/mês (Catió) (Tabela 4) e máximos entre 200 (Bigene) e 826 mm (Catió) (Tabela 5). Como o padrão da precipitação aumentou quando comparado com maio, isso contribuiu para que os valores de desvio padrão sejam maiores (entre 39 e 233 mm).

Considerado como o primeiro mês em que os valores de precipitação são mais elevados em Guiné-Bissau, julho é o terceiro mês do período chuvoso onde a chuva se estabelece com mais intensidade (Figura 6c), os volumes mensais acumulados de precipitação oscilam na maior parte dos anos entre 200 e 600 mm. Evidencia-se que em alguns casos como Bolama e Catió os valores se mantêm acima de 600 mm.

Estação	maio	junho	julho	agosto	setembro	outubro	novembro
Bafatá	23.2	127.1	264.3	354.7	354.4	151.2	2.8
Bigene	6.9	75.0	184.9	242.8	202.9	96.2	3.3
Bissau	18.1	148.0	373.9	471.0	373.1	196.6	15.6
Bolama	25.6	190.0	532.4	616.2	420.0	202.9	19.0
Catió	106.3	361.6	520.6	460.9	263.0	61.7	3.7
Farim	6.5	107.2	260.2	407.4	347.5	105.2	1.1
Gabú	27.8	161.8	265.1	375.6	341.7	129.6	3.6
Mansabá	12.0	119.7	306.8	399.3	327.4	149.8	7.6
Suzana	20.7	39.8	385.8	557.9	349.0	152.4	22.7

Tabela 4 – Valores médios para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).

Em caso de Bolama onde os acumulados ficaram acima dos 600 mm em diferentes períodos ao longo da série e ficou também próximo de 800 mm em 2003, 2004, 2016 e 2018. E já no caso de Catió os acumulados atingiram 600 mm no ano 1991, e ultrapassam o valor de 600 mm nos anos de 1992, 1995 a 2001, 2004, 2008, 2009, 2017 e 2020.

E também pode-se observar alguns acumulados mais elevados específicos, com valores acima de 600 mm em Bissau (2004 e 2020) e atingindo 600 mm em (2012). E também Mansabá e Suzana que conseguiram o valor acima de 800 mm em 2004 e 2012, respectivamente.

Ao avaliar os padrões médios dos valores de precipitação, observa-se que os valores mínimos para julho oscilaram entre 0.0 (Mansabá) e 260 mm (Bolama) (Tabela 3), enquanto que os valores médios oscilam entre 185 (Bigene) e 532 mm/mês (Bolama) (Tabela 4) e máximos entre 449 (Gabú) e 947 mm (Catió) (Tabela 5). O padrão observado na distribuição da precipitação influencia na variação nos valores do desvio padrão, que oscilam entre 94 e 211 mm (Tabela 6).

Agosto é o quarto mês do período chuvoso em Guiné-Bissau, e tem a característica de ser um dos meses mais chuvoso do país (Figura 6d), e com as chuvas muito intensas e fortes com a presença de trovões, raios e ventos fortes, também é predominante os volumes mensais acumulados de precipitação que oscilam na maior parte dos anos das séries temporais com valores acima de 600 mm. Também tem algumas situações como no caso de Bolama, Farim, Mansabá e Suzana com acumulados acima dos 800 mm no período.

Pode-se observar um acumulado mais elevado que ficou acima de 1000 mm em Mansabá em (2004). E também no caso de Farim, Suzana e Bolama que conseguiram valores acima dos 800 mm. Apenas Bigene que indicou valores mais baixos, que não

ultrapassaram 400 mm ao longo do período em análise. E para avaliar os padrões médios dos valores de precipitação, observa-se que os valores mínimos para agosto oscilaram entre 80 (Bigene) e 402 mm (Bolama) (Tabela 3), enquanto que os valores médios oscilam entre 243 (Bigene) e 616 mm/mês (Bolama) (Tabela 4) e máximos entre 546 (Bigene) e 1044 mm (Mansabá) (Tabela 5). O padrão observado na distribuição da precipitação influencia diretamente na variabilidade dos dados, resultando em valores de desvio padrão que oscilam entre 98 e 168 mm, conforme apresentado na (Tabela 6). Essa variação reflete nas quantidades de chuva registradas ao longo do período analisado.

Em setembro os acumulados mensais de precipitação começam a diminuir, quando comparados com agosto, os valores ficam concentrados entre 200 e 600 mm (Figura 6e).




Figura 6 – Séries temporais mensais dos acumulados de precipitação (mm) observados para os meses de maio a novembro para as estações apresentadas na Tabela 1: a) maio; b) junho; c) julho; d) agosto; e) setembro; f) outubro; e g) novembro. Fonte: dos autores (2025).

Com as exceções de Catió, Bissau, Bolama, Gabú, Farim e Suzana. Alguns acumulados mais elevados são observados em anos específicos para estas estações, e como na estação de Catió os acumulados passaram de 600 mm em (2010). Em caso de Bolama os acumulados ficam acima dos 600 mm entre o período de 1994 e 2020 e ainda atingem 600 mm em 2018. E no caso de Bissau os acumulados ficam de 600 mm em 1994 e atingiram 600 mm em 1999. E ainda os acumulados ficaram acima de 600 mm em Gabú (2003). No caso de Farim os acumulados ultrapassam 600 mm e bateu o recorde atingindo 1200 mm em 2018. Para o caso de Suzana onde os acumulados ficam acima dos 600 mm em 2010.

Assim como ocorreu em agosto, Bigene foi a exceção, pois na maior parte do período (entre 2005 até 2022) os valores foram mais baixos que as demais estações, se mantendo próximo de 200 mm.

Estação	maio	junho	julho	agosto	setembro	outubro	novembro
Bafatá	124.5	225.8	477.0	588.1	555.4	381.7	61.0
Bigene	45.5	199.9	479.9	545.9	550.2	357.5	46.4
Bissau	142.0	481.3	627.0	767.3	736.6	343.5	142.7
Bolama	168.7	398.3	810.0	989.7	683.6	467.1	98.8
Catió	363.5	826.3	947.3	718.2	674.9	192.6	78.5
Farim	44.0	232.7	743.3	949.2	1198.0	358.6	31.0
Gabú	90.5	304.5	449.2	690.8	613.3	270.9	64.3
Mansabá	66.4	256.6	655.8	1043.9	520.9	389.3	86.5
Suzana	83.0	210.2	622.8	957.6	621.6	373.8	240.0

Tabela 5 – Valores máximos para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).

E para avaliar os padrões médios dos valores de precipitação, observa-se que os valores mínimos para setembro, oscilam entre 48 (Bigene) e 230 mm (Bolama) (Tabela 3), enquanto que os valores médios oscilam entre 203 (Bigene) e 420 mm/mês (Bolama) (Tabela 4) e máximos entre 521 (Mansabá) e 1198 mm (Farim) (Tabela 5). Esse padrão da precipitação contribui para que os valores de desvio padrão variem entre 81 e 189 mm (Tabela 6). A dinâmica da precipitação observada no período estudado exerce domínio significativa sobre a variabilidade dos dados, o que se reflete nos valores de desvio padrão, variando de 81 e 189 mm, conforme evidenciado na (Tabela 6). Esses resultados indicam a heterogeneidade do regime pluviométrico na região analisada.

Conforme se direciona para o final do período de chuvoso, fica evidenciado que a distribuição da precipitação ao longo da série se torna mais caótica, conforme é observado para o mês de outubro (Figura 6f), é os volumes mensais acumulados de

precipitação não ultrapassam 400 mm.

Algumas exceções são observadas, como no caso de Bolama, onde os acumulados ficam acima dos 400 mm entre o período de 1992 e 1999. Ainda para os outros anos e estações os valores oscilam próximos a 300 mm, como no caso de Suzana, Bissau, Mansabá, Bigene, Bafatá e Farim.

Entretanto o acumulados mais baixos são destacados em anos específicos, como 0.0 mm em Catió no período entre 1990 até 2007. E ainda em Farim que os acumulados ficaram 0.0 mm em 2019. Ao avaliar os padrões médios dos valores de precipitação, se observa que os valores mínimos para outubro, que oscilam entre 0.0 (Catió e Farim) e 67 mm (Bolama) (Tabela 3), enquanto que os valores médios oscilam entre 62 (Catió) e 203 mm/mês (Bolama) (Tabela 4) e máximos entre 193 (Catió) e 467 mm (Bolama) (Tabela 5). A análise da distribuição das chuvas revela um comportamento irregular ao longo da avaliação deste mês, o padrão de precipitação, contribui para uma oscilação no índice mensal, retrata-se nos valores do desvio padrão que variam entre 64 e 100 mm, mostrado na (Tabela 6).

O mês de Novembro caracteriza o término do período chuvoso em Guiné-Bissau (Figura 6g), onde os volumes mensais acumulados de precipitação normalmente não ultrapassam 100 mm. Com exceção de Bolama, onde os acumulados ficaram acima dos 100 mm para os anos de 2009 e 2012.

Alguns anos se destacam pelo registro de acumulados superiores, e observados como 140 mm em Bissau no período entre 2009. Ainda em 2009 a estação de Suzana indicou valores próximos de 80 mm, assim como Catió em 2012. Ao avaliar os padrões médios dos valores de precipitação, se observa que os valores mínimos para novembro, se mantém em 0.0 mm (Tabela 3), enquanto que os valores médios oscilam entre 1 (Farim) e 23 mm/mês (Suzana) (Tabela 4) e máximos entre 31 (Farim) e 240 mm (Suzana) (Tabela 5). A variabilidade na precipitação para este mês, analisado e evidencia um comportamento irregular, típico de regiões com forte influência de padrões climáticos sazonais. Essa irregularidade na distribuição pluviométrica interfere diretamente no dados mensal, e resultando em uma ampla faixa de variação nos valores de desvio padrão. E na (Tabela 6), esses valores flutuam entre 5 e 54 mm.

Estação	maio	junho	julho	agosto	setembro	outubro	novembro
Bafatá	32.0	49.0	94.0	97.7	81.4	77.4	10.9
Bigene	11.4	55.1	101.3	105.1	97.0	75.6	9.2
Bissau	28.2	106.0	125.9	121.7	126.7	77.3	31.3
Bolama	36.8	77.2	167.8	128.3	111.8	100.2	27.6
Catió	103.0	233.2	211.2	147.1	136.6	63.8	15.0
Farim	12.1	69.7	133.5	168.0	189.1	79.5	5.4
Gabú	28.0	54.6	94.8	101.7	116.4	64.8	11.5
Mansabá	18.2	59.5	140.6	157.7	119.2	85.1	19.3
Suzana	30.3	38.7	113.7	158.2	112.2	76.2	54.1

Tabela 6 – Valores de desvios padrões para a precipitação (mm) durante os meses de maio a novembro no período de 1990 a 2022 para os dados observados. Fonte: dos autores (2025).

4.2 A Aplicação da Modelagem Matemática

A modelagem matemática desempenha um papel fundamental em diversas áreas do conhecimento e da prática. Sua importância reside na capacidade de transformar problemas do mundo real para uma linguagem matemática, permitindo análise, compreensão, previsão e tomada de decisões mais eficientes. O modelo usado para ajustar as curvas da precipitação mensal ao longo dos anos, é um polinômio de terceira ordem, para o presente caso é mais adequado para o estudo comportamental da precipitação nas regiões do país. A análise integrada da distribuição mensal da precipitação nas diferentes estações meteorológicas da Guiné-Bissau evidenciou forte sazonalidade pluviométrica, característica do clima tropical da África Ocidental, fortemente influenciado pela atuação sazonal da Zona de Convergência Intertropical (ZCIT) e pela dinâmica da monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024). Os resultados obtidos a partir dos boxplots, médias climatológicas, desvios padrão e estatísticas descritiva permitiram identificar padrões consistentes de variabilidade temporal, dispersão interanual e ocorrência de eventos extremos de precipitação.

4.2.1 Estação de Bafatá

A distribuição mensal da precipitação na estação de Bafatá (Figura 7a) evidencia um regime pluviométrico fortemente sazonal, com marcada distinção entre a estação seca e a estação chuvosa. Os boxplots (ou diagrama de caixas) associados à média climatológica e ao desvio padrão mostram claramente a evolução temporal da precipitação ao longo do ciclo anual, permitindo avaliar simultaneamente tendência central, dispersão, variabilidade interanual e ocorrência de eventos extremos (Diedhiou et al., 2018).

Os meses de janeiro a abril apresentam precipitação praticamente nula, com medianas próximas de zero, intervalos interquartis extremamente reduzidos e baixa dispersão dos dados. Esse comportamento indica elevada estabilidade climática durante a estação seca, com pequena variabilidade interanual e ausência significativa de eventos extremos. Nesses meses, o desvio padrão também permanece muito baixo, indicando que os totais de precipitação variam pouco entre estes meses.

O início da estação chuvosa ocorre em maio segundo Mendes; Fragoso (2023), quando se observa aumento gradual da precipitação, acompanhado por expansão do intervalo interquartil (IQR) (Figura 7a) e aumento da dispersão dos dados. A mediana ainda permanece relativamente baixa, indicando que a transição do regime chuvoso ocorre de forma progressiva. A presença de outliers nesse período evidencia a ocorrência de eventos isolados de precipitação intensa, típicos da fase inicial da atuação da monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024).

A partir de junho ocorre uma transição efetiva da estação chuvosa, com elevação expressiva da média climatológica e da mediana. O aumento significativo do intervalo interquartil demonstra maior variabilidade interanual da precipitação, indicando que os volumes mensais variam consideravelmente de um ano para outro. O desvio padrão também aumenta substancialmente nesse período, refletindo maior instabilidade atmosférica e intensificação da atividade convectiva associada à migração sazonal da Zona de Convergência Intertropical (ZCIT) (Berthou et al., 2019; Tanimoune et al., 2024).

O pico da monção ocorre entre agosto e setembro Mendes; Fragoso (2023), meses em que se registram os maiores valores de precipitação média (354,7 ; 354,4) e mediana (340,4 ; 335,1) (Tabela 6). Nesses meses, os boxplots na (Figura 7a) apresentam caixas mais altas e whiskers (“ou bigodes” são as linhas que se estendem para fora da caixa central) mais extensos, indicando elevada dispersão dos dados e forte variabilidade interanual. O intervalo interquartil elevado demonstra que a precipitação apresenta ampla faixa de variação entre os anos.

A ampla faixa de desvio padrão observada entre julho e setembro confirma a elevada variabilidade da precipitação durante o pico da estação chuvosa. Isso indica que os totais pluviométricos apresentam grande sensibilidade às flutuações atmosféricas regionais e à intensidade da monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024).

A presença de valores extremos (outliers) Figura 7a em diversos meses da estação chuvosa demonstra a ocorrência de eventos intensos de precipitação. Em agosto, por exemplo, observam-se máximos elevados, associados a episódios convectivos severos (Tanimoune et al., 2024; Sylla et al., 2018; Diedhiou et al., 2018). Esses extremos são importantes indicadores de variabilidade climática e reforçam a ocorrência de precipitações excepcionalmente intensas durante o pico da monção.

Os resultados evidenciam que a estação de Bafatá apresenta forte sazonalidade pluviométrica, elevada variabilidade interanual durante a estação chuvosa e ocorrência frequente de eventos extremos, período dominado pela atuação intensa da ZCIT e dos sistemas convectivos tropicais da África Ocidental.

4.2.2 Estação de Bigene

A distribuição mensal da precipitação na estação de Bigene evidencia um regime pluviométrico tropical fortemente sazonal, caracterizado por uma estação seca bem definida entre novembro e abril e uma estação chuvosa concentrada entre maio e outubro. A análise integrada dos boxplots Figura 7b, média climatológica, desvio padrão e métricas estatísticas permite compreender a dinâmica temporal da precipitação, a variabilidade interanual e o comportamento dos eventos extremos (Klutse et al., 2021).

Os meses de janeiro a abril apresentam precipitação praticamente nula, com medianas iguais ou muito próximas de zero e intervalos interquartis extremamente reduzidos. Esse comportamento indica elevada estabilidade climática durante a estação seca, com baixa variabilidade interanual.

O início da estação chuvosa ocorre em maio, como mostra na (Figura 7b), quando se observa aumento gradual da precipitação associado à atuação inicial da monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024). Nesse período, a mediana aumenta discretamente e o intervalo interquartil começa a se expandir, indicando crescimento da variabilidade da precipitação. A presença de outliers em maio evidencia ocorrência de eventos isolados de chuva intensa, específicos da fase de transição climática.

A partir de junho ocorre a transição efetiva do regime chuvoso, acompanhado por elevação significativa da média climatológica e da mediana. O aumento do intervalo interquartil (IQR) demonstra maior dispersão da precipitação entre os anos, refletindo elevada variabilidade interanual. O crescimento da amplitude dos whiskers confirma que os totais mensais passam a apresentar maior heterogeneidade durante a estação úmida Figura 7b.

O pico da monção ocorre em agosto, mês em que a média climatológica atinge aproximadamente 250 mm. Nesse período, os boxplots apresentam elevada amplitude vertical, indicando forte dispersão dos dados. A mediana elevada demonstra persistência de altos volumes pluviométricos, enquanto o amplo intervalo interquartil revela grande variabilidade entre os meses analisados.

A faixa sombreada correspondente ao desvio padrão torna-se substancialmente mais ampla entre julho e setembro, indicando elevada instabilidade atmosférica e forte variabilidade interanual durante o pico da estação chuvosa. Esse comportamento reflete a influência dos sistemas convectivos tropicais e da migração sazonal da Zona de Convergência Intertropical (ZCIT) (Berthou et al., 2019; Tanimoune et al., 2024).

Os valores extremos (outliers) observados praticamente em todos os meses da estação chuvosa, demonstram ocorrência frequente de eventos intensos de precipitação. Em agosto e setembro são observados máximos superiores a 500 mm, indicando episódios extremos associados à intensificação da atividade convectiva tropical. Esses eventos extremos contribuem diretamente para o aumento do desvio padrão (105,2 ; 97,1), uma vez que elevam significativamente a dispersão dos dados.

Os testes estatísticos complementares revelam importantes características das distribuições analisadas. O teste de Shapiro-Wilk aplicado aos dados observados indica rejeição da normalidade em vários meses da estação chuvosa excepto o mês de agosto. Esse comportamento reflete a assimetria positiva típica das distribuições pluviométricas tropicais influenciadas por eventos extremos.

Por tanto, a estação de Bigene apresenta forte sazonalidade pluviométrica, elevada variabilidade interanual durante a estação chuvosa e ocorrência frequente de eventos extremos.

4.2.3 Estação de Bissau

A distribuição mensal da precipitação na estação de Bissau evidencia um regime pluviométrico tropical fortemente sazonal, caracterizado por uma estação seca bem definida entre novembro e abril e uma estação chuvosa concentrada entre maio e outubro. A análise conjunta dos boxplots (Figura 7c), média climatológica, desvio padrão e métricas estatísticas permite identificar padrões de variabilidade sazonal, dispersão interanual e ocorrência de eventos extremos associados à dinâmica da monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024).

Os meses secos apresentam medianas próximas de zero, intervalos interquartis extremamente reduzidos e whiskers curtos, indicando baixa dispersão dos dados e elevada estabilidade climática. O desvio padrão reduzido nesse período demonstra pequena variabilidade interanual da precipitação, evidenciando consistência dos baixos volumes pluviométricos observados durante a estação seca.

A Figura 7c mostra o início da estação chuvosa que ocorre em maio, quando a média climatológica começa a aumentar gradualmente. Nesse período, observa-se expansão inicial do intervalo interquartil (IQR), indicando aumento da variabilidade da precipitação entre os anos e meses analisados. A mediana permanece relativamente baixa em maio, sugerindo que o começo do regime chuvoso ainda ocorre de forma irregular e intermitente.

A partir de junho ocorre intensificação significativa da precipitação, refletida pela elevação simultânea da média climatológica, da mediana e da amplitude dos boxplots. O aumento do intervalo interquartil demonstra crescimento da variabilidade interanual, indicando maior dispersão dos totais pluviométricos entre diferentes meses do ano. Os whiskers mais extensos observados nesse período confirmam aumento da amplitude

da precipitação mensal.

O pico da monção ocorre em agosto, quando a média climatológica atinge aproximadamente 470 mm. Nesse mês, Figura 7c os boxplots apresentam elevada amplitude vertical, indicando forte variabilidade dos dados. Na Figura 7c a mediana elevada demonstra persistência de elevados volumes de precipitação durante o pico da estação chuvosa. O amplo intervalo interquartil observado entre julho e setembro evidencia elevada variabilidade interanual, característica das regiões tropicais sob influência direta da Zona de Convergência Intertropical (ZCIT) (Berthou et al., 2019; Tanimoune et al., 2024).

A faixa correspondente ao desvio padrão torna-se substancialmente mais ampla entre junho e setembro, demonstrando forte dispersão da precipitação em torno da média climatológica. Isso indica elevada instabilidade atmosférica e grande sensibilidade da precipitação às flutuações da monção da África Ocidental e aos sistemas convectivos tropicais (Berthou et al., 2019; Sylla et al., 2018).

A ocorrência de valores extremos (outliers) é particularmente evidente entre maio, junho, setembro, outubro e novembro. Em setembro, observam-se máximos superiores a 700 mm, indicando eventos extremos intensos associados à atividade convectiva severa. Esses eventos extremos aumentam significativamente a dispersão estatística da série, influenciando diretamente o crescimento do desvio padrão (126,8).

O teste de Shapiro-Wilk aplicado dados observados indica que parte das distribuições não segue normalidade, principalmente nos meses chuvosos. Valores de $p < 0.05$ levam à rejeição da hipótese nula de normalidade, refletindo a forte assimetria positiva típica das séries pluviométricas tropicais influenciadas por eventos extremos. Em alguns meses menos úmidos, entretanto, observa-se não rejeição da normalidade devido à menor dispersão dos dados.

Pois, os resultados mostram que a estação de Bissau apresenta forte sazonalidade pluviométrica, elevada variabilidade interanual e ocorrência frequente de eventos extremos durante a estação chuvosa.

4.2.4 Estação de Bolama

A distribuição mensal da precipitação na estação de Bolama evidencia um regime pluviométrico tropical fortemente sazonal, caracterizado por uma estação seca bem definida entre novembro e abril e uma estação chuvosa intensa entre maio e outubro. A análise integrada dos boxplots, média climatológica, desvio padrão, métricas estatísticas e testes de hipóteses demonstra elevada variabilidade sazonal e interanual da precipitação, sobretudo durante o auge da monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024).

Durante os meses secos, as medianas permanecem próximas de zero, os intervalos interquartis são extremamente reduzidos e os whiskers apresentam pequena

amplitude, indicando elevada estabilidade climática e baixa variabilidade interanual da precipitação. O desvio padrão praticamente nulo nesse período confirma a predominância de condições atmosféricas secas e homogêneas.

O início da estação chuvosa ocorre em maio como mostra na (Figura 7d), quando se observa aumento gradual da média climatológica e expansão inicial dos boxplots. A mediana ainda relativamente baixa nesse mês indica que o estabelecimento da precipitação ocorre de forma progressiva. O aumento do intervalo interquartil demonstra crescimento da dispersão dos dados entre os anos e meses analisados, refletindo variabilidade interanual associada à transição sazonal (Berthou et al., 2019; Tanimoune et al., 2024).

A partir de junho ocorre intensificação acentuada da precipitação, com aumento expressivo da média climatológica, da mediana e da amplitude dos boxplots (Figura 7d). O intervalo interquartil torna-se significativamente mais amplo entre julho e setembro, evidenciando elevada dispersão dos totais pluviométricos e forte variabilidade interanual. Esse comportamento indica maior instabilidade atmosférica durante o período de atuação mais intensa da monção (Tanimoune et al., 2024; Klutse et al., 2021).

O pico da estação chuvosa ocorre em agosto, quando a média climatológica ultrapassa aproximadamente 600 mm. Nesse período, os boxplots apresentam elevada amplitude vertical, whiskers longos e grande expansão do intervalo interquartil, demonstrando forte variabilidade da precipitação. A mediana elevada confirma persistência de altos volumes pluviométricos durante o ponto mais alto da monção (Tanimoune et al., 2024; Klutse et al., 2021).


A faixa correspondente ao desvio padrão apresenta forte expansão entre julho e setembro, indicando elevada dispersão dos dados em torno da média climatológica. Isso demonstra que os totais mensais de precipitação variam substancialmente entre os anos analisados, refletindo elevada variabilidade interanual que pode ser associada aos sistemas convectivos tropicais e às oscilações da Zona de Convergência Intertropical (ZCIT) (Berthou et al., 2019; Tanimoune et al., 2024).

A ocorrência de eventos extremos é particularmente evidente durante os meses de máxima precipitação. Observam-se diversos outliers acima dos whiskers em meses como maio, agosto, outubro e novembro, e especialmente em agosto, quando os totais pluviométricos extremos se aproximam de 1000 mm. Esses extremos indicam ocorrência de episódios convectivos severos e precipitações excepcionais, que podem ser indicado ao ponto mais alto da monção tropical.


A análise do teste de Shapiro-Wilk demonstra comportamento distinto entre as séries observadas. Em diversos meses como; maio, outubro e novembro, os valores de $p < 0.05$ levam à rejeição da hipótese nula de normalidade, indicando distribuições assimétricas influenciadas pela ocorrência de extremos pluviométricos. Em alguns meses tais como; junho, julho, agosto e setembro, o teste não rejeita normalidade,

sugerindo comportamento aproximadamente gaussiano em determinadas condições atmosféricas.


Deste modo, a estação de Bolama apresenta forte sazonalidade pluviométrica, elevada variabilidade interanual e ocorrência frequente de eventos extremos durante o auge da monção. A combinação entre ampla dispersão dos boxplots, elevados desvios padrão, grandes intervalos interquartis e presença de numerosos outliers evidencia a elevada complexidade atmosférica da região costeira tropical.




(a) Estação de Bafatá



(b) Estação de Bigene




(c) Estação de Bissau




(d) Estação de Bolama


Figura 7 – Boxplot de séries mensais ao longo do anual dos acumulados de precipitação (mm), para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).




(a) Estação de Catió




(b) Estação de Farim



(c) Estação de Gabú



(d) Estação de Mansabá



(e) Estação de Suzana

Figura 8 – Boxplot séries mensais ao longo do anual dos acumulados de precipitação (mm), para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá e)Suzana. Fonte: dos autores (2025)

4.2.5 Estação de Catió

A distribuição mensal da precipitação na estação de Catió evidencia um regime pluviométrico tropical fortemente sazonal, caracterizado por uma estação seca bem definida entre novembro e abril e uma estação chuvosa intensa entre maio e outubro. A análise dos boxplots, associada à média climatológica, ao desvio padrão e às métricas estatísticas, demonstra elevada variabilidade temporal e interanual da precipitação, especialmente durante os meses de maior atuação da Monção da África Ocidental.

Durante a estação seca, os valores médios de precipitação permanecem próximos de zero, com medianas praticamente nulas, intervalos interquartis reduzidos e whiskers muito curtos, indicando forte estabilidade climática e baixa variabilidade interanual. A reduzida dispersão dos dados nesse período confirma a predominância de

condições atmosféricas secas e homogêneas.

O início da estação chuvosa ocorre em maio, quando a média climatológica aumenta significativamente e os boxplots passam a apresentar maior amplitude vertical (Figura 8a). A mediana eleva-se progressivamente, refletindo um crescimento gradual da precipitação sazonal. O aumento do intervalo interquartil demonstra crescimento da variabilidade entre os anos, indicando que o início da estação chuvosa apresenta comportamento temporal relativamente irregular.

Entre junho e setembro ocorre a fase mais intensa da estação chuvosa. Os boxplots tornam-se amplos, os whiskers apresentam grande extensão e o intervalo interquartil aumenta substancialmente, evidenciando forte variabilidade interanual da precipitação. A mediana elevada nesse período demonstra persistência de altos totais pluviométricos.

O pico da monção ocorre em julho e agosto, quando a média climatológica ultrapassa aproximadamente 520 mm. Nesses meses observam-se a maior expansão do desvio padrão, indicando elevada dispersão dos totais mensais em torno da média climatológica. Os boxplots apresentam grande amplitude e whiskers extremamente longos, demonstrando elevada instabilidade pluviométrica e forte influência de eventos convectivos intensos associados à atuação da Zona de Convergência Intertropical (ZCIT) (Berthou et al., 2019; Tanimoune et al., 2024; Diedhiou et al., 2018).

Em agosto, apesar de ligeira redução da média climatológica, a variabilidade permanece elevada. O intervalo interquartil continua amplo e os whiskers ainda apresentam elevada extensão, indicando persistência da forte variabilidade interanual durante o pico alto da estação chuvosa.

A ocorrência de eventos extremos é evidenciada pela presença de múltiplos outliers acima dos whiskers, especialmente entre maio, setembro e novembro (Figura 8a). Em julho observam-se whiskers que ficam próximos a 900 mm, enquanto em setembro os outliers ultrapassam aproximadamente 650 mm. Esses valores extremos indicam episódios convectivos severos e precipitações excepcionalmente intensas durante o período monçônico (Berthou et al., 2019; Tanimoune et al., 2024; Diedhiou et al., 2018).

A faixa sombreada correspondente ao desvio padrão apresenta forte expansão entre junho e setembro, demonstrando grande dispersão estatística da precipitação mensal. Isso indica que os totais pluviométricos variam significativamente entre os anos, caracterizando elevada variabilidade interanual que pode ser influenciada pela monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024).

A análise do teste de Shapiro-Wilk revela comportamento predominantemente não normal das distribuições pluviométricas. Em junho, julho e agosto, os dados não rejeitam a normalidade, enquanto que em maio, os dados observados apresentaram $p \approx 0.0014$, levando à rejeição da hipótese de normalidade. Em setembro, o teste também indicou rejeição da normalidade para os dados observados ($p \approx 0.0030$). Esses resultados

refletem forte assimetria das distribuições, causada principalmente pela ocorrência de eventos extremos.

A estação de Catió apresenta elevada variabilidade sazonal e interanual da precipitação, forte influência de eventos extremos e grande complexidade atmosférica durante o maior pico da monção da África Ocidental. A ampla dispersão dos boxplots, os elevados desvios padrão, os grandes intervalos interquartis e a presença de numerosos outliers evidenciam a elevada instabilidade pluviométrica da região.

4.2.6 Estação de Farim

A distribuição mensal da precipitação na estação de Farim evidencia um comportamento climático tropical fortemente sazonal, marcado por uma estação seca muito pronunciada entre novembro e abril e uma estação chuvosa intensa entre maio e outubro. A análise conjunta dos boxplots (Figura 8b), da média climatológica, do desvio padrão e das métricas estatísticas demonstra elevada variabilidade temporal da precipitação, especialmente durante o auge da Monção da África Ocidental.

Nos meses secos, os valores de precipitação permanecem próximos de zero, com medianas praticamente nulas, intervalos interquartis extremamente reduzidos e whiskers curtos, indicando baixa variabilidade interanual e forte estabilidade atmosférica. Essa configuração estatística demonstra predominância de condições secas persistentes ao longo do período climatológico.

O início da estação chuvosa ocorre em maio, quando a média climatológica apresenta crescimento gradual e os boxplots começam a ampliar sua dispersão vertical. Nesse período observa-se aumento do intervalo interquartil e do comprimento dos whiskers (Figura 8b), refletindo maior heterogeneidade entre os anos analisados e o estabelecimento progressivo da atividade convectiva regional.

Entre junho e setembro ocorre a fase mais intensa da estação chuvosa. A média climatológica aumenta substancialmente, atingindo seu pico em agosto, com valores superiores a aproximadamente 400 mm (Figura 8b). Os boxplots tornam-se significativamente mais amplos, indicando aumento expressivo da variabilidade pluviométrica.

O mês de julho apresenta forte elevação da precipitação média, associada à expansão da faixa correspondente ao desvio padrão. O aumento do desvio padrão evidencia grande dispersão dos dados em torno da média climatológica, indicando elevada variabilidade interanual da precipitação. O intervalo interquartil torna-se bastante amplo, demonstrando grande concentração de valores distribuídos em faixas extensas de precipitação.

Em agosto ocorre o pico pluviométrico anual, acompanhado do maior alargamento da faixa de desvio padrão. Isso indica elevada instabilidade climática e forte irregularidade interanual dos totais precipitados. Os whiskers longos e os boxplots extensos revelam que os totais mensais variam significativamente entre os diferentes anos ob-

servados.

Em setembro observa-se redução gradual da média climatológica, embora os valores permaneçam elevados. A persistência de grande dispersão dos dados demonstra continuidade da influência monçônica e da ocorrência de eventos convectivos intensos (Tanimoune et al., 2024; Sylla et al., 2018).

Os extremos pluviométricos são claramente identificados pela presença de diversos outliers acima dos whiskers, especialmente entre julho e setembro. Em setembro destaca-se um evento extremo superior a aproximadamente 1200 mm, indicando ocorrência excepcionalmente intensa de precipitação. Em agosto observam-se outliers próximos de 950 mm, enquanto em julho os extremos ultrapassam aproximadamente 700 mm. Esses resultados confirmam elevada frequência de eventos severos associados à dinâmica convectiva tropical (Tanimoune et al., 2024; Sylla et al., 2018).

A análise do teste de Shapiro-Wilk revela predominância de distribuições não normais, excepto o mês de junho que os dados não rejeita normalidade com $p > 0.063$. Em maio, os dados observados apresentaram $p < 0.001$, levando à rejeição da hipótese de normalidade. Em julho, os dados também rejeição da normalidade ($p \approx 0.0044$ e $p \approx 0.0118$, respectivamente). Da mesma forma em setembro, os dados também rejeitaram a hipótese de normalidade ($p < 0.001$). Esses resultados indicam forte assimetria das distribuições pluviométricas, causada principalmente pela ocorrência de eventos extremos.

Os resultados demonstram que a estação de Farim apresenta elevada variabilidade sazonal e interanual da precipitação, forte influência de eventos extremos e comportamento pluviométrico altamente irregular durante o pico da monção africana. A ampla dispersão dos boxplots, os elevados desvios padrão, os grandes intervalos interquartis e a presença de outliers extremos evidenciam a complexidade climática da região.

4.2.7 Estação de Gabú

A distribuição mensal da precipitação na estação de Gabú evidencia um regime pluviométrico tropical fortemente sazonal, caracterizado por uma estação seca bem definida entre novembro e abril e uma estação chuvosa concentrada entre maio e outubro. A análise integrada dos boxplots (Figura 8c), da média climatológica, do desvio padrão e das métricas estatísticas revela elevada variabilidade temporal da precipitação, principalmente durante os meses de máxima atuação da Monção da África Ocidental.

Nos meses secos, os valores de precipitação permanecem próximos de zero, apresentando medianas praticamente nulas, intervalos interquartis extremamente reduzidos e whiskers muito curtos. Essa configuração indica baixa dispersão dos dados e elevada estabilidade interanual, refletindo domínio persistente de condições atmosféricas secas.

A partir de maio inicia-se a transição para a estação chuvosa, observando-se aumento gradual da média climatológica e expansão da dispersão dos boxplots (Figura 8c). Nesse período o intervalo interquartil aumenta substancialmente, indicando crescimento da variabilidade pluviométrica interanual. O aumento do desvio padrão demonstra que os valores começam a se afastar progressivamente da média mensal, evidenciando maior irregularidade da precipitação.

Entre junho e setembro ocorre a fase mais intensa do período chuvoso. Em junho a mediana já apresenta elevação significativa, enquanto os boxplots tornam-se mais amplos, indicando aumento da variabilidade interanual. O intervalo interquartil relativamente elevado demonstra grande dispersão dos dados centrais, sugerindo forte influência de eventos convectivos.

Em julho observa-se crescimento expressivo da precipitação média, acompanhado pela ampliação da faixa correspondente ao desvio padrão. Essa expansão do desvio padrão evidencia forte dispersão dos totais precipitados em torno da média climatológica, indicando comportamento pluviométrico altamente variável. O intervalo interquartil amplo e os whiskers extensos revelam grande heterogeneidade temporal da precipitação.

O pico pluviométrico ocorre em agosto, quando a média climatológica ultrapassa aproximadamente 370 mm. Nesse mês os boxplots apresentam máxima expansão vertical, refletindo elevada variabilidade interanual. O intervalo interquartil muito amplo indica grande dispersão dos valores centrais da precipitação, enquanto os whiskers longos evidenciam ocorrência de amplitudes pluviométricas bastante elevadas.

Em setembro, embora a precipitação média apresente ligeira redução, a dispersão permanece elevada. A presença de boxplots amplos e whiskers extensos demonstra continuidade da variabilidade climática intensa (Figura 8c). O desvio padrão ainda permanece elevado, indicando persistência da irregularidade pluviométrica mesmo durante o enfraquecimento gradual da estação chuvosa.

Os eventos extremos são claramente identificados pela presença outliers acima dos whiskers (Figura 8c). Em agosto observa-se ocorrência de extremos próximos de 700 mm, enquanto em setembro destacam-se eventos superiores a 600 mm. Esses outliers indicam episódios pluviométricos excepcionais associados à intensa atividade convectiva tropical e à variabilidade da monção africana (Berthou et al., 2019; Tanimoune et al., 2024).

A análise do teste de Shapiro-Wilk revela predominância de distribuições normais. Apenas em maio, os dados observados apresentaram $p < 0.001$, e em novembro apresentaram $p < 0.001$, levando à rejeição da hipótese de normalidade. Embora tenham sido observados eventos extremos de precipitação em alguns meses como agosto e novembro, a maioria das distribuições apresentou comportamento estatisticamente compatível com a normalidade com ($p > 0.05$). Isso indica que, apesar da presença

de outliers e variabilidade elevada durante os meses chuvosos, os dados mantiveram distribuição aproximadamente simétrica na maior parte dos anos.

A estação de Gabú apresenta elevada sazonalidade climática e forte variabilidade interanual da precipitação durante a estação chuvosa. Os grandes intervalos interquartis, os elevados desvios padrão, os whiskers extensos e a presença de outliers extremos evidenciam elevada irregularidade pluviométrica e forte influência de eventos convectivos intensos.

4.2.8 Estação de Mansabá

A distribuição mensal da precipitação na estação de Mansabá evidencia um regime pluviométrico fortemente sazonal, característico do clima tropical úmido da África Ocidental. Os boxplots associados à média climatológica e à faixa de ± 1 desvio padrão demonstram uma clara diferenciação entre a estação seca, compreendida entre novembro e abril, e a estação chuvosa, concentrada principalmente entre maio e outubro.

Durante os meses secos, especialmente entre dezembro e abril, os valores de precipitação permanecem próximos de zero, apresentando medianas praticamente nulas, intervalos interquartis extremamente reduzidos e whiskers curtos. Esse comportamento indica elevada estabilidade atmosférica e baixa variabilidade interanual da precipitação. Nesses meses, o desvio padrão também é muito reduzido, demonstrando que os valores observados permanecem fortemente concentrados em torno da média climatológica.

A partir de maio inicia-se a transição para a estação chuvosa, observando-se aumento progressivo da precipitação média e expansão significativa da dispersão dos dados. O crescimento da largura dos boxplots na (Figura 8d) evidencia aumento do intervalo interquartil, indicando maior variabilidade dos dados centrais da precipitação. Simultaneamente, o aumento da faixa correspondente ao desvio padrão demonstra maior dispersão dos totais precipitados em torno da média climatológica.

Em junho a precipitação já apresenta crescimento substancial, com medianas mais elevadas e ampliação dos whiskers. Esse comportamento evidencia maior heterogeneidade pluviométrica e aumento da irregularidade temporal das chuvas. O intervalo interquartil relativamente amplo demonstra que os valores centrais da distribuição tornam-se mais dispersos em decorrência da intensificação da atividade convectiva regional.

Os maiores volumes pluviométricos concentram-se entre julho e setembro. Em julho observa-se expressiva expansão do boxplot mostrada na (Figura 8d), indicando aumento acentuado da variabilidade interanual. O intervalo interquartil amplo revela elevada dispersão dos valores centrais, enquanto os whiskers extensos demonstram ocorrência de amplitudes pluviométricas consideráveis.

O pico da estação chuvosa ocorre em agosto, quando a média climatológica

aproxima-se de 400 mm. Nesse mês, a faixa de ± 1 desvio padrão atinge máxima amplitude, evidenciando elevada variabilidade dos totais precipitados. O boxplot apresenta grande extensão vertical e amplo intervalo interquartil, indicando forte irregularidade pluviométrica e elevada dispersão dos dados centrais. Além disso, observam-se outliers extremamente elevados, incluindo eventos superiores a 1000 mm, indicando ocorrência de precipitações excepcionais associadas à intensa atuação da Monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2018).

Em setembro a precipitação permanece elevada, embora com ligeira redução da média climatológica. Ainda assim, os boxplots permanecem amplos e os whiskers continuam extensos, indicando persistência da elevada variabilidade interanual. O desvio padrão continua elevado, refletindo grande dispersão dos valores precipitados em torno da média.

Em outubro observa-se redução significativa da precipitação média e diminuição gradual da variabilidade. Entretanto, ainda são observados boxplots relativamente amplos e presença de outliers, demonstrando que eventos extremos ainda podem ocorrer durante a transição para a estação seca.

Os outliers identificados nos boxplots evidenciam ocorrência de eventos pluviométricos extremos ao longo da estação chuvosa (Figura 8d). Em julho destacam-se valores superiores a 650 mm, enquanto em agosto foram observados extremos acima de 1000 mm. Esses eventos extremos indicam elevada irregularidade da precipitação e forte influência de sistemas convectivos intensos.

A análise do teste de Shapiro-Wilk demonstra predominância de distribuições não normais. Em maio os dados observados apresentaram $p < 0.001$, rejeitando a hipótese de normalidade. Em junho, julho e setembro os dados observados apresentaram p -valores superiores a 0.05, indicando não rejeição da normalidade, e com presença de outliers evidenciando influência de assimetria e extremos pluviométricos.

Os resultados evidenciam que a estação de Mansabá apresenta elevada sazonalidade pluviométrica e forte variabilidade interanual durante a estação chuvosa. Os amplos intervalos interquartis, os elevados desvios padrão e a presença de numerosos outliers extremos demonstram elevada irregularidade temporal da precipitação.

4.2.9 Estação de Suzana

A distribuição mensal da precipitação na estação de Suzana evidencia um regime pluviométrico altamente sazonal, caracterizado por forte concentração das chuvas entre os meses de junho e outubro, enquanto o período entre novembro e abril apresenta precipitação praticamente nula. Os boxplots associados à média climatológica e à faixa de ± 1 desvio padrão demonstram elevada variabilidade temporal da precipitação, sobretudo durante o auge da estação chuvosa.

Nos meses secos, particularmente entre dezembro e abril, observa-se ausência

quase total de precipitação, com medianas próximas de zero, intervalos interquartis extremamente reduzidos e whiskers muito curtos. Esse comportamento evidencia elevada estabilidade climática e baixa variabilidade interanual. O desvio padrão também permanece muito reduzido, indicando forte concentração dos dados em torno da média climatológica.

Em maio inicia-se a transição para a estação chuvosa, com aumento gradual da precipitação média e expansão do intervalo interquartil (Figura 8e). O boxplot apresenta crescimento moderado, evidenciando aumento da dispersão dos valores centrais da precipitação. Apesar dos acumulados ainda relativamente baixos, já são observados outliers superiores a 70 mm, demonstrando ocorrência ocasional de eventos convectivos precoces.

A partir de junho ocorre intensificação significativa do regime pluviométrico. O aumento da altura das caixas e da extensão dos whiskers evidencia maior variabilidade dos dados e ampliação da amplitude pluviométrica. O intervalo interquartil torna-se mais amplo, indicando dispersão crescente dos valores centrais em torno da mediana. A presença de extremos superiores a 200 mm demonstra ocorrência de eventos intensos associados ao fortalecimento da monção africana (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009).

O período de máxima precipitação concentra-se entre julho e setembro. Em julho a média climatológica ultrapassa aproximadamente 380 mm, enquanto o boxplot apresenta grande expansão vertical e amplo intervalo interquartil (Figura 8e), indicando elevada variabilidade interanual. Os whiskers extensos revelam grande amplitude dos totais precipitados, refletindo forte irregularidade temporal das chuvas.

O pico pluviométrico ocorre em agosto, quando a média climatológica atinge aproximadamente 560 mm. Nesse mês observa-se a maior amplitude da faixa correspondente ao desvio padrão, evidenciando intensa dispersão dos dados em torno da média. O intervalo interquartil extremamente amplo demonstra elevada heterogeneidade dos valores centrais da precipitação, enquanto os whiskers alcançam valores próximos de 950 mm. Além disso, são identificados eventos extremos muito intensos, reforçando a elevada variabilidade interanual característica desse período.

Em setembro observa-se leve redução da precipitação média em relação a agosto; entretanto, os boxplots continuam amplos e os desvios padrão permanecem elevados. Isso demonstra persistência da variabilidade pluviométrica elevada durante o final da estação chuvosa. O intervalo interquartil ainda permanece largo, indicando dispersão significativa dos valores centrais.

Durante outubro ocorre redução progressiva da precipitação média, embora ainda sejam observados boxplots relativamente elevados e presença de outliers superiores a 350 mm. Esse comportamento demonstra que eventos extremos ainda podem ocorrer durante a fase de transição para a estação seca.

Em novembro a precipitação reduz-se drasticamente, porém a presença de múltiplos outliers evidencia ocorrência esporádica de chuvas tardias intensas. O boxplot (Figura 8e) reduzido e o pequeno intervalo interquartil indicam que a maior parte dos valores permanece próxima de baixos acumulados pluviométricos, enquanto poucos eventos extremos aumentam a assimetria da distribuição.

Os outliers identificados nos boxplots refletem ocorrência de eventos pluviométricos extremos durante a estação chuvosa. Em agosto destacam-se máximos próximos de 950 mm, enquanto em setembro e outubro ainda ocorrem extremos acima de 600 mm e 350 mm, respectivamente. Esses extremos evidenciam elevada irregularidade interanual e forte influência de sistemas convectivos intensos associados à dinâmica da Zona de Convergência Intertropical e da Monção da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024).

A análise do teste de Shapiro-Wilk evidencia comportamento misto quanto à normalidade dos dados. Em maio, junho, outubro e novembro os dados observados apresentaram rejeição da hipótese de normalidade ($p < 0.001$), indicando distribuições assimétricas e influência de extremos pluviométricos. Em julho, agosto e setembro os dados observados apresentaram p -valores superiores a 0.05, indicando não rejeição da normalidade, refletindo persistência de assimetria e influência dos eventos extremos com a presença de outliers em alguns meses.

A estação Suzana apresenta elevada sazonalidade pluviométrica, marcada por forte concentração das chuvas entre julho e setembro e elevada variabilidade interanual. Os amplos intervalos interquartis, os elevados desvios padrão e a presença de numerosos extremos demonstram forte irregularidade temporal da precipitação.

4.3 Curvas de Tendência e Extrapolação

O gráfico na (Figura 9a) apresenta a evolução das máximas anuais de precipitação em Bafatá no período de 1990 a 2022, em que os pontos azuis representam os totais máximos anuais observados e a linha tracejada vermelha corresponde a um ajuste cúbico (polinômio de grau três), utilizado para identificar a tendência de longo prazo da série temporal.

De forma geral, observa-se uma tendência crescente das máximas anuais de precipitação, particularmente a partir do final da década de 1990 e início dos anos 2000. No início do período analisado, entre aproximadamente 1990 e 1997, o ajuste indica uma fase de leve diminuição ou relativa estabilidade das máximas pluviométricas. Esse comportamento inicial pode estar associado a variações interanuais da intensidade da Monção da África Ocidental, que nesse intervalo apresentou episódios de enfraquecimento regional, afetando o aporte de umidade sobre o interior do continente.

A partir de meados dos anos 2000 (Figura 9a), a curva de tendência passa a

apresentar uma inclinação mais acentuada, indicando um aumento progressivo e mais consistente das máximas anuais de precipitação, com destaque para os anos mais recentes, próximos a 2020. Esse padrão sugere uma intensificação dos eventos de precipitação extrema, coerente com estudos que apontam para o fortalecimento dos fluxos monçônicos e maior disponibilidade de vapor da água na atmosfera, associada ao aquecimento das superfícies oceânicas adjacentes e ao aumento das temperaturas continentais.

O gráfico evidencia ainda picos pluviométricos expressivos, como valores próximos a 600 mm por volta de 2009 e superiores a 550 mm em torno de 2016, os quais podem ser interpretados como episódios extremos de precipitação. Esses eventos estão frequentemente relacionados a fases mais intensas da monção, à maior persistência da Zona de Convergência Intertropical (ZCIT) sobre a região e à ocorrência de sistemas convectivos, característicos do regime climático da África Ocidental (Berthou et al., 2019; Tanimoune et al., 2024). O ajuste cúbico suaviza essas oscilações interanuais, permitindo destacar a tendência estrutural do aumento da intensidade das máximas anuais.

Apesar da tendência ascendente evidenciada pela curva ajustada, observa-se uma dispersão considerável dos valores em torno da linha de tendência, indicando elevada variabilidade interanual das máximas de precipitação em Bafatá. Essa variabilidade reflete a forte dependência do regime pluviométrico local em relação à dinâmica sazonal e interanual da monção, bem como à influência de forçantes climáticas de grande escala.

A extrapolação da curva de ajuste até 2030 sugere que, caso o comportamento atual se mantenha, a precipitação anual máxima em Bafatá (Figura 9a) poderá continuar apresentando valores crescentes nas próximas décadas. Esse resultado reforça a indicação de um cenário de maior frequência e intensidade de eventos extremos de precipitação, potencialmente associado às mudanças climáticas recentes e ao fortalecimento da Monção da África Ocidental, com implicações relevantes para riscos hidrológicos e o planejamento climático regional.

Diferentemente do comportamento observado em outras estações, o gráfico das máximas anuais de precipitação em Bigene revela uma dinâmica temporal mais complexa, caracterizada por fases distintas de aumento, declínio prolongado e recuperação recente. A curva de ajuste cúbico (polinômio de grau três) evidencia essa variabilidade ao longo do período analisado.

No período inicial da série (1990–1997) (Figura 9b), observa-se um aumento expressivo das máximas anuais de precipitação, com a curva de tendência atingindo um pico por volta de 1993–1994. Esses valores elevados indicam anos com episódios intensos de precipitação, possivelmente associados a fases mais ativas da Monção da África Ocidental, quando o fortalecimento dos fluxos de sudoeste favorece maior

transporte de umidade para o interior do continente e a intensificação da convecção.

Após esse pico inicial, a série entra em um período de declínio pronunciado entre aproximadamente 1997 e 2015. A curva de ajuste indica uma redução contínua das máximas anuais de precipitação, atingindo um mínimo em torno de 2015–2016. Esse comportamento sugere uma fase prolongada de enfraquecimento relativo dos eventos extremos de chuva em Bigene, possivelmente associada a variações de grande escala que afetam a intensidade e a posição da monção, como alterações na circulação atmosférica regional, no gradiente térmico oceano–continente e na persistência da Zona de Convergência Intertropical (ZCIT) (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009).

A partir de 2015–2016, observa-se uma recuperação das máximas anuais de precipitação, com a curva de tendência voltando a apresentar inclinação positiva até 2022. Esse aumento recente pode indicar uma retomada da intensidade dos eventos extremos de precipitação, em consonância com evidências recentes de fortalecimento da monção e aumento do conteúdo de vapor da água na atmosfera, associados ao aquecimento regional e global.

Apesar da tendência geral capturada pelo ajuste cúbico, os dados apresentam elevada variabilidade interanual, característica intrínseca das séries de precipitação. Observam-se anos com máximas muito acima da curva de tendência, como no intervalo entre 1993 e 1999, bem como anos com valores significativamente abaixo, a exemplo de 2006, 2019 e 2022. A dispersão considerável dos pontos em torno da curva reforça a forte influência de processos atmosféricos de curta escala, como sistemas convectivos intensos, na determinação das máximas anuais.

De modo geral, o gráfico de Bigene evidencia uma evolução não linear das máximas anuais de precipitação, marcada por um aumento inicial, seguido por um longo período de declínio e uma recuperação recente. Essa dinâmica complexa reflete a sensibilidade do regime pluviométrico local às flutuações da Monção da África Ocidental e às interações entre forçantes climáticas regionais e globais.

No que se refere à projeção futura, a partir dos dados mais recentes, especialmente no período pós-2020, a extrapolação sugere um aumento extremamente acentuado das máximas anuais de precipitação, indicando que, caso essa tendência se mantenha, Bigene poderá atingir valores recordes de precipitação até 2030. Esse cenário aponta para um potencial aumento na frequência e intensidade de eventos extremos, elevando o risco de inundações severas e destacando a necessidade de planejamento e adaptação frente às mudanças climáticas em curso.

O gráfico das máximas anuais de precipitação em Bissau, no período de 1990 a 2022, evidencia uma evolução temporal ondulatória, caracterizada por fases sucessivas de aumento, declínio e posterior recuperação das precipitações máximas. A curva de ajuste destaca essa dinâmica não linear, refletindo a forte influência dos mecanis-

mos atmosféricos que controlam o regime pluviométrico da região costeira da África Ocidental.

No período inicial da série (1990–1997), observa-se um aumento progressivo das máximas anuais de precipitação, com a curva de tendência atingindo um pico por volta de 1998. Esse comportamento sugere uma fase de intensificação dos eventos extremos de chuva, possivelmente associada a períodos mais ativos da Monção da África Ocidental, quando o fortalecimento dos ventos de sudoeste e a maior disponibilidade de umidade oceânica favorecem episódios de precipitação intensa na faixa costeira.

Entre aproximadamente 1997 e 2012, a série apresenta um período de declínio das máximas anuais de precipitação, culminando em um mínimo por volta de 2012. Essa redução pode estar relacionada a flutuações na intensidade da monção, à variabilidade na posição e persistência da Zona de Convergência Intertropical (ZCIT) e a mudanças na circulação atmosférica regional, que afetam diretamente o aporte de umidade sobre Bissau (Tanimoune et al., 2024; Sylla et al., 2009).

A partir de 2012, observa-se um reestabelecimento da tendência de aumento das máximas anuais, com a curva de ajuste indicando crescimento contínuo até 2022. O aumento acentuado nos anos mais recentes sugere uma retomada da intensidade dos eventos extremos de precipitação, coerente com evidências recentes de fortalecimento da monção e aumento do conteúdo de vapor da água na atmosfera, associados ao aquecimento das águas do Atlântico Tropical e ao aumento das temperaturas continentais.

Apesar da tendência geral descrita pela curva ajustada, os dados apresentam elevada variabilidade interanual, característica típica de séries pluviométricas. Destacam-se picos expressivos em anos como 1994, 2001 e, sobretudo, 2020, que registra o maior valor da série, próximo a 750 mm, indicando um evento extremo de precipitação. Em contraste, anos como 2006, 2007 e 2018 apresentam valores significativamente abaixo da média. Essa dispersão reflete a forte influência de sistemas convectivos intensos, frequentemente associados à dinâmica da monção e a interações atmosféricas de curta escala.

De modo geral, o gráfico revela que as máximas anuais de precipitação em Bissau passaram por um aumento inicial, seguido por um período de enfraquecimento e, posteriormente, por uma recuperação consistente nos anos mais recentes. Essa evolução reforça a sensibilidade do regime pluviométrico local às variações da Monção da África Ocidental, especialmente em uma região costeira diretamente influenciada pelas condições oceânicas.

A partir dos dados mais recentes (pós-2022), a projeção indica um aumento significativo e acelerado das máximas anuais de precipitação, sugerindo que, até 2030 (Figura 9c), os valores poderão superar os maiores extremos observados no passado. Esse cenário aponta para implicações relevantes na gestão dos recursos hídricos, na

agricultura e no aumento do risco de inundações, reforçando a necessidade de estratégias de adaptação e planejamento climático em Bissau.

O gráfico das máximas anuais de precipitação na estação de Bolama, referente ao período de 1990 a 2022, evidencia um comportamento temporal ondulatório, no qual se alternam fases de redução, intensificação e posterior enfraquecimento dos eventos pluviométricos mais intensos. A curva de ajuste cúbico permite identificar essa evolução não linear, característica de regiões costeiras fortemente influenciadas pela dinâmica atmosférica da África Ocidental.

Nos anos iniciais da série (1990–1998), a tendência aponta para um declínio das máximas anuais de precipitação, culminando em um mínimo por volta de 1998. Esse padrão sugere um período de menor ocorrência de eventos extremos, possivelmente associado a uma fase de enfraquecimento relativo da Monção da África Ocidental (MAO), com redução do transporte de umidade do Atlântico para a faixa costeira e menor organização da convecção profunda (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009).

Entre 1998 e 2017, observa-se uma fase prolongada de aumento gradual das máximas anuais, com a curva de tendência atingindo um pico em torno de 2017. Esse crescimento progressivo indica uma intensificação dos eventos extremos de precipitação ao longo de quase duas décadas, compatível com um fortalecimento gradual da monção, maior disponibilidade de vapor da água na atmosfera e maior frequência de sistemas convectivos intensos atuando sobre a região costeira de Bolama.


Nos anos mais recentes da série (2017–2022), a curva de ajuste sugere uma estabilização seguida de leve declínio das máximas anuais de precipitação, com uma queda mais evidente a partir de 2020. Esse comportamento pode refletir mudanças recentes na circulação atmosférica regional, incluindo variações na posição da Zona de Convergência Intertropical (ZCIT) e possíveis alterações na intensidade dos fluxos monçônicos que afetam diretamente a ocorrência de eventos extremos na região (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009).

Apesar da tendência geral capturada pelo ajuste cúbico, os dados apresentam elevada variabilidade interanual, com significativa dispersão dos pontos em relação à curva de tendência. Observam-se anos com valores máximos expressivamente elevados, como nos períodos de 1991 a 1999, 2002 a 2004 e entre 2012 e 2018, além de 2020, contrastando com anos de precipitação máxima reduzida, como 1997, 2000–2001, 2005–2011, 2015, 2019, 2021 e 2022. O menor valor da série ocorre em 1990, próximo a 450 mm, enquanto o maior é registrado em 2013, com aproximadamente 1000 mm, evidenciando a ocorrência de eventos extremos de grande magnitude.


De forma sintética, o gráfico de Bolama revela uma evolução marcada por um declínio inicial, seguido de um aumento expressivo e, mais recentemente, por uma estabilização com tendência de queda nas máximas anuais de precipitação. Essa di-

nâmica reflete a sensibilidade do regime pluviométrico local às oscilações da Monção da África Ocidental, particularmente em áreas costeiras sujeitas à influência direta do Atlântico Tropical.


O modelo sugere uma redução contínua ao longo da extrapolação e relativamente acentuada das máximas anuais de precipitação nos próximos anos. Caso essa tendência se mantenha, a precipitação máxima anual em Bolama (Figura 9d) poderá diminuir para valores entre 400 e 450 mm até 2030. Embora os dados observados apresentem flutuações significativas, tanto a tendência recente quanto a projeção indicam um possível enfraquecimento dos eventos de precipitação mais intensa, com implicações diretas para a disponibilidade hídrica e a dinâmica ambiental local.




(a) Estação de Bafatá



(b) Estação de Bigene




(c) Estação de Bissau




(d) Estação de Bolama


Figura 9 – Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).




(a) Estação de Catió




(b) Estação de Farim



(c) Estação de Gabú



(d) Estação de Mansabá



(e) Estação de Suzana

Figura 10 – Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana.

Fonte: dos autores (2025)

O gráfico das máximas anuais de precipitação na estação de Catió, para o período de 1990 a 2022, apresenta um comportamento temporal ondulatório, com alternância entre fases de aumento, declínio e recuperação dos eventos pluviométricos mais intensos. Esse padrão reflete a forte influência da dinâmica atmosférica da África Ocidental sobre o regime pluviométrico da região sul da Guiné-Bissau, localizada em uma zona de transição entre áreas costeiras e o interior continental.

No período inicial da série (1990–1998), observa-se um aumento progressivo das máximas anuais de precipitação, culminando em um pico por volta de 1998. Esse comportamento pode ser associado a fases mais ativas da Monção da África Ocidental (MAO), caracterizadas por maior transporte de umidade do Atlântico Tropical e intensificação da convecção profunda, favorecendo a ocorrência de eventos extremos de chuva (Tanimoune et al., 2024).

Entre aproximadamente 1998 e 2015, a curva de tendência indica um declínio prolongado das máximas anuais de precipitação, atingindo um mínimo por volta de 2015. Essa redução sugere um enfraquecimento relativo dos eventos extremos, possivelmente relacionado a variações na intensidade da monção e à menor persistência da Zona de Convergência Intertropical (ZCIT) sobre a região, um comportamento mais próximo ao observado em estações do interior (Berthou et al., 2019; Tanimoune et al., 2024).

A partir de 2015, verifica-se uma recuperação consistente das máximas anuais de precipitação, com crescimento acentuado nos anos mais recentes da série. Esse aumento recente indica uma intensificação dos eventos extremos, alinhada ao fortalecimento da monção e ao aumento do conteúdo de vapor da água na atmosfera, aproximando o comportamento de Catió ao observado nas estações costeiras.

A série apresenta elevada variabilidade interanual, com picos expressivos em 1997–1998 (próximos a 950 mm) e em 2001 e 2003 (acima de 800 mm), comparando com anos de precipitação máxima reduzida, como 2000, 2005, 2014, 2016, 2018 e 2019. Essa dispersão evidencia a forte influência de sistemas convectivos intensos e processos atmosféricos de curta escala.

De forma geral, Catió apresenta um comportamento intermediário entre as estações costeiras e interiores, refletindo sua posição geográfica. No que se refere à projeção futura, a extrapolação da tendência ajustada indica um aumento acentuado das máximas anuais de precipitação até 2030 (Figura 10a). Caso essa tendência se mantenha, o município poderá enfrentar maiores riscos de inundações e desafios na gestão de recursos hídricos, reforçando a necessidade de estratégias de adaptação frente à intensificação dos eventos extremos associados à Monção da África Ocidental (MAO).

O gráfico das máximas anuais de precipitação na estação de Farim, no período de 1990 a 2022, revela uma evolução temporal marcada por uma fase inicial de relativa estabilidade, seguida por um aumento progressivo e contínuo dos eventos pluviométricos mais intensos. A curva de ajuste evidencia esse comportamento, refletindo a influência da dinâmica atmosférica da Monção da África Ocidental (MAO) sobre o regime pluviométrico do interior da Guiné-Bissau.

No início da série temporal (1990–2000), observa-se uma fase de estabilização com leve declínio das máximas anuais de precipitação, atingindo um mínimo por volta de 1997. Esse comportamento sugere um período de menor intensidade dos eventos extremos, possivelmente associado a variações interanuais da monção, com menor eficiência no transporte de umidade para o interior continental durante parte da década de 1990.

A partir do ano 2000, a curva de tendência passa a indicar um aumento contínuo e progressivo das máximas anuais de precipitação, estendendo-se até 2022. Nos

anos mais recentes, a inclinação da curva torna-se mais acentuada, sugerindo uma aceleração no aumento das precipitações máximas, coerente com um fortalecimento da monção e maior disponibilidade de vapor da água na atmosfera, associado ao aquecimento regional e global.

A série apresenta elevada variabilidade interanual, evidenciada pela significativa dispersão dos pontos em torno da curva de tendência. Destacam-se eventos extremos recentes, como o pico observado em 2018, superior a 1200 mm, o maior da série, e outro em 2020, próximo a 800 mm, ambos muito acima da tendência média. Em contraste, registram-se anos com precipitações máximas excepcionalmente baixas, como 1996 e 2006, com valores próximos a 200 mm. Essa variabilidade reflete a forte influência de sistemas convectivos intensos e de processos atmosféricos de curta escala, típicos da atuação da monção no interior do continente.

De forma geral, o gráfico de Farim indica uma evolução caracterizada por uma fase inicial de estabilidade e leve declínio, seguida por um período prolongado de aumento das máximas anuais, aparentemente acelerado nos anos finais da série. Esse comportamento evidencia a crescente relevância dos eventos extremos de precipitação no interior da região, associados às flutuações e ao fortalecimento recente da Monção da África Ocidental (MAO) que foi explicado também nos trabalhos destes autores (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009).

A projeção nos próximos anos sugere a continuidade do aumento das máximas anuais de precipitação até aproximadamente 2025, seguida por uma fase de estabilização ou leve declínio nos anos subsequentes. Caso esse cenário se concretize, a precipitação máxima anual em Farim (Figura 10b) poderá manter-se na faixa de 550 a 600 mm até 2030, valores ainda superiores aos observados no início da série histórica.

Em síntese, o gráfico aponta para um aumento moderado das chuvas mais intensas ao longo das últimas décadas, com indícios recentes de estabilização ou leve redução. No entanto, considerando a complexidade do sistema climático e a elevada variabilidade associada à monção, essas projeções devem ser interpretadas com cautela, uma vez que alterações na circulação atmosférica regional e em forçantes de grande escala podem modificar substancialmente esse comportamento futuro.

O gráfico das máximas anuais de precipitação na estação de Gabú, no período de 1990 a 2022, evidencia uma evolução temporal marcada por três fases principais: um aumento inicial dos acumulados máximos, seguido por um intervalo de relativa estabilidade com leve declínio e, por fim, uma retomada expressiva da precipitação nos anos mais recentes. Esse comportamento reflete a forte influência da Monção da África Ocidental (MAO) (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009), sobre o regime pluviométrico do interior oriental da Guiné-Bissau.

Durante a década de 1990 (1990–2000), observa-se um aumento progressivo das máximas anuais de precipitação, com a curva de tendência atingindo um pico por volta

do ano 2000. Esse crescimento sugere uma fase de intensificação dos fluxos monçônicos e maior transporte de umidade continental, favorecendo episódios de precipitação mais intensa na região de Gabú, típica área de interior sob influência direta da penetração da monção.

No período subsequente, entre aproximadamente 2000 e 2015, a curva de ajuste indica uma fase de relativa estabilidade, acompanhada de leve declínio das máximas anuais, com flutuações interanuais, mas sem uma tendência clara de intensificação. O ponto mínimo desse intervalo ocorre por volta de 2015. Esse comportamento pode estar associado a variações na intensidade e na persistência da monção, bem como a mudanças na circulação atmosférica regional que modulam a convecção profunda no interior do continente.

A partir de 2015, observa-se uma retomada consistente do aumento das máximas anuais de precipitação, com a curva apresentando inclinação positiva até o final da série em 2022. Esse padrão recente sugere uma intensificação dos eventos extremos de chuva, coerente com evidências de fortalecimento da monção e aumento do conteúdo de vapor da água na atmosfera, associados ao aquecimento regional e global.

A série apresenta elevada variabilidade interanual, evidenciada pela dispersão significativa dos pontos em relação à curva de tendência. Destacam-se picos expressivos em anos como 1999, com valores próximos a 700 mm, e 2003, acima de 600 mm, contrastando com anos de precipitação máxima reduzida, como 1991 (cerca de 300 mm) e 2000 (próximo a 250 mm). Essa variabilidade reflete a forte influência de sistemas convectivos intensos e de processos atmosféricos de curta escala, típicos da atuação da monção no interior da África Ocidental.

De forma geral, o gráfico de Gabú revela uma evolução caracterizada por um aumento inicial das máximas anuais, seguido por um período de estabilização com leve declínio e, posteriormente, por uma recuperação marcada nos anos mais recentes. Essa dinâmica evidencia a sensibilidade do regime pluviométrico local às oscilações da Monção da África Ocidental (MAO), especialmente em regiões interiores.

Para os próximos anos a tendência, apontando para um aumento acentuado das máximas anuais de precipitação até 2030 (Figura 10c). Caso esse cenário se concretize, os valores projetados poderão superar grande parte dos extremos observados na série histórica, indicando um potencial aumento na frequência e intensidade de eventos extremos de precipitação, com implicações significativas para riscos hidrológicos, uso do solo e planejamento climático na região de Gabú.

O gráfico das máximas anuais de precipitação na estação de Mansabá, no período de 1990 a 2022, evidencia uma variabilidade temporal marcada por flutuações interanuais e mudanças graduais na intensidade dos eventos pluviométricos extremos. A curva de tendência polinomial destaca essa evolução não linear, refletindo a forte dependência do regime pluviométrico local em relação à dinâmica da Monção da África

Ocidental (MAO) (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009), especialmente em áreas do interior da Guiné-Bissau.

Nos anos iniciais da série, ao longo da década de 1990, observa-se uma leve redução das máximas anuais de precipitação, seguida por uma fase de relativa estabilização no final da década. Esse comportamento pode estar associado a variações interanuais da monção, com episódios de enfraquecimento do transporte de umidade para o interior continental, resultando em menor frequência ou intensidade de eventos extremos de chuva.

Entre o início dos anos 2000 e meados da década de 2010, a curva de tendência indica um aumento gradual das máximas anuais de precipitação, atingindo um pico por volta de 2010–2012. Esse período sugere uma intensificação dos eventos extremos, possivelmente relacionada ao fortalecimento dos fluxos monçônicos, à maior disponibilidade de vapor da água na atmosfera e à intensificação da convecção profunda associada à atuação mais persistente da monção sobre a região.

A partir de meados da década de 2010, a curva de ajuste passa a indicar uma fase de estabilização, seguida por uma leve tendência de declínio das máximas anuais, particularmente entre 2020 e 2022. Esse comportamento recente pode refletir mudanças na circulação atmosférica regional e na intensidade da monção, afetando diretamente a ocorrência de eventos extremos de precipitação em Mansabá.

Apesar da tendência geral capturada pelo ajuste polinomial, os dados apresentam elevada variabilidade interanual, evidenciada pela dispersão significativa dos pontos em relação à curva de tendência. Destacam-se eventos extremos isolados, como o pico superior a 1000 mm registrado por volta de 2004, que representa o maior acumulado da série e se destaca claramente do comportamento médio. Esses episódios refletem a ocorrência de sistemas convectivos intensos, característicos da dinâmica da monção, e reforçam a natureza episódica dos extremos pluviométricos na região.

A projeção sugere uma diminuição contínua das máximas anuais de precipitação até 2030, indicando que, caso essa tendência se mantenha, a precipitação máxima anual em Mansabá (Figura 10d) poderá reduzir-se para valores entre 200 e 300 mm. Esse cenário aponta para uma possível redução na intensidade das chuvas mais fortes, o que pode trazer implicações relevantes para a disponibilidade de recursos hídricos e para a agricultura local.

O gráfico de Mansabá indica uma tendência recente de enfraquecimento dos eventos extremos de precipitação, projetada para os próximos anos. No entanto, a elevada variabilidade interanual associada à Monção da África Ocidental (MAO) (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009) representa um desafio adicional para o planejamento e a gestão dos recursos hídricos, uma vez que eventos extremos isolados continuam sendo possíveis, mesmo em um contexto de tendência média decrescente.

O gráfico das máximas anuais de precipitação na estação de Suzana, no período de 1990 a 2022, revela uma tendência geral relativamente estável, marcada por pequenas variações ao longo do tempo quando comparada à elevada dispersão dos dados observados. Esse comportamento distingue Suzana de outras estações analisadas, especialmente das áreas costeiras, que apresentam tendências mais acentuadas, e das estações do interior, onde predominam aumentos mais expressivos das máximas anuais. A curva de tendência indica uma leve redução inicial, seguida por um longo período de estabilidade e, por fim, um novo declínio suave nos anos mais recentes, refletindo a complexa interação entre a variabilidade interanual e a dinâmica da Monção da África Ocidental.

No início da série (1990–1995), observa-se um leve declínio das máximas anuais de precipitação, possivelmente associado a flutuações iniciais da intensidade monçônica e a uma menor frequência de episódios convectivos intensos atuando sobre a região. Esse comportamento inicial antecede uma fase mais prolongada de relativa estabilidade.

Durante o período intermediário (1995–2015), a curva de ajuste mantém-se praticamente plana, oscilando em torno de um valor médio sem indicar uma tendência clara de aumento ou diminuição. Essa estabilidade sugere que, ao longo de aproximadamente duas décadas, a intensidade média dos eventos extremos de precipitação em Suzana permaneceu relativamente constante, comparando com o aumento observado em estações do interior e com a maior variabilidade estrutural identificada nas estações costeiras, mais diretamente influenciadas pelas condições oceânicas.

Nos anos mais recentes da série (2015–2022), a curva de tendência aponta para um novo e discreto declínio das máximas anuais de precipitação, indicando uma possível redução na intensidade dos eventos extremos. Esse comportamento pode estar relacionado a mudanças recentes na circulação atmosférica regional, incluindo variações na posição e persistência da Zona de Convergência Intertropical (ZCIT) (Berthou et al., 2019; Tanimoune et al., 2024; Sylla et al., 2009), e na eficiência dos fluxos monçônicos em gerar convecção profunda sobre áreas de transição como Suzana.

Apesar da suavidade da curva de tendência, os dados observados apresentam altíssima variabilidade interanual, com dispersão significativa em torno da linha ajustada. Destacam-se eventos extremos pontuais, como os picos registrados em 1998 (acima de 800 mm), 2008 (superior a 900 mm) e nos anos de 1999, 2009, 2010, 2014 e 2020 (todos acima de 700 mm). Em contraste, observam-se diversos anos com máximas substancialmente abaixo da média, como 2002, 2005, 2007, 2011, 2018 e 2019, alguns com valores inferiores a 400 mm. Essa ampla dispersão evidencia a forte influência de eventos convectivos episódicos e de fatores locais, característica típica das regiões sob influência da monção.

De forma geral, Suzana apresenta um comportamento intermediário entre as es-

tações costeiras e interiores, com tendência de longo prazo relativamente estável e marcada dominância da variabilidade interanual. Esse padrão reforça o papel das áreas de transição na modulação dos impactos da Monção da África Ocidental, onde a ocorrência de eventos extremos não depende exclusivamente da tendência média da precipitação.

Para o futuro, a extrapolação da curva ajustada até 2030 indica a continuidade da tendência de declínio das máximas anuais de precipitação. Caso esse cenário se confirme, a precipitação máxima anual em Suzana (Figura 10e) poderá situar-se na faixa de 400 a 450 mm. Essa possível redução na intensidade das chuvas mais extremas pode implicar menor risco de inundações súbitas; contudo, quando analisada em conjunto com indícios de aumento da precipitação total anual, sugere uma redistribuição temporal das chuvas, com menor concentração em eventos extremos e maior frequência de episódios moderados.

4.4 Resultados da (ANOVA) Análise de Variância de Dois Fatores com Interação

A análise de variância (ANOVA) de dois fatores foi utilizada para investigar a influência do tipo de produto de precipitação (Fator A) e das diferentes estações meteorológicas (Fator B) sobre os valores de precipitação analisados, bem como verificar a existência de interação entre esses fatores (Montgomery, 2017). considerando os fatores A (produto) e B (estação), com $a = 4$ níveis, $b = 8$ níveis e $n = 231$ repetições por combinação. Esse delineamento experimental resultou em uma base de dados robusta, adequada para inferência estatística.

Fonte	SQ	GL	QM	F	p-valor
Fator A	$2,18 \times 10^6$	3	$7,25 \times 10^5$	22,38	$< 0,001$
Fator B	$1,32 \times 10^7$	7	$1,88 \times 10^6$	58,10	$< 0,001$
Interação	$1,50 \times 10^6$	21	$7,16 \times 10^4$	2,21	0,001
Erro	$2,38 \times 10^8$	7360	$3,24 \times 10^4$	—	—

Tabela 7 – Resultados da ANOVA de dois fator com interação

A Tabela 4.4 apresenta os resultados da ANOVA de dois fatores com interação aplicada aos dados de precipitação, considerando como fatores os diferentes produtos de precipitação (Fator A) e as estações meteorológicas (Fator B). A análise permitiu avaliar a contribuição individual de cada fator, bem como a influência conjunta entre eles sobre a variabilidade pluviométrica observada.

Os resultados mostram que o Fator A apresentou soma de quadrados igual a $2,18 \times 10^6$, com 3 graus de liberdade, resultando em quadrado médio de $7,25 \times 10^5$. O

valor de $F = 22,38$ e o p -valor inferior a 0,001 indicam que existem diferenças estatisticamente significativas entre os produtos de precipitação analisados. Isso significa que os diferentes produtos apresentam desempenhos distintos na representação da precipitação, evidenciando que alguns modelos conseguem reproduzir melhor os padrões pluviométricos observados do que outros.

O Fator B (Estação) apresentou a maior contribuição para a variabilidade total dos dados, com soma de quadrados de $1,32 \times 10^7$ e valor de $F = 58,10$, altamente significativo ($p < 0,001$). Esse resultado demonstra que as diferenças entre as estações meteorológicas exercem forte influência sobre o comportamento da precipitação. Em outras palavras, a variabilidade climática regional entre as estações é mais importante do que as diferenças entre os produtos utilizados.

A interação entre os fatores também é estatisticamente significativa ($F = 2,21$; $p = 0,001$). Esse resultado indica que o desempenho dos produtos de precipitação não é uniforme em todas as estações meteorológicas. Assim, determinados produtos apresentaram melhor desempenho em algumas estações e desempenho inferior em outras, evidenciando dependência entre produto.

Embora o valor de F da interação tenha sido inferior aos observados para os fatores principais, sua significância estatística confirma que existe influência conjunta entre produto e estação na representação da precipitação. Isso sugere que a capacidade dos produtos em reproduzir os padrões pluviométricos depende parcialmente das características climáticas locais de cada estação.

O termo de erro apresentou soma de quadrados elevada ($2,38 \times 10^8$), refletindo a grande variabilidade natural da precipitação. Esse comportamento é esperado em séries pluviométricas tropicais, que geralmente apresentam elevada dispersão temporal, ocorrência de extremos climáticos e forte irregularidade interanual.

De forma geral, os resultados da ANOVA demonstram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente os valores de precipitação analisados. Além disso, a presença de interação significativa evidencia que o desempenho dos produtos varia espacialmente, reforçando a necessidade de avaliações regionais antes da aplicação operacional desses produtos em estudos e climáticos.

4.4.1 Interpretação das Hipóteses Estatísticas e dos Pressupostos da ANOVA

A verificação dos pressupostos da ANOVA revelou:

- Normalidade dos resíduos: rejeitada ($p \approx 9,64 \times 10^{-45}$);
- Homogeneidade das variâncias: rejeitada ($p \approx 1,22 \times 10^{-104}$).

Foram testadas as seguintes hipóteses:

Fator A (Produto):

$$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_a = 0 \quad (48)$$

$$H_1 : \exists \alpha_i \neq 0 \quad (49)$$

Fator B (Estação):

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_b = 0 \quad (50)$$

$$H_1 : \exists \beta_j \neq 0 \quad (51)$$

Interação:

$$H_0 : (\alpha\beta)_{ij} = 0 \quad \forall i, j \quad (52)$$

$$H_1 : \exists (\alpha\beta)_{ij} \neq 0 \quad (53)$$

Com base nos valores de p , todas as hipóteses nulas foram rejeitadas ao nível de significância de 5%.

Para o Fator A (Produto), a hipótese nula (H_0) estabelece que não existem diferenças estatisticamente significativas entre as médias dos produtos utilizados, ou seja, todos os efeitos associados aos produtos são iguais a zero. A hipótese alternativa (H_1) indica que pelo menos um dos produtos apresenta comportamento estatisticamente diferente dos demais. Em termos físicos, isso significa verificar se os diferentes produtos de reanálise conseguem reproduzir de maneira semelhante os valores observados de precipitação (Wilks, 2011).

Para o Fator B (Estação), a hipótese nula assume que não existem diferenças significativas entre as estações meteorológicas analisadas, implicando comportamento pluviométrico semelhante entre elas. Já a hipótese alternativa indica que pelo menos uma estação apresenta padrão de precipitação estatisticamente distinto, refletindo diferenças espaciais associadas à variabilidade climática regional (Wilks, 2011).

No caso da interação entre os fatores, a hipótese nula considera que o efeito do produto independe da estação meteorológica, ou seja, o desempenho dos produtos permanece constante em todas as estações analisadas. A hipótese alternativa sugere que existe dependência entre produto e estação, indicando que determinados produtos podem apresentar melhor desempenho em algumas estações e pior desempenho em outras (Montgomery, 2017).

A verificação dos pressupostos da ANOVA revelou importantes limitações estatísticas dos dados analisados. O teste de normalidade dos resíduos apresentou valor de $p \approx 9,64 \times 10^{-45}$, extremamente inferior ao nível de significância de 5%, levando à rejeição da hipótese de normalidade. Esse resultado indica que os resíduos não seguem distribuição normal, evidenciando forte assimetria e influência de eventos extremos de precipitação, característica frequentemente observada em séries pluviométricas tropicais (Wilks, 2011).

Além disso, o teste de homogeneidade das variâncias apresentou $p \approx 1,22 \times 10^{-104}$, também muito inferior a 0,05, indicando rejeição da hipótese de igualdade das variâncias. Isso demonstra que existe heterocedasticidade entre os grupos analisados, ou seja, diferentes níveis de dispersão entre produtos e estações meteorológicas (Montgomery, 2017).

Esses resultados mostram que os pressupostos clássicos da ANOVA paramétrica não foram completamente atendidos. Entretanto, devido ao grande tamanho amostral e à robustez relativa da ANOVA frente a desvios moderados de normalidade, a análise ainda pode fornecer informações relevantes sobre diferenças médias entre os grupos (Montgomery, 2017). Contudo, os resultados devem ser interpretados com cautela, especialmente em razão da elevada variabilidade da precipitação e da presença de extremos climáticos intensos.

A rejeição simultânea da normalidade e da homogeneidade das variâncias sugere que a precipitação apresenta comportamento altamente variável e assimétrico, reforçando a complexidade da modelagem estatística de eventos pluviométricos na região estudada. Esse comportamento é compatível com a natureza intermitente das chuvas tropicais, caracterizadas por longos períodos secos alternados com eventos extremos de elevada intensidade (Wilks, 2011).

Entretanto, considerando o elevado tamanho amostral ($n = 231$ por célula), a ANOVA apresenta robustez frente a essas violações moderada, permitindo a continuidade da análise com cautela interpretativa.

4.4.1.1 *Independência dos Dados*

O pressuposto de independência foi avaliado considerando a estrutura temporal das observações e o teste de Durbin-Watson aplicado aos resíduos do modelo. Embora as observações sejam provenientes de diferentes períodos temporais (meses e anos), alguns resultados indicaram presença de autocorrelação positiva dos resíduos, evidenciada por valores de Durbin-Watson inferiores a 2 em determinadas análises.

Esse comportamento sugere certa dependência temporal entre os resíduos, característica frequentemente observada em séries pluviométricas devido à persistência climática e à sazonalidade da precipitação. Entretanto, considerando o elevado tamanho amostral e a natureza exploratória da ANOVA, os resultados ainda permitem identificar diferenças estatísticas relevantes entre os grupos analisados, devendo, contudo, ser interpretados com cautela.

4.5 Relação de Fator de Dois nas Comparações dos dados de Reanálises sobre Observados para as Estações

De acordo com a (Hanna; Chang, 2012) a métrica **FAT2** (Fração dentro de um Fator de Dois) mede a fração de previsões (C_p) que se encontram dentro de um fator de dois em relação às observações (C_o), isto é, aquelas que satisfazem a condição

$$0.5 < \frac{C_p}{C_o} < 2,$$

Onde:

- C_p refere-se à concentração predita pelo modelo.
- C_o refere-se à concentração observada.

Além disso, o FAT2 apresenta a vantagem de ser uma métrica robusta frente à influência de valores extremos, permitindo avaliar a capacidade geral do modelo em reproduzir a ordem de magnitude das observações, mesmo em situações de elevada variabilidade climática.

A escolha do critério de fator 2 na métrica FAT2 está associada à elevada variabilidade e incerteza inerentes aos dados ambientais e meteorológicos, especialmente em estudos envolvendo precipitação (Hanna; Chang, 2012). Em séries pluviométricas, pequenas diferenças absolutas podem representar grandes diferenças relativas, principalmente durante eventos extremos ou períodos de baixa precipitação.

Nesse contexto, a adoção de previsões dentro de um fator de dois das observações constitui um critério amplamente utilizado na avaliação de modelos ambientais e atmosféricos, permitindo uma análise mais realista do desempenho dos modelos diante da elevada variabilidade natural da precipitação (Chang; Hanna, 2004; Hanna; Chang, 2012).

Indica que os valores predita pelo modelo, podem variar entre metade e o dobro dos valores observados, permanecendo ainda dentro de um intervalo considerado aceitável para aplicações ambientais e climatológicas. Esse critério é amplamente utilizado em estudos de validação de modelos atmosféricos e dispersão ambiental devido à alta variabilidade natural dos fenômenos meteorológicos (Chang; Hanna, 2004; Hanna; Chang, 2012).

4.5.1 Reanálise MSWEP V2

4.5.1.1 Estação Bafatá

Os menores erros ocorreram em maio e outubro, quando o desempenho foi classificado como bom, com baixos valores de MAE, RMSE e NRMSE (Tabela 11), indicando

boa representação da precipitação observada. Em contrapartida, julho, setembro e principalmente agosto apresentaram aumento expressivo dos erros devido ao fortalecimento da estação chuvosa (Figura 11a). Agosto registrou o pior desempenho estatístico ($NRMSE = 1,70$), acompanhado de forte superestimação da precipitação ($Bias = 111,32$ mm), baixa correlação temporal e reduzida capacidade explicativa do modelo.

Os coeficientes mensais de determinação (R^2) (Tabela 11), mostraram elevada variabilidade ao longo da estação chuvosa, com melhores resultados em julho e novembro e valores muito reduzidos em agosto e setembro, evidenciando dificuldade do produto em representar adequadamente os extremos pluviométricos.

A regressão linear global apresentou elevado coeficiente de determinação ($R^2 = 0,84$) e inclinação próxima da unidade (1,0576) (Tabela 8), indicando boa representação média da precipitação, embora com leve tendência de superestimação. A análise FAT2 confirmou essa tendência, mostrando boa concordância geral entre observado e reanálise e a (Figura 13a) mostra que os dados estão mais dispersos, e grande parte deles se encontra dentro de um fator de dois, mas aumento significativo da dispersão durante eventos extremos (Figura 12a).

Os resultados da ANOVA mostraram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) demonstrou influência das características climáticas regionais no desempenho do modelo (Tabela 4.4).

Os boxplots evidenciaram forte variabilidade sazonal, com aumento expressivo da dispersão e da frequência de extremos durante julho e agosto (Figura 11a). Os testes de Shapiro-Wilk mostraram alternância entre distribuições normais e não normais, refletindo a influência dos extremos pluviométricos. O teste de Levene indicou homogeneidade das variâncias na maior parte dos meses, enquanto o Durbin-Watson revelou autocorrelação positiva mais intensa em agosto, indicando persistência temporal dos erros no pico da estação chuvosa.

De forma geral, reanálise apresentou desempenho satisfatório na representação da precipitação média e da sazonalidade, porém persistiram limitações importantes na reprodução quantitativa dos extremos severos, especialmente durante os períodos de maior intensidade pluviométrica.

4.5.1.2 Estação Bigene

A análise integrada da precipitação mensal na estação Bigene evidenciou forte variabilidade sazonal no desempenho do MSWEP V2. Os melhores resultados ocorreram em maio, junho e outubro, enquanto julho, agosto e setembro apresentaram maiores

limitações, principalmente na representação dos extremos pluviométricos (Figura 25). Em maio e junho, a reanálise apresentou desempenho bom, com correlações moderadas a fortes e baixos vieses, além de boa concordância entre observado e reanálise (Tabela 12).

Entretanto, entre julho e setembro ocorreu forte degradação do desempenho, marcada por baixa capacidade explicativa, elevados erros e intensa superestimação da precipitação (Tabela 12). Agosto apresentou o pior resultado estatístico ($NRMSE = 2,31$), com correlação praticamente inexistente e forte amplificação dos extremos pluviométricos pela reanálise.

Em outubro observou-se melhora significativa do desempenho, com viés próximo de zero e maior concordância entre observado e reanálise. Já novembro apresentou desempenho moderado, acompanhado de leve superestimação e maior dispersão da reanálise.

As análises de regressão linear e FAC2 confirmaram tendência sistemática de superestimação pelo MSWEP V2. O coeficiente global de determinação ($R^2 = 0,67$) indicou desempenho intermediário da reanálise, enquanto a inclinação da regressão (1,2083) e a mediana FAT2 ($Y/X = 1,4712$) (Tabela 8), evidenciaram amplificação dos máximos pluviométricos e elevada dispersão relativa entre observado e reanálise (Figura 13b).

Os resultados da ANOVA mostraram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) demonstrou que o desempenho do MSWEP V2 varia conforme as características climáticas regionais (Tabela 4.4).

O MSWEP V2 conseguiu representar parcialmente a sazonalidade da precipitação em Bigene, principalmente nos meses de transição da estação chuvosa. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos severos e da variabilidade interanual durante o pico pluviométrico, especialmente entre julho e setembro.

4.5.1.3 Estação Bissau

A precipitação mensal na estação de Bissau evidenciou desempenho sazonalmente variável do produto MSWEP V2, com melhores resultados entre julho e novembro e maiores limitações em maio e nos períodos associados aos extremos pluviométricos mais intensos.

Em maio, a reanálise apresentou baixo desempenho, com correlação fraca ($r = 0,22$; $R^2 = 0,05$) e subestimação da precipitação ($Bias = -14,87$ mm) (Tabela 13), além de elevada assimetria e discrepância entre observado e reanálise. Em junho

houve melhora parcial, com correlação moderada e significativa, embora persistisse limitada capacidade de representação da variabilidade temporal e dos extremos.

Entre julho e outubro ocorreram os melhores resultados estatísticos da estação. Julho apresentou forte associação linear ($r = 0,64$; $R^2 = 0,41$) e bom desempenho ($NRMSE = 0,99$), embora alguns extremos tenham sido superestimados (Figura 28c,f). Em agosto ocorreu forte superestimação dos máximos pluviométricos ($Bias = 112,57$ mm), acompanhada de elevados erros e maior dispersão nos boxplots (Figura 27d). Setembro apresentou desempenho relativamente satisfatório, enquanto outubro registrou um dos melhores resultados da estação, com forte correlação ($r = 0,660$; $R^2 = 0,436$) e menor $NRMSE$ do período (0,761) (Tabela 13), apesar da subestimação parcial dos extremos mais intensos.

Em novembro, o desempenho permaneceu relativamente bom, com correlação moderada e leve superestimação da precipitação, embora os boxplots (Figura 27g) tenham mostrado maior dispersão da reanálise durante a transição para a estação seca.

As análises de regressão linear e FAT2 reforçaram o bom desempenho global da reanálise em Bissau. O coeficiente global de determinação ($R^2 = 0,85$) indicou elevada concordância entre observado e reanálise, enquanto a inclinação próxima da unidade (1,0420) confirmou boa representação média da precipitação (Tabela 8). Entretanto, permaneceu dispersão significativa nos eventos extremos mais intensos (Figura 13c).

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$), destacando a forte contribuição do fator estação ($F = 58,10$) e da interação entre produto e estação ($F = 2,21$; $p = 0,001$) (Tabela 4.4).

Em geral, o MSWEP V2 apresentou excelente desempenho global na estação de Bissau, conseguindo representar satisfatoriamente a sazonalidade e os padrões médios de precipitação, embora persistam limitações importantes na reprodução quantitativa dos extremos severos durante os períodos mais intensos da estação chuvosa.

4.5.1.4 Estação Bolama

Na estação Bolama evidenciou desempenho sazonalmente variável da reanálise MSWEP V2, com melhores resultados em maio, julho e outubro, enquanto agosto e novembro apresentaram maiores limitações na representação dos extremos pluviométricos e na persistência temporal dos erros.

Nos meses de maio e junho, o desempenho variou entre bom e moderado, com baixos a médios erros absolutos e leve subestimação da precipitação. Em maio, a correlação moderada e significativa ($r = 0,46$; $R^2 = 0,21$) indicou representação razoável da variabilidade temporal, enquanto os boxplots mostraram forte assimetria positiva e ocorrência de extremos superiores a 170 mm (Figura 29a). Em junho, em-

bora os erros tenham aumentado, a correlação permaneceu moderada e significativa ($r = 0,43$), evidenciando representação parcial dos eventos extremos superiores a 300 mm. Os testes estatísticos indicaram, em geral, homogeneidade das variâncias e independência residual satisfatória. Julho apresentou um dos melhores desempenhos da estação, com maior correlação observada ($r = 0,53$; $R^2 = 0,28$) e representação relativamente adequada dos eventos intensos acima do percentil 90 (P90) (Figura 30a). Apesar dos elevados erros absolutos, a reanálise conseguiu reproduzir parte importante da sazonalidade e dos máximos pluviométricos. Em agosto, durante o auge da estação chuvosa, passou a predominar superestimação sistemática da precipitação ($Bias = 68,14$ mm), acompanhada de elevada dispersão nos boxplots (Figura 29a) e maiores discrepâncias entre observado e reanálise.

Em setembro, o desempenho permaneceu moderado, com erros ainda elevados, embora o viés próximo de zero ($Bias = 1,55$ mm) tenha indicado ausência de tendência sistemática importante (Tabela 14). A correlação moderada não apresentou significância estatística ao nível de 5%, indicando limitações na representação da variabilidade temporal. Outubro voltou a apresentar desempenho bom ($NRMSE = 0,82$), com redução significativa dos erros e correlação relativamente forte ($r = 0,567$; $R^2 = 0,321$), embora os extremos severos tenham permanecido parcialmente subestimados. Em novembro, apesar dos menores erros absolutos, o desempenho voltou a ser moderado devido à elevada variabilidade relativa dos baixos volumes pluviométricos e à persistente superestimação das chuvas, além da presença de autocorrelação positiva residual.

De forma geral, o MSWEP V2 apresentou desempenho relativamente satisfatório na estação Bolama, conseguindo representar parcialmente a sazonalidade e parte dos eventos intensos associados ao P90. Entretanto, persistiram limitações importantes na representação quantitativa dos extremos pluviométricos durante os períodos mais intensos da estação chuvosa.

A distribuição dos pontos no diagrama de dispersão mostra um alinhamento consistente ao longo da tendência linear, com a maioria das observações posicionada entre as retas de referência $y = x/2$ e $y = 2x$ (Figura 13d). Ainda assim, observa-se aumento da dispersão para valores mais altos, indicando maior variabilidade da reanálise em eventos mais intensos. A regressão linear e FAT2 reforçaram esse comportamento. O elevado coeficiente de determinação global ($R^2 = 0,89$) (Tabela 8) indicou excelente concordância estatística entre observado e reanálise, enquanto a inclinação da regressão (0,9608) revelou apenas discreta tendência média de subestimação das precipitações mais intensas. Apesar da boa concordância geral, permaneceu dispersão significativa durante eventos extremos.

A ANOVA confirmaram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica

($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$) (Figura 4.4), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) demonstrou que o desempenho do MSWEP V2 varia conforme as características climáticas regionais.

Os resultados mostram que o MSWEP V2 apresentou excelente desempenho global na estação Bolama, embora persistam limitações associadas à reprodução quantitativa dos extremos severos.

4.5.1.5 Estação Catió

A análise da precipitação mensal na estação Catió evidenciou desempenho geralmente limitado da reanálise MSWEP V2 ao longo da estação chuvosa, com forte influência da sazonalidade e dos eventos extremos pluviométricos (Figura 32). De forma geral, observou-se tendência de subestimação das precipitações nos meses iniciais da estação chuvosa e forte superestimação entre julho e novembro, principalmente durante os períodos de transição sazonal.

Nos meses de maio e junho, o desempenho foi moderado, porém associado a erros elevados e baixa capacidade explicativa do modelo. Em maio, a reanálise apresentou forte subestimação da precipitação ($Bias = -86,90$ mm) e correlação praticamente inexistente ($r = 0,025$), indicando incapacidade de representar adequadamente a variabilidade temporal observada. Em junho, embora tenha ocorrido ligeira melhora da correlação ($r = 0,33$), persistiram erros muito elevados e forte subestimação dos eventos extremos acima do percentil 90 (P90) (Tabela 32). Os boxplots mostraram grande discrepância entre observado e reanálise, enquanto os testes estatísticos indicaram distribuições predominantemente não normais, diferenças significativas entre as variâncias e forte autocorrelação positiva dos resíduos.

Entre julho e setembro ocorreu mudança importante no comportamento do produto, passando a predominar superestimação sistemática da precipitação. Julho apresentou superestimação dos máximos pluviométricos e correlação negativa não significativa, enquanto agosto registrou o pior desempenho estatístico da estação ($NRMSE = 2,38$; $Bias = 291,03$ mm), com erros extremamente elevados e baixa capacidade explicativa. Em setembro, apesar da correlação moderada ($r = 0,33$), persistiram elevados erros absolutos e exagero dos extremos simulados pela reanálise. (Figura 31) os boxplots evidenciaram grande dispersão e afastamento entre as distribuições observadas e reanalisadas, enquanto os testes de Durbin-Watson continuaram indicando persistência temporal dos erros.

Outubro e novembro apresentaram os resultados mais críticos associados ao enfraquecimento da estação chuvosa. Em outubro, o MSWEP V2 manteve precipitações elevadas mesmo quando os dados observados mostraram valores próximos de zero, resultando em desempenho extremamente fraco ($NRMSE = 3,16$) e fortíssima auto-

correlação positiva ($DW = 0,1857$). Em novembro, embora os erros absolutos tenham diminuído, o desempenho permaneceu fraco ($NRMSE = 2,78$), devido à persistência de precipitação na reanálise durante um período climatologicamente menos úmidos. Os boxplots mostraram forte diferenças entre as séries, com predominância de valores próximos de zero nas observações e manutenção de eventos moderados na reanálise (Figura 31a).

As análises de regressão linear e FAT2 confirmaram desempenho apenas moderado da reanálise em Catió. O coeficiente de determinação global ($R^2 = 0,57$) indicou baixa capacidade explicativa quando comparada às demais estações, enquanto a inclinação da regressão (0,9196) na (Tabela 8) e o intercepto elevado evidenciaram presença de viés e elevada dispersão dos dados, principalmente durante eventos extremos. Embora parte das estimativas tenha permanecido dentro do critério do fator de dois persistiram desvios significativos associados à superestimação dos máximos pluviométricos. Apesar disso, grande parte das observações permanece dentro do envelope definido pelas retas de referência $y = x/2$ e $y = 2x$ (Figura 14a), indicando concordância geral dentro do critério do fator de dois.

Os resultados da ANOVA mostraram ainda que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$) (Tabela 4.4). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) demonstrou que o desempenho do MSWEP V2 depende fortemente das características climáticas regionais.

Os resultados indicam que o MSWEP V2 apresentou limitações importantes na estação Catió, principalmente na representação quantitativa dos extremos pluviométricos e da variabilidade sazonal da precipitação, devendo ser utilizado com cautela em aplicações hidrológicas e climáticas que exijam elevada precisão quantitativa.

4.5.1.6 Estação Farim

Na estação Farim evidenciou comportamento sazonalmente variável da reanálise MSWEP V2 ao longo da estação chuvosa, com melhor desempenho durante os meses centrais da estação, especialmente em julho e setembro, e maiores limitações no final do período chuvoso, sobretudo em novembro.

Nos meses de maio e junho, o desempenho foi moderado, com baixos a médios erros absolutos e predominância de leve subestimação da precipitação. Em maio, a correlação moderada e significativa ($r = 0,35$; $p = 0,043$) indicou capacidade razoável da reanálise em representar a variabilidade temporal da precipitação, embora os boxplots tenham mostrado distribuições assimétricas e subestimação parcial dos eventos extremos (Figura 33). Em junho, a correlação tornou-se fraca e não significativa ($r = 0,27$), evidenciando limitações na representação da variabilidade interanual. Os

testes de Shapiro-Wilk indicaram ausência de normalidade em maio e comportamento aproximadamente normal em junho, enquanto o teste de Levene revelou homogeneidade das variâncias em maio e diferenças significativas entre as variâncias em junho. O teste de Durbin-Watson indicou independência residual satisfatória em ambos os meses.

Julho apresentou o melhor desempenho estatístico da estação, com $NRMSE = 0,73$, correlação relativamente elevada ($r = 0,68$; $R^2 = 0,465$; $p < 0,001$) e leve superestimação média da precipitação ($Bias = 18,60$ mm). Os boxplots mostraram medianas próximas entre observado e reanálise, além de elevada concentração de eventos intensos típicos do pico da estação chuvosa (Figura 33). Apesar da elevada dispersão associada aos máximos pluviométricos, a reanálise conseguiu representar parcialmente eventos acima do percentil 90 (P90) (Figura 34). Ambas as séries rejeitaram normalidade, o teste de Levene confirmou homogeneidade das variâncias e o Durbin-Watson indicou independência residual satisfatória.

Durante agosto e setembro, os erros aumentaram significativamente em função da intensificação da precipitação. Em agosto, observou-se baixa capacidade de representação da variabilidade temporal, com correlação fraca e não significativa, além de forte dispersão nos boxplots e dificuldades na reprodução dos máximos extremos. Já em setembro, embora o desempenho tenha sido relativamente melhor ($NRMSE = 0,95$), persistiu subestimação dos eventos mais intensos, principalmente dos extremos superiores a 1200 mm observados na série histórica (Figura 34). Os testes estatísticos mostraram predominância de distribuições não normais e, em geral, homogeneidade das variâncias, enquanto o Durbin-Watson indicou independência residual aceitável.


Em outubro, o desempenho permaneceu moderado, com Bias praticamente nulo e redução dos erros absolutos. Entretanto, a correlação entre observado e reanálise permaneceu baixa, indicando limitada capacidade da reanálise em reproduzir a variabilidade temporal da precipitação. Os boxplots mostraram medianas semelhantes entre as séries, porém com maior dispersão e máximos superiores nos dados observados (Figura 34). Em novembro ocorreu o pior desempenho relativo da estação ($NRMSE = 2,99$) (Tabela 16), caracterizado por superestimação persistente da precipitação, forte discrepância entre as distribuições observadas e reanalisadas e ausência praticamente total de associação linear entre as séries. Nesse mês, os testes de Shapiro-Wilk rejeitaram normalidade para ambas as séries, o teste de Levene indicou diferenças significativas entre as variâncias e o Durbin-Watson revelou autocorrelação positiva residual.

As análises de regressão linear e FAT2 confirmaram esse comportamento intermediário da reanálise em Farim. O coeficiente de determinação global ($R^2 = 0,75$) na (Tabela 8) indicou que aproximadamente 75% da variabilidade da reanálise foi


explicada pelos dados observados. Entretanto, a inclinação da regressão inferior à unidade (0,7696) evidenciou tendência sistemática de subestimação das precipitações mais intensas, principalmente durante eventos extremos. Embora a maior parte dos dados tenha permanecido dentro do critério do fator de dois mostrada na (Figura 14b), observou-se aumento da dispersão para valores pluviométricos elevados.

Os resultados da ANOVA mostraram ainda que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) demonstrou que o desempenho do MSWEP V2 depende das características climáticas regionais e da intensidade sazonal das precipitações (Tabela 4.4).


De forma geral, o MSWEP V2 apresentou desempenho relativamente satisfatório na estação Farim durante os meses centrais da estação chuvosa, conseguindo representar parcialmente a sazonalidade e alguns eventos extremos. Contudo, persistiram limitações importantes na representação quantitativa dos máximos pluviométricos, com tendência alternada de subestimação e superestimação dos extremos, além de dificuldades na reprodução da variabilidade interanual da precipitação.




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro


Figura 11 – Distribuição mensal da precipitação na estação de Bafatá para os meses de maio a novembro.




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro


Figura 12 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Bafatá para os meses de maio a novembro.




(a) Estação de Bafatá



(b) Estação de Bigene




(c) Estação de Bissau




(d) Estação de Bolama


Figura 13 – Comparação mensal dos dados de reanálise MSWEP V2 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).




(a) Estação de Catió




(b) Estação de Farim



(c) Estação de Gabú



(d) Estação de Mansabá



(e) Estação de Suzana

Figura 14 – Comparação mensal dos dados de reanálise MSWEP V2 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)

4.5.1.7 Estação Gabú

A análise da precipitação mensal na estação Gabú revelou desempenho sazonalmente variável do MSWEP V2 ao longo da estação chuvosa, com melhores resultados entre maio e agosto e maiores limitações nos meses finais da estação chuvosa. Deste modo, a reanálise conseguiu representar parcialmente a sazonalidade da precipitação e parte dos eventos intensos associados ao percentil 90 (P90) (Figura 36), embora persistissem dificuldades importantes na representação quantitativa dos extremos pluviométricos e da variabilidade interanual.

Em maio, o desempenho foi considerado bom ($NRMSE = 0,78$) na (Tabela 17), com correlação moderadamente forte e significativa ($r = 0,69$; $R^2 = 0,48$) e leve subestimação da precipitação ($Bias = -8,64$ mm). Em junho, observou-se aumento dos erros e redução da capacidade explicativa do modelo ($NRMSE = 1,44$), acompanhado de persistente subestimação da precipitação ($Bias = -40,49$ mm) e baixa correlação entre observado e reanálise.

Durante julho e agosto, a reanálise apresentou desempenho relativamente satisfatório. Julho mostrou correlação significativa ($r = 0,39$) e leve superestimação média ($Bias = 14,60$ mm), enquanto agosto apresentou desempenho bom ($NRMSE = 0,98$) e correlação moderada ($r = 0,49$), embora persistisse tendência de superestimação dos eventos extremos pluviométricos.

Nos meses finais da estação chuvosa, especialmente setembro e outubro, o desempenho voltou a apresentar limitações importantes. Em setembro, a correlação foi praticamente inexistente ($r = -0,008$), evidenciando incapacidade da reanálise em representar adequadamente a variabilidade temporal observada. Em outubro, persistiu forte superestimação da precipitação ($Bias = 42,61$ mm) (Tabela 17), acompanhada de baixa capacidade explicativa do modelo. Em novembro, o desempenho permaneceu moderado a fraco ($NRMSE = 1,34$), apesar dos baixos erros absolutos, devido à baixa magnitude climatológica das precipitações e à persistente superestimação dos máximos pluviométricos.

Os boxplots na (Figura 35) mostraram elevada variabilidade sazonal, forte assimetria positiva e presença frequente de eventos extremos acima do percentil 90 (Figura 36). Em diversos meses, os dados observados apresentaram maior dispersão e máximos superiores aos da reanálise, enquanto em outros períodos o MSWEP V2 apresentou tendência de amplificação dos extremos pluviométricos.

Os testes de Shapiro-Wilk indicaram comportamento variável da normalidade ao longo da estação chuvosa. Maio e novembro rejeitaram normalidade para ambas as séries devido à forte influência dos extremos pluviométricos. Em junho, julho, setembro e outubro predominou distribuição aproximadamente normal para observado e reanálise. O teste de Levene mostrou predominância de homogeneidade das variâncias, embora setembro e novembro tenham apresentado diferenças significativas entre as

dispersões estatísticas. Os valores do teste de Durbin-Watson evidenciaram, em alguns meses, presença de autocorrelação positiva residual, especialmente em junho, agosto, outubro e novembro, indicando persistência temporal dos erros do modelo.

A regressão linear em FAT2 confirmaram desempenho satisfatório da reanálise em Gabú. Na (Tabela 8) o coeficiente de determinação global ($R^2 = 0,82$) indicou forte associação entre observado e reanálise, enquanto a inclinação da regressão (0,9498) revelou leve tendência de subestimação média das precipitações observadas. Apesar da maior parte dos dados permanecer dentro do critério do fator de dois, observou-se aumento da dispersão para eventos pluviométricos mais intensos (Figura 14b).

Os resultados da ANOVA mostraram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$) (Tabela 4.4). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) evidenciou que o desempenho do MSWEP V2 varia conforme as características climáticas regionais e a intensidade sazonal da precipitação.

4.5.1.8 Estação Mansabá

A análise mensal da precipitação na estação Mansabá mostrou que o MSWEP V2 apresentou desempenho geralmente satisfatório entre maio e outubro, com melhores resultados nos meses iniciais e intermediários da estação chuvosa. Nesses meses, o desempenho foi classificado como bom ($NRMSE$ entre 0,90 e 0,97), com correlações moderadas e significativas (r entre 0,38 e 0,49) na (Tabela 18), indicando capacidade razoável de reanálise em representar a variabilidade temporal da precipitação observada. Os valores de Bias permaneceram relativamente baixos, alternando leves subestimações e superestimações dos acumulados pluviométricos.

Os boxplots evidenciaram forte assimetria positiva e presença frequente de eventos extremos acima do percentil 90 (P90) (Figura 37c;d) e (Figura 38c;d), principalmente entre julho e setembro. Apesar de o MSWEP V2 conseguir representar parcialmente a sazonalidade e diversos eventos intensos, os máximos pluviométricos mais severos permaneceram frequentemente subestimados ou suavizados pela reanálise.

Os testes de Shapiro-Wilk mostraram comportamento variável ao longo dos meses analisados. Em maio e novembro, ambas as séries rejeitaram a hipótese de normalidade, evidenciando forte influência de extremos pluviométricos e elevada assimetria. Em junho e setembro, observou-se distribuição aproximadamente normal para observado e reanálise, enquanto em agosto apenas os dados observados rejeitaram normalidade devido à influência dos extremos superiores a 1000 mm (Figura 38d). O teste de Levene indicou predominância de homogeneidade das variâncias, embora setembro tenha apresentado diferenças significativas entre as dispersões ($p = 0,0280$). Os valores do teste de Durbin-Watson ficaram, em geral, próximos de 2, indicando

independência residual satisfatória, exceto em agosto e novembro, quando ocorreu autocorrelação positiva moderada dos resíduos.

Agosto correspondeu ao período de pior desempenho estatístico da estação, associado ao pico da estação chuvosa. a reanálise apresentou desempenho moderado ($NRMSE = 1,25$), correlação fraca e não significativa ($r = 0,19$; $R^2 = 0,038$) e forte superestimação da precipitação ($Bias = 97,49$ mm). Os erros elevados ($MAE = 158,24$ mm; $RMSE = 196,84$ mm) evidenciaram dificuldade de reanálise em representar adequadamente os extremos superiores a 1000 mm observados durante o período (Figura 38d).

Em novembro, durante a transição para a estação seca, o desempenho voltou a diminuir ($NRMSE = 1,23$), apesar dos baixos erros absolutos, devido à baixa magnitude climatológica das precipitações. A correlação foi fraca e não significativa ($r = 0,30$), enquanto os boxplots mostraram predominância de valores próximos de zero nas observações e maior persistência de precipitação na reanálise, indicando tendência de superestimação dos eventos moderados (Figura 37d).

O FAT2 confirmaram o desempenho geral satisfatório da reanálise na estação Mansabá. A maior parte dos dados permaneceu dentro do critério do fator de dois, embora a dispersão aumentasse significativamente para eventos extremos (Figura 14d). O coeficiente de determinação global ($R^2 = 0,79$) indicou forte associação entre observado e reanálise na (Tabela 8), enquanto a inclinação da regressão (0,9350) revelou leve tendência média de subestimação das precipitações mais elevadas.

Os resultados da ANOVA mostraram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$) na (Tabela 4.4). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) evidenciou que o desempenho do MSWEP V2 varia conforme as características climáticas regionais e a intensidade sazonal da precipitação.

Estação	R²	Inclinação	Intercepto (mm)	Mediana Y/X	IQR	Fator 2 (%)
Bafatá	0.84	1.06	8.86	1.10	0.59	23.6
Bigene	0.67	1.21	20.28	1.47	1.28	37.8
Bissau	0.85	1.04	3.00	1.02	0.68	18.3
Bolama	0.89	0.96	11.24	0.99	0.62	17.2
Catió	0.57	0.92	55.29	1.42	1.44	33.5
Farim	0.75	0.77	26.40	1.06	0.68	19.0
Gabú	0.82	0.95	12.09	1.05	0.70	18.5
Mansabá	0.79	0.94	16.27	1.13	0.73	28.0
Suzana	0.82	0.84	9.11	0.88	0.60	8.8

Tabela 8 – Resumo comparativo do desempenho da reanálise em relação MSWEP V2 aos dados observados para as estações analisadas.

4.5.1.9 Estação Suzana

A estação Suzana mostrou que a reanálise MSWEP V2 apresentou desempenho variável entre maio e novembro, com melhores resultados em setembro e outubro, e maiores limitações durante maio, julho e agosto. De forma geral, o produto conseguiu representar parcialmente a sazonalidade da precipitação, porém persistiram dificuldades importantes na reprodução da magnitude dos extremos pluviométricos.

Em maio, julho e agosto predominou forte subestimação da precipitação, com Bias negativos de $-19,36$ mm, $-1,14$ mm e $-73,34$ mm, respectivamente na (Tabela 19). Agosto apresentou um dos desempenhos mais críticos da estação, com elevados erros ($MAE = 148,57$ mm; $RMSE = 183,35$ mm) e correlação fraca e não significativa ($r = 0,226$; $R^2 = 0,051$), evidenciando baixa capacidade da reanálise em representar os extremos superiores a 900 mm observados durante o pico da estação chuvosa (Figura 39).

Junho e setembro apresentaram desempenho moderado, Em junho ocorreu comportamento oposto, com superestimação significativa ($Bias = 34,64$ mm), com correlações significativas ($r = 0,55$ e $r = 0,48$), permitindo representação parcial da variabilidade temporal e dos eventos intensos. Outubro correspondeu ao melhor desempenho estatístico da estação, com $NRMSE = 0,89$ na (Tabela 19), forte correlação ($r = 0,72$; $R^2 = 0,52$) e elevada significância estatística ($p < 0,001$), indicando boa sincronização temporal entre observado e reanálise, embora os extremos severos ainda tenham sido subestimados com Bias negativo $-42,76$.

Os boxplots mostraram elevada assimetria positiva, grande dispersão e forte influência de eventos extremos acima do percentil 90 (P90) (Figura 40) e (Figura 39). Em diversos meses, a reanálise apresentou distribuição mais suavizada que os dados observados, evidenciando tendência da reanálise em suavizar ou amplificar eventos extremos altamente localizados.

Os testes de Shapiro-Wilk indicaram comportamento variável da normalidade. Maio, junho e novembro rejeitaram normalidade para ambas as séries, refletindo forte influência dos extremos pluviométricos. Em julho e outubro apenas os dados de reanálise apresentaram distribuição não normal, enquanto setembro apresentou normalidade para ambas as séries. O teste de Levene mostrou predominância de homogeneidade das variâncias, embora maio e agosto tenham apresentado diferenças significativas entre as dispersões estatísticas. Os valores do teste de Durbin-Watson revelaram, em vários meses, presença de autocorrelação positiva residual, especialmente em maio ($DW = 1,06$), agosto ($DW = 1,37$) e outubro ($DW = 1,14$), indicando persistência temporal dos erros do modelo.

As análises de regressão linear e FAT2 confirmaram desempenho geral satisfatório da reanálise na estação Suzana. O coeficiente de determinação global ($R^2 = 0,82$) indicou forte associação entre observado e reanálise, enquanto a inclinação da regressão (0,8424) na (Tabela 8) revelou tendência sistemática de subestimação das precipitações mais intensas. Embora a maioria dos pontos tenha permanecido dentro do critério do fator de dois, observou-se aumento significativo da dispersão para valores elevados de precipitação (Figura 14e).

Os resultados da ANOVA mostraram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) (Tabela 4.4), evidenciou que o desempenho do MSWEP V2 varia conforme as características climáticas regionais e a intensidade sazonal da precipitação.

4.5.2 Reanálise ERA5

4.5.2.1 Estação de Bafatá

Na estação de Bafatá mostrou que a reanálise ERA5 apresentou desempenho sazonalmente variável ao longo da estação chuvosa, conseguindo representar parcialmente a sazonalidade pluviométrica regional, embora persistam limitações importantes na reprodução dos extremos severos e da variabilidade interanual.

Entre maio e julho ocorreram os melhores resultados estatísticos da estação. Maio apresentou desempenho satisfatório ($NRMSE = 0,98$), enquanto julho registrou o melhor desempenho global ($NRMSE = 0,87$), com correlação moderadamente forte ($r = 0,60$) e Bias próximo de zero ($-2,96$ mm) (Tabela 20), indicando boa representação da variabilidade temporal da precipitação. Os boxplots desses meses mostraram maior proximidade entre observado e reanálise, embora os extremos pluviométricos mais intensos permanecessem parcialmente subestimados (Figura 41a;c).

Entre agosto e setembro observaram-se as maiores limitações do ERA5. Os boxplots evidenciaram elevada dispersão, forte assimetria positiva e máximos observa-

dos superiores a 500 mm na (Figura 41d,f), enquanto a reanálise apresentou distribuição mais suavizada e menor intensidade dos extremos. Setembro apresentou o pior desempenho estatístico ($NRMSE = 1,55$), correlação praticamente inexistente ($r = 0,04$) e forte subestimação da precipitação ($Bias = -84,54$ mm), demonstrando baixa capacidade de reanálise em reproduzir adequadamente os eventos extremos acima do percentil 90 (P90) (Figura 42d,f). A série temporal confirmou elevada variabilidade interanual e ocorrência frequente de extremos severos, sobretudo após 2005.

Em outubro e novembro ocorreu melhora parcial do desempenho estatístico. Novembro apresentou correlação relativamente melhor e leve superestimação da precipitação, embora persistisse aumento da dispersão nos dados de reanálise durante o período de transição para a estação seca. De forma geral, os valores de MAE e RMSE na (Tabela 20) aumentaram significativamente nos meses mais chuvosos, refletindo forte influência dos extremos pluviométricos sobre os erros do modelo.

Os testes estatísticos mostraram predominância de distribuições não normais em vários meses, evidenciando forte influência dos extremos climáticos sobre a distribuição das séries. O teste de Levene indicou homogeneidade das variâncias em parte do período analisado, enquanto o teste de Durbin–Watson revelou independência residual satisfatória em julho e autocorrelação positiva moderada em alguns meses da estação chuvosa.

O FAC2 confirmaram desempenho global satisfatório da reanálise em Bafatá. O coeficiente global de determinação ($R^2 = 0,84$) indicou forte associação entre observado e reanálise (Figura 15a), enquanto a inclinação da regressão (0,76) revelou tendência sistemática de subestimação das precipitações mais intensas (Tabela 9). A análise FAT2 reforçou essa limitação, mostrando baixa aderência ao critério ideal do fator 2 (Figura 15a), especialmente durante eventos extremos de maior magnitude.

Os resultados da ANOVA mostraram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$) (Tabela 4.4). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) evidenciou que o desempenho da reanálise ERA5 varia conforme as características climáticas regionais.

De forma geral, o ERA5 apresentou desempenho moderado a bom na estação de Bafatá, conseguindo reproduzir parcialmente a sazonalidade pluviométrica e parte dos eventos intensos. Entretanto, persistiram limitações importantes na representação quantitativa dos extremos severos, principalmente durante o pico da estação chuvosa.

4.5.2.2 Estação de Bigene

A análise mensal da precipitação na estação de Bigene evidenciou que a reanálise ERA5 apresentou desempenho sazonalmente variável ao longo da estação chuvosa,

conseguindo representar parcialmente a sazonalidade pluviométrica regional, embora persistam limitações importantes na reprodução dos extremos severos e da variabilidade interanual da precipitação.

Entre maio, junho e outubro ocorreram os melhores resultados estatísticos da estação, com desempenho classificado como bom e correlações moderadas. Maio apresentou o melhor ajuste geral ($NRMSE = 0,788$; $r = 0,6982$; $R^2 = 0,4875$) (Tabela 20), indicando capacidade relativamente satisfatória de representação da variabilidade temporal da precipitação. Os boxplots desses meses mostraram maior proximidade entre observado e reanálise, embora persistisse subestimação dos maiores extremos pluviométricos (Figura 41).

Entre julho e setembro ocorreram as maiores limitações do ERA5, coincidentes com o pico da estação chuvosa. Os boxplots evidenciaram elevada dispersão, forte assimetria positiva e ocorrência frequente de extremos acima do percentil 90 (P90) (Figura 42). Durante esse período, a reanálise apresentou forte superestimação dos acumulados pluviométricos, incluindo máximos superiores a 600 mm, especialmente em 2020, comportamento não observado nos dados reais. Agosto apresentou o pior desempenho da série, com correlação praticamente inexistente ($r = 0,0609$; $R^2 = 0,0037$), elevado RMSE e forte superestimação sistemática da precipitação ($Bias = 134,96$ mm). Setembro também apresentou baixa capacidade explicativa e persistência da superestimação dos extremos severos.

Em novembro, o desempenho permaneceu moderado, com persistência da superestimação dos acumulados pluviométricos e aumento da dispersão entre observado e reanálise durante a transição para a estação seca. A análise temporal confirmou elevada variabilidade interanual ao longo de toda a estação chuvosa, mostrando que o ERA5 conseguiu acompanhar parcialmente a sazonalidade da precipitação, porém com limitações importantes na intensidade dos extremos severos.

Os testes estatísticos mostraram predominância de distribuições não normais em grande parte dos meses analisados, refletindo forte influência dos extremos pluviométricos sobre a distribuição das séries. O teste de Levene indicou homogeneidade das variâncias na maior parte do período, enquanto o teste de Durbin–Watson revelou independência residual relativamente satisfatória em maio e novembro, mas forte autocorrelação positiva entre julho e setembro, indicando persistência temporal dos erros durante o pico da estação chuvosa.

O coeficiente global de determinação ($R^2 = 0,67$) indicou associação moderada a forte entre observado e reanálise. A inclinação próxima da unidade (1,03) mostrou boa aproximação média entre as séries, embora a mediana da razão Y/X ($\approx 1,39$) evidencie tendência de superestimação da precipitação mensal (Tabela 9). O FAT2 mostram desempenho global moderado da reanálise em Bigene. No entanto mostrou concordância relativamente melhor em comparação a outras estações, embora ainda

persistam dispersões no dados na (Figura 15b).

Os resultados da ANOVA mostraram que tanto os produtos de precipitação quanto as estações meteorológicas influenciaram significativamente a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total ($F = 58,10$) (Tabela 4.4), enquanto a interação significativa entre produto e estação ($F = 2,21$; $p = 0,001$) evidenciou que o desempenho da reanálise ERA5 varia conforme as características climáticas regionais.

Deste modo, o ERA5 apresentou desempenho moderado na estação de Bigene, conseguindo representar parcialmente a sazonalidade da precipitação e parte da variabilidade temporal observada. Entretanto, persistiram limitações importantes na representação quantitativa dos extremos severos e da magnitude máxima das precipitações, principalmente durante o pico da estação chuvosa entre julho e setembro.

4.5.2.3 Estação de Bissau

A precipitação na estação de Bissau mostrou que a reanálise ERA5 apresentou desempenho sazonal variável, com melhores resultados entre julho, agosto e outubro, enquanto maio, junho e setembro apresentaram maiores limitações na representação dos extremos pluviométricos.

Os boxplots evidenciaram forte assimetria positiva, elevada dispersão dos dados observados e tendência da reanálise em suavizar os máximos pluviométricos (Figura 41), principalmente nos eventos acima do percentil 90 (P90) (Figura 42). A análise temporal mostrou forte variabilidade interanual, com melhor concordância entre observado e ERA5 durante o pico da estação chuvosa.

Entre julho e agosto ocorreram os melhores desempenhos estatísticos, com correlações significativas e representação relativamente satisfatória da sazonalidade da precipitação. Em contrapartida, maio, junho e setembro apresentaram correlações fracas, maiores erros e persistente subestimação dos extremos severos. Outubro mostrou melhora importante do desempenho, enquanto novembro apresentou superestimação das chuvas moderadas durante a transição para a estação seca, e com o bom desempenho também.

Os testes estatísticos indicaram predominância de distribuições não normais em vários meses devido à influência dos extremos pluviométricos. O teste de Levene mostrou homogeneidade das variâncias na maior parte do período, enquanto o Durbin–Watson indicou autocorrelação positiva dos resíduos principalmente em junho e novembro.

As análises de regressão linear e FAT2 confirmaram desempenho global satisfatório do ERA5 em Bissau, com elevado coeficiente de determinação global ($R^2 = 0,86$) (Tabela 9), embora persistisse tendência de subestimação das precipitações mais intensas como mostra na (Figura 15c). Os resultados da ANOVA também mostraram

influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$) (Tabela 4.4).

Em geral, o ERA5 conseguiu representar parcialmente a sazonalidade e a variabilidade temporal da precipitação em Bissau, mas apresentou limitações importantes na reprodução quantitativa dos extremos severos durante os períodos mais intensos da estação chuvosa.

4.5.2.4 Estação de Bolama

A análise integrada da precipitação na estação de Bolama evidenciou forte sazonalidade pluviométrica e desempenho predominantemente moderado do ERA5 ao longo da estação chuvosa. Os melhores resultados ocorreram em maio e outubro, enquanto julho, agosto e setembro apresentaram maiores limitações associadas ao pico pluviométrico e à representação dos extremos severos.

Os boxplots mostraram elevada variabilidade interanual (Figura 47), forte assimetria positiva e maior dispersão nos dados observados, sobretudo entre julho e setembro. Nesse período ocorreram diversos eventos acima do percentil 90 (P90) (Figura 48), com máximos próximos de 800 mm, 1000 mm e 680 mm, frequentemente subestimados pelo ERA5. As séries temporais também evidenciaram dificuldade da reanálise em reproduzir adequadamente os maiores extremos pluviométricos durante o auge da estação chuvosa.

Entre maio e outubro ocorreram os melhores resultados estatísticos da estação. Maio apresentou desempenho bom ($NRMSE = 0,91$) na (Tabela 23), correlação moderada ($r = 0,46$) e erros relativamente baixos, embora persistisse leve subestimação dos extremos. Outubro correspondeu ao melhor desempenho geral, com $NRMSE = 0,82$, correlação moderada ($r = 0,55$) e Bias próximo de zero, indicando melhor equilíbrio entre observado e reanálise. Entre junho e setembro o desempenho permaneceu moderado, mas com aumento expressivo dos erros absolutos durante o pico da estação chuvosa. Julho e agosto apresentaram os maiores desvios na (Tabela 23), com RMSE superiores a 160 mm e forte viés negativo, evidenciando subestimação sistemática das precipitações extremas na (Figura 48), embora o ERA5 ainda tenha conseguido representar parcialmente a variabilidade temporal da precipitação. Em novembro, durante a transição para a estação seca, observou-se superestimação das chuvas moderadas e predominância de baixos acumulados observados.

Os testes estatísticos mostraram predominância de distribuições não normais em vários meses devido à forte influência dos extremos pluviométricos e da elevada assimetria das séries. O teste de Levene indicou homogeneidade das variâncias na maior parte dos meses, enquanto o teste de Durbin–Watson revelou autocorrelação positiva principalmente em julho, agosto e novembro, indicando persistência temporal dos erros durante os períodos mais chuvosos.

A regressão linear e FAT2 confirmaram desempenho global satisfatório do ERA5 em Bolama. O elevado coeficiente de determinação global ($R^2 = 0,87$) (Tabela 9) indicou forte associação entre observado e reanálise, enquanto a inclinação da regressão inferior à unidade (0,77) revelou tendência sistemática de subestimação das precipitações mais intensas na (Figura 15d). A análise FAT2 também mostrou concordância moderada entre as séries, embora persistisse dispersão significativa nos eventos extremos.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$), destacando forte contribuição do fator estação e da interação entre produto e estação (Tabela 4.4).

O ERA5 conseguiu representar parcialmente a sazonalidade e a variabilidade temporal da precipitação em Bolama, apresentando melhor desempenho nos meses de menor intensidade pluviométrica. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos severos durante o pico da estação chuvosa.

4.5.2.5 Estação de Catió

A estação de Catió evidenciou forte variabilidade sazonal e desempenho predominantemente limitado do ERA5 na representação da precipitação observada. De forma geral, os maiores problemas ocorreram durante o pico da estação chuvosa e na transição para a estação seca, quando a reanálise apresentou dificuldades importantes na reprodução dos extremos pluviométricos e da variabilidade interanual.

Os boxplots mostraram elevada assimetria positiva (Figura 49), ampla dispersão dos dados observados e ocorrência frequente de extremos acima do percentil 90 (P90) (Figura 50), principalmente entre junho e setembro. As séries temporais evidenciaram que o ERA5 frequentemente suavizou os máximos pluviométricos, subestimando eventos severos no início da estação chuvosa e superestimando precipitações durante os meses finais.

Entre maio e julho predominou forte subestimação da precipitação. Maio apresentou correlação praticamente inexistente ($r = 0,025$), desempenho moderado ($NRMSE = 1,34$) e forte viés negativo ($Bias = -92,95$ mm) (Tabela 24), indicando baixa capacidade do ERA5 em representar os extremos convectivos do início da estação chuvosa. Junho apresentou os maiores erros absolutos da série, com RMSE superior a 300 mm e severa subestimação dos eventos extremos acima de 800 mm. Julho manteve desempenho moderado, porém com persistência da subestimação dos máximos pluviométricos.

Agosto correspondeu ao período de melhor concordância relativa entre observado e reanálise. Os boxplots mostraram medianas e amplitudes interquartis mais próximas entre as séries (Figura 31), além de melhor sincronização temporal dos eventos

intensos. Apesar disso, o desempenho permaneceu moderado, com baixa correlação e persistência da subestimação dos extremos severos.

Entre setembro e novembro ocorreu mudança no comportamento do modelo, passando a predominar superestimação sistemática da precipitação. Setembro apresentou forte exagero dos acumulados pluviométricos, enquanto outubro correspondeu a um dos piores desempenhos da série ($NRMSE = 2,33$), com incapacidade do ERA5 em representar adequadamente a redução sazonal das chuvas. Em novembro, o desempenho permaneceu fraco ($NRMSE = 2,76$) na (Tabela 24), com persistência de superestimação e grande discrepância entre observado e reanálise, já que os dados observados permaneceram próximos de zero enquanto o ERA5 manteve precipitações frequentes.

Os testes estatísticos mostraram predominância de distribuições não normais devido à forte influência dos extremos pluviométricos e da elevada assimetria das séries. O teste de Levene revelou diferenças significativas entre as variâncias em vários meses, indicando inconsistências na dispersão estatística entre observado e reanálise. Já o teste de Durbin–Watson indicou predominância de autocorrelação positiva, principalmente em junho, outubro e novembro, evidenciando persistência temporal dos erros do modelo. O FAT2 confirmaram desempenho apenas moderado do ERA5 em Catió. O coeficiente global de determinação ($R^2 = 0,58$) indicou associação linear moderada entre observado e reanálise, enquanto a inclinação da regressão inferior à unidade (0,71) revelou tendência sistemática de subestimação das precipitações mensais (Tabela 9). A análise FAT2 também mostrou concordância limitada e elevada dispersão (Figura 16a), especialmente nos eventos mais intensos.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$), (Tabela 4.4) destacando forte contribuição do fator estação e da interação entre produto e estação.

No entanto geral, o ERA5 apresentou desempenho limitado na estação de Catió, com dificuldades importantes na representação quantitativa dos extremos pluviométricos e da sazonalidade da precipitação, especialmente durante os períodos de máxima intensidade chuvosa e transição para a estação seca.

4.5.2.6 Estação de Farim

A análise da precipitação na estação de Farim evidenciou elevada variabilidade sazonal e forte influência dos extremos pluviométricos sobre o desempenho do ERA5. De forma geral, o produto apresentou desempenho variando entre bom e moderado ao longo da estação chuvosa, embora persistam limitações importantes na representação quantitativa dos máximos pluviométricos.

Os boxplots mostraram predominância de distribuições assimétricas positivas, com

presença frequente de outliers extremos, sobretudo entre julho e setembro, período correspondente ao pico da estação chuvosa (Figura 51). Os dados observados apresentaram maior dispersão e máximos pluviométricos muito superiores aos simulados pelo ERA5, evidenciando tendência de suavização dos extremos pela reanálise.

Entre maio e julho ocorreram os melhores resultados estatísticos da estação. Maio apresentou desempenho bom ($NRMSE = 0,96$), embora com leve subestimação dos eventos extremos acima do percentil 90 (P90) (Figura 52). Junho mostrou aumento da variabilidade pluviométrica, acompanhado de piora do desempenho estatístico, baixa correlação e persistência da subestimação dos máximos observados. Julho apresentou uma das melhores concordâncias entre observado e reanálise, com forte correlação ($r = 0,68$) e baixo NRMSE ($0,72$) (Tabela 25), indicando boa capacidade do ERA5 em representar a variabilidade temporal da precipitação, apesar da persistência de subestimação dos máximos absolutos.

Durante agosto e setembro ocorreu intensificação significativa dos extremos climáticos, com máximos superiores a 900 mm e 1200 mm, respectivamente (Figura 52). Nesses meses, o ERA5 conseguiu representar parcialmente a variabilidade temporal da precipitação, porém apresentou forte subestimação dos eventos severos, refletida pelos elevados erros estatísticos e vieses negativos persistentes. Em agosto, a correlação não apresentou significância estatística, evidenciando baixa capacidade explicativa do modelo durante o auge da estação chuvosa.

Outubro apresentou desempenho moderado, ainda com dificuldades na representação da variabilidade temporal e dos extremos severos. Em novembro ocorreu o pior desempenho da série, com NRMSE extremamente elevado ($2,78$) e correlação praticamente inexistente ($r = -0,02$) na (Tabela 25). Nesse período, os dados observados permaneceram próximos de zero, enquanto o ERA5 apresentou precipitações persistentes e máximos superiores às observações, indicando superestimação durante a transição para a estação seca.

Os testes estatísticos mostraram predominância de distribuições não normais nos meses mais extremos, refletindo forte influência da assimetria positiva e dos eventos convectivos severos. O teste de Levene revelou diferenças significativas entre as variâncias em vários meses, principalmente entre junho e novembro, indicando inconsistências na dispersão estatística entre observado e reanálise. Já o teste de Durbin–Watson mostrou predominância de independência residual, embora setembro e novembro tenham apresentado autocorrelação positiva dos resíduos.

A regressão linear e FAT2 confirmaram desempenho global satisfatório do ERA5 em Farim. O coeficiente global de determinação ($R^2 = 0,76$) indicou forte associação entre observado e reanálise (Figura 16b), enquanto a inclinação da regressão inferior à unidade ($0,68$) revelou tendência sistemática de subestimação das precipitações mais intensas (Tabela 9). A análise FAT2 mostrou boa aproximação média entre os

conjuntos de dados, embora persistisse dispersão significativa nos eventos extremos.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$), (Tabela 4.4) destacando forte contribuição do fator estação e da interação entre produto e estação.

O ERA5 apresentou capacidade razoável de representar a sazonalidade e parte da variabilidade temporal da precipitação em Farim, especialmente durante julho. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos severos, com tendência predominante de subestimação durante o pico da estação chuvosa e superestimação durante a transição para a estação seca.







Figura 15 – Comparação mensal dos dados de reanálise ERA5 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).




(a) Estação de Catió




(b) Estação de Farim



(c) Estação de Gabú



(d) Estação de Mansabá



(e) Estação de Suzana

Figura 16 – Comparação mensal dos dados de reanálise ERA5 sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)

4.5.2.7 Estação de Gabú

A precipitação na estação de Gabú evidenciou forte variabilidade sazonal e elevada ocorrência de extremos pluviométricos ao longo da estação chuvosa. E geral, o ERA5 apresentou desempenho variando entre bom, moderado e fraco, conseguindo representar parcialmente a sazonalidade e parte da variabilidade temporal da precipitação, embora persistam limitações importantes na reprodução quantitativa dos extremos severos. Os boxplots mostraram maior dispersão, amplitudes interquartis elevadas e ocorrência frequente de outliers extremos nos dados observados, sobretudo entre julho e setembro, período correspondente ao pico da estação chuvosa (Figura 53). Em praticamente todos os meses, o ERA5 apresentou distribuição mais compacta e suavizada, evidenciando tendência predominante de subestimação dos máximos pluviométricos, embora em alguns períodos tenha ocorrido superestimação pontual dos extremos anuais.

Entre maio e agosto ocorreram os melhores resultados estatísticos da estação. Maio apresentou desempenho bom ($NRMSE = 0,84$), forte correlação linear ($r = 0,71$) na (Tabela 26) e capacidade razoável de representar a sazonalidade da precipitação, embora os eventos extremos tenham permanecido subestimados na (Figura 54). Junho apresentou aumento expressivo da variabilidade interanual e piora do desempenho estatístico, com forte subestimação da precipitação e ausência de significância estatística da correlação. Julho mostrou uma das melhores concordâncias entre observado e ERA5, com medianas relativamente próximas e representação satisfatória dos eventos intensos, apesar da leve superestimação de alguns máximos anuais. Agosto correspondeu ao melhor desempenho geral durante o pico da estação chuvosa, apresentando boa representação da sazonalidade, correlação moderada e distribuição aproximadamente normal para ambas as séries, embora os máximos extremos ainda tenham sido parcialmente subestimados.

Em setembro ocorreu deterioração significativa do desempenho estatístico. Apesar da elevada variabilidade pluviométrica e da frequência de extremos acima do percentil 90 (P90) (Figura 54), o ERA5 apresentou correlação negativa e praticamente inexistente ($r = -0,09$) na (Tabela 26), além de forte subestimação dos máximos anuais. Outubro apresentou desempenho moderado, com leve superestimação média da precipitação e persistência de limitações na representação da variabilidade temporal observada. Em novembro ocorreu o pior desempenho da série, com predominância de valores observados próximos de zero, enquanto o ERA5 manteve precipitações persistentes e medianas superiores às observações, evidenciando superestimação durante a transição para a estação seca.

Os testes estatísticos mostraram predominância de distribuições não normais nos meses com maior influência dos extremos pluviométricos, especialmente em maio e novembro. O teste de Levene revelou diferenças significativas entre as variâncias em

diversos períodos, indicando inconsistências na dispersão estatística entre observado e reanálise. Já o teste de Durbin–Watson mostrou predominância de independência residual satisfatória, embora junho, outubro e novembro tenham apresentado autocorrelação positiva dos resíduos.

As análises de regressão linear e FAT2 confirmaram desempenho global satisfatório do ERA5 em Gabú. O coeficiente global de determinação ($R^2 = 0,79$) indicou forte associação entre observado e reanálise na (Figura 16c), enquanto a inclinação da regressão inferior à unidade (0,80) revelou tendência sistemática de subestimação das precipitações mais intensas (Tabela 9). A análise mostrou concordância moderada entre as séries, embora persistisse elevada dispersão nos eventos extremos. Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$) (Tabela 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.

De modo geral, o ERA5 apresentou capacidade razoável de representar a sazonalidade e parte da variabilidade temporal da precipitação em Gabú, especialmente durante julho e agosto. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos mais severos, com tendência predominante de subestimação durante o pico da estação chuvosa e superestimação na transição para a estação seca.

Estação	R^2	Inclinação	Intercepto (mm)	Mediana Y/X	IQR	Fator 2 (%)
Bafatá	0.84	0.76	6.5	0.81	0.51	5.4
Bigene	0.67	1.03	17.4	1.39	1.22	36.2
Bissau	0.86	0.82	8.2	0.86	0.58	7.0
Bolama	0.87	0.77	15.8	0.90	0.65	11.0
Catió	0.58	0.71	43.6	1.25	1.28	17.6
Farim	0.76	0.68	18.3	0.98	0.62	12.4
Gabú	0.79	0.80	14.6	0.93	0.66	16.4
Mansabá	0.81	0.78	11.5	0.90	0.70	17.7
Suzana	0.83	0.67	7.5	0.70	0.46	7.8

Tabela 9 – Resumo comparativo dos indicadores estatísticos da relação entre precipitação observada e reanálise ERA5 nas estações analisadas.

4.5.2.8 Estação de Mansabá

Na estação de Mansabá evidenciou forte variabilidade sazonal e elevada ocorrência de extremos pluviométricos ao longo da estação chuvosa. Para esta estação ERA5 apresentou desempenho variando entre bom e moderado, conseguindo representar satisfatoriamente a sazonalidade e parte da variabilidade temporal da precipitação,

embora persistam limitações importantes na reprodução quantitativa dos máximos pluviométricos observados.

Os boxplots (Figura 55) mostraram maior dispersão, amplitudes interquartis elevadas e ocorrência frequente de outliers extremos nos dados observados, principalmente entre julho e setembro, período correspondente ao pico da estação chuvosa. Em praticamente todos os meses, o ERA5 apresentou distribuição mais homogênea e suavizada, evidenciando tendência predominante de subestimação dos máximos pluviométricos observados.

Entre maio e julho ocorreram os melhores resultados estatísticos da estação. Em maio, o ERA5 apresentou desempenho bom ($NRMSE = 0,92$), erros relativamente baixos e correlação moderada ($r = 0,47$) na (Tabela 27), embora tenha subestimado os extremos mais intensos superiores a 50 mm. Em junho observou-se aumento expressivo da variabilidade pluviométrica e piora moderada do desempenho estatístico, acompanhada de forte subestimação da precipitação e dificuldade na representação dos eventos extremos acima de 250mm (Figura 56). Julho apresentou uma das melhores concordâncias entre observado e reanálise, com amplitudes relativamente semelhantes entre as séries, correlação significativa e representação satisfatória da variabilidade temporal, apesar da persistência de subestimação dos máximos absolutos.

Durante agosto ocorreu o pico climatológico da estação chuvosa, marcado pelos maiores volumes pluviométricos e elevada irregularidade interanual. Os dados observados apresentaram extremos superiores a 1000mm na (Figura 56), enquanto o ERA5 representou adequadamente a tendência média da precipitação, porém suavizou os maiores máximos observados. O desempenho foi apenas moderado, com baixa correlação linear e ausência de significância estatística da associação entre as séries, evidenciando dificuldades do modelo na reprodução dos extremos convectivos mais severos.

Em setembro e outubro o ERA5 voltou a apresentar desempenho relativamente satisfatório. Setembro mostrou $NRMSE$ de 0,96 na (Tabela 27) e correlação moderada significativa, embora persistisse subestimação sistemática dos máximos pluviométricos superiores a 500mm (Figura 56).

Outubro apresentou redução gradual da precipitação associada ao enfraquecimento da estação chuvosa (Figura 55), com desempenho relativamente bom e reprodução razoável dos padrões médios da precipitação, apesar da continuidade das limitações na representação dos extremos severos. Em novembro, caracterizado por baixos acumulados médios e elevada irregularidade interanual, o ERA5 apresentou desempenho moderado, leve superestimação média e baixa capacidade explicativa da variabilidade temporal, embora tenha conseguido representar parcialmente os padrões médios da precipitação.

Os testes estatísticos mostraram predominância de distribuições não normais nos

meses mais influenciados pelos extremos climáticos, especialmente em maio, agosto e novembro. O teste de Levene indicou homogeneidade das variâncias em diversos períodos, embora diferenças significativas tenham sido observadas principalmente entre agosto e outubro, evidenciando inconsistências do ERA5 na representação da dispersão estatística dos extremos. Já o teste de Durbin–Watson revelou predominância de independência residual satisfatória, com apenas alguns meses apresentando autocorrelação positiva moderada.

As análises de regressão linear e FAT2 confirmaram desempenho global satisfatório do ERA5 em Mansabá. O coeficiente global de determinação ($R^2 = 0,81$) na (Figura 16d), indicou forte associação entre observado e reanálise, enquanto a inclinação da regressão inferior à unidade (0,78) revelou tendência sistemática de subestimação das precipitações mais intensas (Tabela 9). A análise FAT2 mostrou concordância moderada entre as séries, embora persistisse dispersão crescente nos eventos extremos.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$), destacando forte contribuição do fator estação e da interação entre produto e estação (Tabela 4.4).

Em geral, o ERA5 apresentou capacidade satisfatória de representar a sazonalidade e parte da variabilidade temporal da precipitação em Mansabá, sobretudo durante julho e setembro. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos severos, com tendência predominante de subestimação dos máximos observados durante o pico da estação chuvosa.

4.5.2.9 Estação de Suzana

A análise da precipitação extrema na estação de Suzana evidenciou elevada variabilidade interanual, forte influência dos eventos extremos e grande irregularidade sazonal ao longo da estação chuvosa. O ERA5 apresentou desempenho variando entre bom, moderado e fraco, conseguindo representar parcialmente a sazonalidade e parte da variabilidade temporal da precipitação, embora persistam limitações importantes na reprodução quantitativa dos máximos pluviométricos observados.

A (Figura 57) os boxplots mostraram predominância de distribuições assimétricas, elevada dispersão dos dados observados e ocorrência frequente de outliers extremos, principalmente entre julho e setembro, período correspondente ao pico da estação chuvosa. Em praticamente todos os meses, os dados observados apresentaram amplitudes interquartis superiores às da reanálise, indicando maior variabilidade pluviométrica observada em comparação ao ERA5. A reanálise apresentou comportamento mais suavizado, com tendência predominante de subestimação dos máximos pluviométricos.

Entre maio e junho ocorreu a consolidação inicial da estação chuvosa. Em maio, o

ERA5 apresentou desempenho moderado ($NRMSE = 1,15$), baixa capacidade explicativa da variabilidade observada e tendência sistemática de subestimação da precipitação, com forte suavização dos extremos acima do percentil 90 (Figura 58). Junho apresentou um dos melhores desempenhos da série, com $NRMSE_{de0,95}$ na (Tabela 28), correlação moderadamente elevada e igualdade estatística das variâncias entre observado e reanálise, embora ainda persistissem limitações na representação precisa dos máximos extremos.

Durante julho e agosto ocorreu a intensificação máxima da estação chuvosa, marcada por elevada variabilidade interanual e ocorrência de extremos severos. Em julho, os dados observados apresentaram máximos superiores a $600mm$ na (Figura 58), enquanto o ERA5 mostrou desempenho moderado e forte subestimação da precipitação. Agosto correspondeu ao pico climatológico da estação chuvosa, com extremos próximos de $950mm$ nos dados observados. Nesse período, o ERA5 apresentou um dos desempenhos mais limitados da série, com $NRMSE_{de1,49}$, erros extremamente elevados, baixa correlação linear e forte subestimação sistemática dos máximos pluviométricos observados.

Em setembro e outubro observou-se melhora parcial do desempenho da reanálise. Setembro apresentou $NRMSE_{de1,15}$ e correlação significativa na (Tabela 28), indicando representação parcial da variabilidade temporal da precipitação, embora persistisse subestimação dos máximos superiores a $600mm$. Outubro marcou um dos melhores desempenhos estatísticos do ERA5, com redução significativa dos erros, forte correlação linear ($r = 0,74$) e boa representação do padrão sazonal da precipitação, apesar da continuidade da subestimação moderada dos eventos extremos.

Em novembro ocorreu o enfraquecimento da estação chuvosa, caracterizado por baixos acumulados pluviométricos e ocorrência episódica de extremos isolados. O ERA5 apresentou desempenho moderado, baixa capacidade de representação da variabilidade temporal e persistência da subestimação da precipitação durante a transição sazonal.

Os testes de Shapiro–Wilk evidenciaram predominância de distribuições não normais em vários meses, especialmente em maio, julho e novembro, refletindo forte assimetria positiva e influência dos extremos climáticos sobre a distribuição pluviométrica. O teste de Levene mostrou alternância entre homogeneidade e diferenças significativas das variâncias, enquanto o teste de Durbin–Watson indicou predominância de independência residual, embora alguns meses apresentassem autocorrelação positiva durante os períodos de maior irregularidade pluviométrica.

Análises de regressão linear e FAT2 confirmaram desempenho global satisfatório do ERA5 em Suzana. O coeficiente global de determinação ($R^2 = 0,83$) na (Figura 16e), indicou forte associação entre observado e reanálise, enquanto a inclinação da regressão ($0,67$) revelou uma das maiores tendências de subestimação sistemática

entre as estações analisadas (Tabela 9). A análise reforçou a baixa aderência aos valores ideais, especialmente para eventos extremos de maior magnitude.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$), destacando forte contribuição do fator estação e da interação entre produto e estação (Tabela 4.4).

Os resultados demonstraram que o ERA5 possui capacidade razoável de representar a sazonalidade e parte da variabilidade temporal da precipitação em Suzana, especialmente durante junho e outubro. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos severos, com predominância de subestimação dos máximos observados durante o pico da estação chuvosa.

4.5.3 Reanálise ERA5-LAND

4.5.3.1 Estação de Bafatá

A estação de Bafatá evidenciou elevada variabilidade interanual, forte influência dos extremos pluviométricos e diferenças importantes entre os dados observados e a reanálise ERA5-LAND. De modo geral, a reanálise apresentou desempenho variando entre bom, moderado e fraco ao longo da estação chuvosa, conseguindo representar parcialmente a sazonalidade da precipitação, embora persistam limitações importantes na reprodução da magnitude e frequência dos eventos extremos.

Os boxplots mostraram predominância de distribuições assimétricas positivas, principalmente em maio, setembro e novembro, refletindo forte irregularidade pluviométrica e ocorrência de extremos isolados (Figura 59). Em praticamente todos os meses analisados, os dados observados apresentaram maior dispersão e máximos superiores aos da reanálise, enquanto o ERA5-LAND apresentou comportamento mais suavizado, frequentemente subestimando os maiores acumulados pluviométricos observados.

Entre maio e junho ocorreu o estabelecimento gradual da estação chuvosa. Em maio, o ERA5-LAND apresentou desempenho considerado bom na (Tabela 29), com correlação moderada e tendência sistemática de subestimação da precipitação, suavizando fortemente os extremos acima do percentil 90 (Figura 60). Junho apresentou aumento expressivo da variabilidade pluviométrica e desempenho moderado, marcado por persistente subestimação dos acumulados e limitada capacidade de representar adequadamente os eventos intensos superiores a 200 mm.

Julho correspondeu a um dos melhores desempenhos estatísticos da estação. Os boxplots mostraram elevada concordância entre observado e reanálise, com medianas próximas e amplitudes semelhantes na (Figura 59). O ERA5-LAND apresentou desempenho bom, leve superestimação média da precipitação e forte correlação linear, conseguindo reproduzir razoavelmente a variabilidade temporal e parte dos eventos

extremos acima do P90 na (Figura 60), embora ainda tenham ocorrido episódios pontuais de superestimação dos máximos pluviométricos.

Durante agosto e setembro ocorreu o período de maior irregularidade pluviométrica e pior desempenho da reanálise na (Tabela 29). Agosto correspondeu ao pico da estação chuvosa, apresentando elevada variabilidade pluviométrica e extremos intensos tanto nas observações quanto na reanálise. Apesar de o ERA5-LAND representar parcialmente alguns eventos severos, a correlação linear foi muito fraca, evidenciando baixa capacidade de reproduzir a variabilidade interanual da precipitação. Setembro apresentou o pior desempenho estatístico da série, com forte subestimação sistemática, baixa correlação e incapacidade da reanálise em representar adequadamente os extremos superiores a 500mm observados.

Em outubro observou-se melhora moderada do desempenho estatístico do ERA5-LAND. Os boxplots na (Figura 59) mostraram distribuições relativamente semelhantes entre observado e reanálise, embora os extremos observados superiores a 300mm tenham permanecido subestimados. A reanálise apresentou desempenho relativamente bom, correlação moderada e capacidade razoável de representar a variabilidade temporal da precipitação durante o enfraquecimento gradual da estação chuvosa.

Novembro marcou o encerramento da estação chuvosa e apresentou comportamento bastante distinto entre observado e reanálise. Os dados observados mostraram predominância de baixos acumulados pluviométricos, enquanto o ERA5-LAND apresentou maior frequência de precipitações moderadas, aumento na estação úmida na (Figura 59). Nesse período, a reanálise apresentou tendência de superestimação da precipitação e persistência de eventos intensos ao longo da série temporal.

Os testes estatísticos mostraram comportamento variável da normalidade ao longo dos meses analisados. O teste de Shapiro–Wilk evidenciou predominância de distribuições não normais em meses mais influenciados pelos extremos pluviométricos, especialmente maio, julho e novembro. O teste de Levene indicou alternância entre homogeneidade e diferenças significativas entre as variâncias, enquanto o teste de Durbin–Watson revelou predominância de independência residual, embora alguns meses apresentassem autocorrelação positiva dos resíduos, sobretudo durante os períodos de maior irregularidade pluviométrica.

As análises de regressão linear e FAT2 confirmaram desempenho global razoável do ERA5-LAND em Bafatá. O coeficiente global de determinação ($R^2 = 0,83$) (Figura 17a), indicou forte associação entre observado e reanálise, enquanto a inclinação da regressão inferior à unidade ($0,763$) revelou tendência sistemática de subestimação da precipitação, principalmente nos meses mais chuvosos. A análise reforçou a presença de dispersão significativa e baixa aderência aos valores ideais durante os eventos extremos (Tabela 10).

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de

precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$) (Tabela 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.

Em geral, os resultados demonstraram que o ERA5-LAND possui capacidade razoável de representar a sazonalidade e parte da variabilidade temporal da precipitação em Bafatá, especialmente durante julho e outubro. Entretanto, persistiram limitações importantes na representação quantitativa dos extremos pluviométricos severos, com predominância de subestimação dos máximos observados durante o pico da estação chuvosa e superestimação da precipitação residual no final da estação úmida.

4.5.3.2 Estação de Bigene

A precipitação mensal na estação de Bigene evidenciou forte variabilidade sazonal no desempenho do ERA5-LAND ao longo da estação chuvosa. De forma geral, os melhores resultados ocorreram em maio, junho e outubro, enquanto julho, agosto e setembro apresentaram maiores limitações, principalmente devido à forte superestimação dos extremos pluviométricos e à baixa capacidade de representação da variabilidade temporal observada.

Os boxplots mostraram distribuições predominantemente assimétricas, elevada dispersão durante os meses centrais da estação úmida e forte presença de outliers associados aos extremos pluviométricos (Figura 43). Em vários meses, os dados observados apresentaram maior variabilidade temporal, enquanto o ERA5-LAND mostrou comportamento mais suavizado ou superestimação persistente dos acumulados pluviométricos.

Entre maio e junho ocorreu o melhor desempenho de reanálise. Em maio, o ERA5-LAND apresentou desempenho classificado como bom, com elevada correlação ($r = 0,73$; $R^2 = 0,53$) na (Tabela 30), baixos erros e leve subestimação da precipitação. Em junho, o desempenho permaneceu satisfatório, embora com aumento da variabilidade sazonal e persistência da subestimação dos extremos superiores a 125 mm (Figura 62). Os testes estatísticos mostraram rejeição parcial da normalidade, homogeneidade das variâncias e independência residual relativamente adequada, embora junho tenha apresentado autocorrelação positiva moderada.

Entre julho e setembro ocorreu o pior desempenho estatístico da estação. Julho marcou mudança importante no comportamento da reanálise, com forte superestimação da precipitação ($Bias = 90,21$ mm), baixa correlação e elevada autocorrelação residual. Agosto apresentou o pior desempenho da série ($NRMSE = 1,87$) na (Tabela 30), acompanhado de intensa superestimação sistemática dos extremos pluviométricos, correlação praticamente inexistente e persistência temporal dos erros. Em setembro, o ERA5-LAND manteve comportamento semelhante, com forte superestimação dos acumulados, baixa capacidade explicativa e forte influência dos extremos

climáticos sobre as distribuições estatísticas.

Em outubro observou-se melhora parcial do desempenho do ERA5-LAND, com redução dos erros, desempenho classificado como bom e representação razoável dos eventos moderados próximos ao percentil 90 (Figura 62), embora alguns extremos acima de 350 mm tenham permanecido subestimados. Em novembro, o desempenho voltou a ser fraco devido ao elevado erro relativo associado aos baixos volumes médios de precipitação e à persistente superestimação das chuvas residuais do final da estação úmida.

Os testes estatísticos evidenciaram predominância de distribuições não normais nos meses mais influenciados pelos extremos pluviométricos. O teste de Levene indicou predominância de homogeneidade das variâncias, enquanto o teste de Durbin–Watson revelou autocorrelação positiva moderada a forte principalmente entre julho e setembro, indicando persistência temporal dos erros durante o pico da estação chuvosa.

A regressão linear e FAT2 confirmaram desempenho intermediário do ERA5-LAND em Bigene. O coeficiente global de determinação ($R^2 = 0,68$) (Figura 17b) indicou associação moderada entre observado e reanálise, enquanto a inclinação da regressão próxima da unidade (1,068) (Tabela 10) revelou tendência média de superestimação da precipitação. A análise FAT2 mostrou elevada dispersão relativa entre observado e reanálise, sobretudo durante os eventos extremos mais intensos.

Os resultados da ANOVA mostraram influência significativa tanto de reanálise de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0,001$) (Tabela 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.

O ERA5-LAND apresentou capacidade razoável de representar a sazonalidade da precipitação em Bigene, especialmente durante maio, junho e outubro. Entretanto, persistiram limitações importantes na representação quantitativa dos extremos pluviométricos severos, principalmente entre julho e setembro, quando ocorreram os maiores erros, forte superestimação e baixa capacidade de representação da variabilidade temporal observada.

4.5.3.3 Estação de Bolama

A análise da precipitação entre maio e novembro na estação de Bolama evidenciou forte variabilidade sazonal no desempenho do ERA5-LAND, com melhores resultados nos meses de maio e outubro e maiores limitações entre julho e setembro, período correspondente ao pico da estação chuvosa. A reanálise conseguiu representar parcialmente a sazonalidade da precipitação, embora persistam dificuldades importantes na reprodução quantitativa dos extremos pluviométricos.

Os boxplots mostraram distribuições predominantemente assimétricas, elevada

dispersão dos dados observados e forte presença de outliers, especialmente durante os meses centrais da estação úmida (Figura 64). As séries temporais evidenciaram ocorrência frequente de eventos acima do percentil 90 (P90) (Figura 65), principalmente entre julho e setembro, enquanto o ERA5-LAND apresentou tendência recorrente de suavização dos máximos pluviométricos observados.

Entre maio e junho ocorreu desempenho relativamente satisfatório do produto. Em maio, o ERA5-LAND apresentou desempenho classificado como bom, com moderada correlação ($r = 0.47$) na (Tabela 32), baixos erros e leve subestimação dos extremos pluviométricos. Em junho, observou-se aumento da variabilidade sazonal e dos erros estatísticos, embora a correlação tenha permanecido moderada ($r = 0.44$). Os testes estatísticos mostraram alternância entre distribuições normais e não normais, predominância de homogeneidade das variâncias e independência residual satisfatória nesses meses.

Entre julho e setembro ocorreram as maiores limitações do ERA5-LAND em Bolama. Julho apresentou forte subestimação sistemática da precipitação ($Bias = -99.93$ mm) na (Tabela 32), embora a correlação moderada ($r = 0.52$) tenha indicado representação parcial da dinâmica temporal das chuvas. Agosto correspondeu ao pico máximo da estação chuvosa, com extremos próximos de 1000 mm nos dados observados, elevados erros estatísticos e persistente subestimação dos máximos pluviométricos ($Bias = -104.10$ mm) na (Figura 65). Em setembro, o desempenho permaneceu moderado, porém com baixa capacidade de representação da variabilidade temporal observada ($r = 0.20$). Os testes de Durbin–Watson revelaram autocorrelação positiva moderada principalmente entre julho e agosto, indicando persistência temporal dos erros durante o pico da estação chuvosa.

Em outubro ocorreu melhora significativa do desempenho estatístico do ERA5-LAND, com viés praticamente nulo e correlação moderada ($r = 0.51$) na (Tabela 32), indicando representação razoável da variabilidade temporal das chuvas. Em novembro, apesar dos baixos erros absolutos, a reanálise voltou a apresentar desempenho moderado, com tendência de superestimação da precipitação residual e forte autocorrelação positiva dos resíduos.

As análises de regressão linear e fator de dois confirmaram excelente capacidade do ERA5-LAND em reproduzir a variabilidade mensal da precipitação em Bolama. O elevado coeficiente de determinação global ($R^2 = 0.86$) na (Figura 17c), indicou forte associação entre observado e reanálise, enquanto a inclinação da regressão inferior à unidade na (Tabela 10) (0.780) revelou tendência sistemática de subestimação da precipitação, principalmente nos meses mais chuvosos. A análise FAT2 reforçou esse comportamento, mostrando desempenho intermediário e persistência de dispersão nos eventos extremos.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de

precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0.001$) (Figura 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.

Os resultados mostram que o ERA5-LAND apresentou bom desempenho global em Bolama, conseguindo representar parcialmente a sazonalidade da precipitação e parte da variabilidade temporal observada. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos severos, principalmente durante o pico da estação chuvosa, quando ocorreu forte suavização dos máximos históricos observados.

4.5.3.4 Estação de Catió

A precipitação entre maio e novembro na estação de Catió evidenciou forte variabilidade sazonal e importantes limitações do ERA5-LAND na representação da precipitação observada. O desempenho variou entre moderado e fraco, com predominância de subestimação das chuvas entre maio e julho e tendência de superestimação entre setembro e novembro, especialmente durante a transição para a estação seca.

Na (Figura 66) os boxplots mostraram elevada dispersão dos dados observados, ampla amplitude interquartil e presença frequente de extremos pluviométricos acima de 600 mm e 800 mm, principalmente entre junho e setembro. Em vários meses, o ERA5-LAND apresentou distribuições mais suavizadas ou superestimadas, evidenciando dificuldade em reproduzir adequadamente tanto a magnitude quanto a variabilidade temporal das chuvas em Catió.

Entre maio e julho ocorreram algumas das maiores limitações de reanálise. Em maio, o ERA5-LAND apresentou forte subestimação sistemática da precipitação ($Bias = -94.27$ mm) e ausência praticamente total de associação linear entre observado e reanálise ($r = 0.034$) na (Tabela 33). Em junho, observaram-se os maiores erros absolutos da análise, com persistente subestimação dos extremos acima do percentil 90 (Figura 67). Julho manteve desempenho moderado, porém com correlação negativa e muito baixa ($r = -0.078$), indicando ausência de relação temporal consistente entre as séries. Os testes estatísticos mostraram predominância de distribuições não normais, diferenças significativas entre variâncias e forte autocorrelação positiva dos resíduos, evidenciando persistência temporal dos erros durante o fortalecimento da estação chuvosa.

Agosto apresentou o melhor desempenho estatístico do ERA5-LAND na estação de Catió. A reanálise mostrou redução dos erros e maior compatibilidade entre observado e reanálise, com medianas e amplitudes interquartis relativamente semelhantes na (Figura 66). Apesar da correlação ainda fraca ($r = 0.179$), o ERA5-LAND conseguiu representar parcialmente diversos eventos extremos acima do P90 (Figura 67). Os testes de Shapiro–Wilk não rejeitaram normalidade para ambas as séries, enquanto


o teste de Levene confirmou igualdade das variâncias e o teste de Durbin–Watson indicou independência residual satisfatória.

Entre setembro e novembro voltou a predominar forte superestimação da precipitação. Em setembro, o ERA5-LAND apresentou $Bias = 102.07$ mm e baixa capacidade explicativa da variabilidade observada. Outubro correspondeu a um dos piores desempenhos estatísticos do período, com correlação praticamente inexistente ($r = -0.01$) na (Tabela 33) e forte superestimação das chuvas durante a transição para a estação seca. Em novembro, o modelo continuou superestimando as precipitações residuais, mantendo valores moderados mesmo quando os dados observados apresentavam predominância de valores próximos de zero. Os testes estatísticos revelaram persistência de autocorrelação positiva residual e alternância entre distribuições normais e não normais, influenciadas principalmente pelos extremos pluviométricos.


A regressão linear e FAT2 confirmaram desempenho inferior do ERA5-LAND em Catió quando comparado às demais estações. O coeficiente global de determinação ($R^2 = 0.59$) (Figura 17d) indicou baixa capacidade explicativa da variabilidade observada, enquanto a inclinação da regressão (0.712) (Tabela 10), revelou subestimação dos volumes elevados e viés positivo em baixos volumes. A análise FAT2 mostrou elevada dispersão relativa entre observado e reanálise, com pequena proporção dos dados próximos ao comportamento ideal.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0.001$) (Tabela 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.


Em geral, os resultados indicam que o ERA5-LAND apresentou limitações importantes na estação de Catió, especialmente na representação quantitativa dos extremos pluviométricos e da variabilidade temporal das chuvas. Embora agosto tenha apresentado desempenho relativamente mais consistente, persistiram dificuldades significativas na reprodução da magnitude real dos eventos extremos, com alternância entre forte subestimação e superestimação ao longo da estação chuvosa.




(a) Estação de Bafatá



(b) Estação de Bigene




(c) Estação de Bolama




(d) Estação de Catió


Figura 17 – Comparação mensal dos dados de reanálise ERA5-LAND sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bolama; d)Catió. Fonte: dos autores (2025).




(a) Estação de Farim



(b) Estação de Gabú



(c) Estação de Mansabá



(d) Estação de Suzana

Figura 18 – Comparação mensal dos dados de reanálise ERA5-LAND sobre observado através de fator 2, ao longo de séries temporais mensais, para estações de: a) Catió; b) Farim; c) Gabú; d) Mansabá; e) Suzana. Fonte: dos autores (2025)

4.5.3.5 Estação de Farim

Entre maio e novembro na estação de Farim, a precipitação evidenciou forte variabilidade sazonal e importante influência dos extremos pluviométricos, principalmente entre julho e setembro, período correspondente ao pico da estação chuvosa. O ERA5-LAND apresentou desempenho variando entre bom, moderado e fraco, conseguindo representar parcialmente a sazonalidade das chuvas, embora persistam limitações relevantes na reprodução quantitativa dos extremos observados.

Ainda na (Figura 68) os boxplots mostraram distribuições fortemente assimétricas, elevada dispersão dos dados observados e presença frequente de outliers extremos,

sobretudo entre agosto e setembro, quando ocorreram acumulados superiores a 800 mm e 1200 mm. Em praticamente todos os meses, os dados observados apresentaram maior amplitude interquartil e máximos superiores aos da reanálise, evidenciando tendência recorrente do ERA5-LAND em suavizar os eventos extremos mais intensos.

Entre maio e junho o desempenho variou entre bom e moderado. Em maio, o ERA5-LAND apresentou baixos erros médios, leve subestimação da precipitação e correlação moderada e significativa ($r = 0.36$) (Tabela 34), indicando capacidade parcial de representação da variabilidade temporal das chuvas. Em junho ocorreu intensificação da atividade pluviométrica, acompanhada de aumento expressivo dos erros estatísticos e persistência da subestimação sistemática da precipitação ($Bias = -37.39$ mm). Os testes estatísticos mostraram alternância entre distribuições normais e não normais, predominância de homogeneidade das variâncias e independência residual satisfatória nesses meses.

Julho apresentou o melhor desempenho geral do ERA5-LAND em Farim. Pois a reanálise mostrou desempenho classificado como bom ($NRMSE = 0.74$), correlação elevada e altamente significativa ($r = 0.66$) e Bias praticamente nulo, indicando bom equilíbrio entre superestimação e subestimação das chuvas. Os boxplots na (Figura 68) mostraram boa concordância entre as medianas e o ERA5-LAND conseguiu representar adequadamente diversos eventos intensos, embora os máximos absolutos ainda tenham permanecido parcialmente subestimados. Os testes de Shapiro–Wilk rejeitaram normalidade para ambas as séries, enquanto o teste de Levene revelou diferenças significativas entre as variâncias e o teste de Durbin–Watson indicou independência residual satisfatória.

Entre agosto e setembro ocorreram as maiores limitações do modelo. Agosto apresentou forte discrepância entre observado e reanálise, principalmente durante eventos extremos superiores a 800 mm e 900 mm (Figura 52), acompanhada de persistente subestimação sistemática da precipitação ($Bias = -52.59$ mm) e baixa correlação estatística. Em setembro, correspondente ao período de maiores extremos da série histórica, o ERA5-LAND manteve elevados erros estatísticos e forte subestimação dos máximos pluviométricos ($Bias = -75.53$ mm) na (Tabela 34), não conseguindo reproduzir adequadamente os eventos acima do percentil 90. Os testes estatísticos indicaram heterogeneidade das variâncias e presença de autocorrelação positiva residual, evidenciando persistência temporal dos erros durante o pico da estação chuvosa.

Em outubro observou-se redução gradual da atividade pluviométrica, porém com persistência de limitações na representação temporal das chuvas, evidenciada pela correlação praticamente nula ($r = 0.054$). Em novembro, correspondente ao encerramento da estação chuvosa, o ERA5-LAND apresentou desempenho fraco, com elevado erro relativo ($NRMSE = 2.77$), superestimação das precipitações residuais e ausência de associação linear significativa entre observado e reanálise. As séries

temporais mostraram prolongamento artificial da estação chuvosa pelo modelo, associado à superestimação frequente de eventos intensos.

As análises de regressão linear em fator e dois confirmaram desempenho intermediário do ERA5-LAND em Farim. O coeficiente global de determinação ($R^2 = 0.74$) (Figura 18a) indicou boa coerência estatística geral entre observado e reanálise, porém a inclinação da regressão (0.658) (Tabela 10) revelou forte subestimação sistemática da precipitação mensal, principalmente durante os meses mais chuvosos. A análise FAT2 reforçou a limitação do modelo na reprodução dos extremos pluviométricos, evidenciando elevada dispersão relativa e baixa aderência aos critérios ideais de concordância. Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0.001$) (Tabela 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.

Por tanto, os resultados mostram que o ERA5-LAND apresentou melhor desempenho em julho, quando conseguiu representar de forma mais consistente a variabilidade sazonal e parte dos eventos intensos. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos, principalmente entre agosto e setembro, período em que ocorreu forte subestimação dos máximos observados e baixa capacidade de representação da magnitude real dos eventos convectivos mais severos em Farim.

4.5.3.6 Estação de Gabú

A análise da precipitação entre maio e novembro na estação de Gabú evidenciou elevada variabilidade sazonal e forte influência dos eventos extremos pluviométricos, principalmente entre julho e setembro, período correspondente ao pico da estação chuvosa. O ERA5-LAND apresentou desempenho variando entre bom, moderado e fraco, conseguindo representar parcialmente a sazonalidade das chuvas, embora persistam limitações importantes na reprodução quantitativa dos extremos observados.

Os boxplots mostraram maior dispersão, amplitudes interquartis elevadas e ocorrência frequente de outliers extremos nos dados observados em comparação à reanálise (Figura 70). Em praticamente todos os meses, o ERA5-LAND apresentou comportamento mais suavizado, reduzindo a intensidade dos máximos pluviométricos observados. As séries temporais também evidenciaram diversos eventos acima do percentil 90 (P90), sobretudo entre agosto e setembro, quando ocorreram os maiores acumulados da série histórica (Figura 71).

Em maio, o ERA5-LAND apresentou um dos melhores desempenhos da estação, classificado como bom ($NRMSE = 0.88$), com baixos erros estatísticos, correlação elevada e significativa ($r = 0.71$) e leve tendência de subestimação da precipitação ($Bias = -14.10$ mm) na (Tabela 35). Apesar do desempenho satisfatório, os extre-

mos superiores a 70 mm e máximos próximos de 90 mm permaneceram parcialmente subestimados. Em maio, os testes de Shapiro–Wilk rejeitaram normalidade para ambas as séries, o teste de Levene indicou heterogeneidade das variâncias e o teste de Durbin–Watson mostrou relativa independência residual.

Em junho ocorreu uma das maiores limitações do modelo. O desempenho tornou-se fraco ($NRMSE = 1.61$), acompanhado de elevados erros estatísticos, forte subestimação sistemática das chuvas ($Bias = -65.02$ mm) e baixa correlação não significativa entre observado e reanálise. Os extremos superiores a 250 mm e máximos acima de 300 mm foram fortemente subestimados pelo ERA5-LAND (Figura 71). Os testes estatísticos mostraram normalidade apenas para os dados observados, homogeneidade das variâncias e forte autocorrelação positiva residual, evidenciando persistência temporal dos erros durante o fortalecimento da estação chuvosa.

Entre julho e agosto ocorreram os resultados mais consistentes da estação. Julho apresentou desempenho moderado ($NRMSE = 1.02$), Bias próximo de zero e correlação moderada e significativa, indicando capacidade parcial do modelo em representar a precipitação observada. Os boxplots mostraram boa concordância entre medianas e amplitudes interquartis, embora alguns extremos superiores a 400 mm tenham permanecido subestimados (Figura 71). Em agosto, o ERA5-LAND apresentou um dos melhores desempenhos do período ($NRMSE = 0.93$) (Tabela 35), com elevada similaridade entre observado e reanálise e correlação significativa, apesar da persistente subestimação dos extremos severos superiores a 690 mm. Nesses meses, os testes de Shapiro–Wilk não rejeitaram normalidade para ambas as séries, o teste de Levene confirmou homogeneidade das variâncias e o teste de Durbin–Watson indicou independência residual satisfatória.

Em setembro, correspondente ao pico da estação chuvosa, o desempenho voltou a ser moderado, com elevados erros estatísticos e forte tendência de subestimação ($Bias = -72.31$ mm) na (Tabela 35). A correlação negativa e não significativa evidenciou baixa capacidade do ERA5-LAND em reproduzir a variabilidade temporal observada. Os boxplots mostraram grande dispersão e ocorrência de extremos superiores a 500 mm e 600 mm na (Figura 70), enquanto a reanálise apresentou forte suavização desses eventos extremos. Os testes estatísticos indicaram normalidade para ambas as séries, diferenças significativas entre as variâncias e relativa independência residual.

Em outubro e novembro observou-se redução gradual da atividade pluviométrica. Outubro apresentou desempenho moderado, com Bias relativamente pequeno e capacidade razoável de representação de alguns eventos próximos ao P90 (Figura 54), embora a correlação tenha permanecido fraca e não significativa. Em novembro, o ERA5-LAND apresentou desempenho moderado, porém com superestimação relativa das precipitações residuais ($Bias = 10.87$ mm) e tendência de prolongamento artificial

da estação chuvosa. Os boxplots mostraram forte assimetria e elevada concentração de valores próximos de zero nos dados observados, enquanto a reanálise apresentou maior frequência de precipitações moderadas (Figura 70). Os testes de Shapiro–Wilk rejeitaram normalidade em novembro, o teste de Levene revelou diferenças significativas entre as variâncias e o teste de Durbin–Watson indicou autocorrelação positiva residual.

As análises de regressão linear e FAT2 confirmaram bom desempenho estatístico geral do ERA5-LAND em Gabú. O coeficiente global de determinação ($R^2 = 0.77$) (Figura 18b) indicou elevada capacidade de representação da variabilidade mensal da precipitação, enquanto a inclinação da regressão (0.741) na (Tabela 10) revelou persistente tendência de subestimação das precipitações mais intensas. A análise FAT2 também evidenciou aderência limitada aos critérios ideais de concordância, principalmente durante eventos extremos pluviométricos.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0.001$) (Tabela 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.

Em geral, o ERA5-LAND apresentou melhor desempenho em maio, julho e agosto, conseguindo representar parcialmente a sazonalidade e parte da variabilidade temporal das chuvas em Gabú. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos, principalmente em junho e setembro, meses em que ocorreu forte subestimação dos máximos observados e baixa capacidade de representação da magnitude real dos eventos extremos.

Estação	R^2	Inclinação	Intercepto (mm)	Mediana Y/X	IQR	$\pm 30\%$ (%)
Bafatá	0.83	0.763	6.7	0.82	0.50	5.4
Bigene	0.68	1.068	19.0	1.48	1.28	40.2
Bolama	0.86	0.780	16.0	0.91	0.73	14.0
Catió	0.59	0.712	40.6	1.21	1.26	19.2
Farim	0.74	0.658	18.7	0.97	0.65	12.4
Gabú	0.77	0.741	13.6	0.88	0.61	14.9
Mansabá	0.81	0.751	10.8	0.83	0.67	16.1
Suzana	0.81	0.698	3.7	0.70	0.57	8.8

Tabela 10 – Resumo estatístico da relação entre precipitação observada e reanálise ERA5-LAND nas estações da séries temporais mensais.

4.5.3.7 Estação de Mansabá

A precipitação entre maio e novembro na estação de Mansabá evidenciou forte variabilidade sazonal e elevada influência dos eventos extremos pluviométricos, prin-

principalmente entre julho e setembro, período correspondente ao auge da estação chuvosa. ERA5-LAND apresentou desempenho variando entre bom e moderado, conseguindo representar parcialmente a sazonalidade da precipitação, embora persistam limitações importantes na reprodução da magnitude dos máximos extremos observados.

(Figura 72) os boxplots mostraram maior dispersão, amplitudes interquartis elevadas e ocorrência frequente de outliers extremos nos dados observados em comparação à reanálise. Em praticamente todos os meses, o ERA5-LAND apresentou distribuição mais suavizada, reduzindo a intensidade dos eventos extremos observados. As séries temporais também evidenciaram elevada irregularidade interanual, com diversos eventos acima do percentil 90 (P90) na (Figura 73), sobretudo entre agosto e setembro, quando ocorreram os maiores acumulados pluviométricos da série histórica.

Em maio, o ERA5-LAND apresentou desempenho considerado bom ($NRMSE = 0.92$), com baixos erros estatísticos, correlação moderada e significativa ($r = 0.49$) e leve tendência de subestimação da precipitação ($Bias = -5.79$ mm) na (Tabela 36). Apesar do desempenho satisfatório, os extremos severos acima do P90 permaneceram subestimados pela reanálise. Em maio, os testes de Shapiro–Wilk rejeitaram normalidade para ambas as séries, o teste de Levene indicou homogeneidade das variâncias e o teste de Durbin–Watson revelou independência residual satisfatória.

Em junho ocorreu redução do desempenho do modelo, com aumento significativo dos erros estatísticos e persistente subestimação das chuvas ($Bias = -40.36$ mm). A correlação moderada e significativa indicou capacidade parcial do ERA5-LAND em representar a variabilidade interanual, embora os máximos superiores a 250 mm tenham sido fortemente suavizados. Os testes estatísticos mostraram normalidade para ambas as séries, igualdade das variâncias e autocorrelação positiva moderada dos resíduos, evidenciando persistência temporal dos erros durante o fortalecimento da estação chuvosa.

Entre julho e agosto ocorreram os resultados mais consistentes da estação. Julho apresentou um dos melhores desempenhos do ERA5-LAND, classificado como bom ($NRMSE = 0.90$), com correlação moderada e significativa e Bias relativamente pequeno ($Bias = -21.86$ mm) na (Tabela 36), indicando subestimação menos intensa em comparação aos meses anteriores. Os boxplots mostraram boa concordância entre medianas e amplitudes interquartis, embora os máximos extremos acima do P90 ainda tenham sido subestimados (Figura 73c;d). Em agosto, o desempenho tornou-se moderado ($NRMSE = 1.04$), acompanhado de elevada influência dos extremos severos e correlação fraca e não significativa. O evento extremo superior a 1000 mm observado na série histórica não foi adequadamente reproduzido pelo ERA5-LAND, evidenciando forte suavização dos máximos extremos. Em julho, os testes de Sha-

piro–Wilk não rejeitaram normalidade para ambas as séries, enquanto em agosto a normalidade foi rejeitada apenas para os dados observados. O teste de Levene confirmou homogeneidade das variâncias e o teste de Durbin–Watson indicou independência residual satisfatória nesses meses.

Em setembro e outubro o ERA5-LAND manteve desempenho moderado, com elevados erros estatísticos e persistente tendência de subestimação dos máximos pluviométricos. Em setembro, diversos eventos superiores a 500 mm foram fortemente suavizados pela reanálise, enquanto outubro apresentou capacidade parcial de representação da variabilidade interanual, embora os eventos intensos acima do P90 continuassem subestimados (Figura 73e,f). Os testes estatísticos mostraram normalidade para ambas as séries em setembro, enquanto em outubro a normalidade foi rejeitada apenas para os dados observados. O teste de Levene revelou diferenças significativas entre as variâncias nesses meses, enquanto o teste de Durbin–Watson indicou independência residual satisfatória.

Em novembro, correspondente ao enfraquecimento da estação chuvosa, o ERA5-LAND apresentou desempenho moderado, porém com baixos erros absolutos e tendência de superestimação da precipitação ($Bias = 5.73$ mm). A correlação linear foi fraca e não significativa, indicando limitada capacidade explicativa do modelo durante a transição para a estação seca. Os boxplots mostraram forte assimetria e maior concentração de valores próximos de zero nos dados observados, enquanto a reanálise apresentou precipitações moderadas mais frequentes (Figura 73). Os testes de Shapiro–Wilk rejeitaram normalidade para ambas as séries, o teste de Levene indicou homogeneidade das variâncias e o teste de Durbin–Watson revelou independência residual satisfatória.

A regressão linear e FAT2 confirmaram bom desempenho estatístico geral do ERA5-LAND em Mansabá. O coeficiente global de determinação ($R^2 = 0.81$) na (Figura 18c), indicou elevada capacidade de representação da variabilidade mensal da precipitação, enquanto a inclinação da regressão (0.751) (Tabela 10) revelou persistente tendência de subestimação das precipitações mais intensas. Ainda o fator de dois também evidenciou aderência limitada aos critérios ideais de concordância, principalmente durante eventos extremos pluviométricos.

Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0.001$) (Tabela 4.4), destacando forte contribuição do fator estação e da interação entre produto e estação.

Os resultados evidenciaram que o ERA5-LAND apresentou melhor desempenho em maio, julho e parcialmente em agosto, conseguindo representar parcialmente a sazonalidade e parte da variabilidade temporal das chuvas em Mansabá. Entretanto, persistiram limitações importantes na reprodução quantitativa dos extremos pluviométricos.

tricos, principalmente entre junho e setembro, meses em que ocorreu forte subestimação dos máximos observados e baixa capacidade de representação da magnitude real dos eventos extremos.

4.5.3.8 Estação de Suzana

A análise da precipitação entre maio e novembro na estação de Suzana evidenciou elevada variabilidade pluviométrica e forte influência dos eventos extremos, principalmente entre julho e setembro, período correspondente ao pico da estação chuvosa. De forma geral, o ERA5-LAND apresentou desempenho variando entre bom, moderado e fraco, com melhores resultados em junho e outubro, enquanto agosto correspondeu ao período de pior desempenho estatístico devido à forte subestimação dos extremos pluviométricos.

Os boxplots mostraram maior dispersão, amplitudes interquartis elevadas e ocorrência frequente de outliers extremos nos dados observados em comparação à reanálise. Em praticamente todos os meses (Figura 74), o ERA5-LAND apresentou distribuições mais suavizadas, frequentemente com medianas inferiores e menor variabilidade, indicando tendência recorrente de subestimação dos acumulados pluviométricos intensos. As séries temporais também evidenciaram elevada irregularidade interanual, sobretudo entre julho e setembro, quando diversos eventos ultrapassaram o percentil 90 (P90) (Figura 75).

Em maio, o ERA5-LAND apresentou desempenho moderado ($NRMSE = 1.145$), acompanhado de significativa subestimação da precipitação ($Bias = -19.27$ mm) e correlação moderada ($r = 0.40$) na (Tabela 37), indicando limitada capacidade de representação da variabilidade temporal das chuvas. A análise dos extremos mostrou forte subestimação dos episódios acima do P90. Em maio, os testes de Shapiro–Wilk rejeitaram normalidade para ambas as séries, o teste de Levene indicou heterogeneidade das variâncias e o teste de Durbin–Watson revelou autocorrelação positiva dos resíduos.

Durante junho ocorreu melhora considerável no desempenho do ERA5-LAND. O NRMSE de 0.934 classificou o desempenho como bom, enquanto o Bias próximo de zero indicou equilíbrio estatístico entre observado e reanálise. A correlação moderadamente elevada ($r = 0.54$) representou uma das melhores associações observadas na estação Suzana. Na (Figura 74) os boxplots mostraram maior proximidade entre observado e reanálise, embora alguns extremos severos tenham sido superestimados em anos específicos. Em junho, os testes de Shapiro–Wilk rejeitaram normalidade para ambas as séries, o teste de Levene confirmou homogeneidade das variâncias e o teste de Durbin–Watson indicou independência residual satisfatória.

Entre julho e setembro ocorreu aumento expressivo dos erros estatísticos associado à intensificação da estação chuvosa. Julho apresentou desempenho moderado,

com forte tendência de subestimação ($Bias = -104.01$ mm) e comportamento inconsistente do modelo, alternando períodos de forte subestimação com superestimações extremas isoladas, incluindo evento superior a 750 mm na reanálise. Agosto representou o cenário mais crítico da análise, com desempenho fraco ($NRMSE = 1.506$), correlação baixa e forte subestimação sistemática ($Bias = -178.85$ mm) na (Tabela 37). A série temporal confirmou incapacidade do ERA5-LAND em reproduzir eventos extremos severos acima de 700 mm e 900 mm. Em setembro, o desempenho permaneceu moderado, com persistente subestimação dos máximos anuais e representação apenas parcial dos eventos próximos ao P90 na (Figura 75). Nesses meses, os testes estatísticos mostraram alternância entre distribuições normais e assimétricas, enquanto o teste de Levene indicou predominância de homogeneidade das variâncias. O teste de Durbin–Watson revelou autocorrelação positiva mais intensa em julho e agosto, refletindo persistência temporal dos erros durante o pico da estação chuvosa.

Outubro apresentou uma das melhores performances do ERA5-LAND em Suzana. O desempenho foi classificado como bom ($NRMSE = 0.95$) na (Tabela 37), com forte correlação linear ($r = 0.705$) e elevada capacidade explicativa da variabilidade observada. Apesar da melhora geral, os eventos extremos severos continuaram sendo subestimados pela reanálise. Em outubro, os testes de Shapiro–Wilk rejeitaram normalidade apenas para os dados observados, o teste de Levene indicou diferenças significativas entre as variâncias e o teste de Durbin–Watson revelou autocorrelação positiva moderada.

Em novembro, correspondente ao encerramento da estação chuvosa, o ERA5-LAND apresentou desempenho moderado e baixa capacidade de representar a dinâmica temporal da precipitação. O NRMSE de 1.01 e a correlação extremamente baixa ($r = 0.095$) demonstraram reduzida habilidade do modelo em reproduzir as oscilações observadas na (Tabela 37). Os boxplots mostraram forte assimetria e predominância de baixos volumes observados na (Figura 74), enquanto a reanálise apresentou precipitações mais suavizadas e persistentes. Os testes de Shapiro–Wilk rejeitaram normalidade para ambas as séries, o teste de Levene confirmou homogeneidade das variâncias e o teste de Durbin–Watson indicou independência residual satisfatória.

As análises de regressão linear em fator de dois confirmaram bom desempenho estatístico global do ERA5-LAND em Suzana. O coeficiente global de determinação ($R^2 = 0.81$) (Figura 18d) indicou elevada capacidade de representação da variabilidade mensal da precipitação, enquanto a inclinação da regressão (0.698) (Tabela 10) revelou persistente tendência de subestimação das precipitações mais intensas. A análise FAT2 também mostrou baixa aderência aos critérios ideais de concordância, principalmente durante eventos extremos pluviométricos. Os resultados da ANOVA mostraram influência significativa tanto dos produtos de precipitação quanto das estações meteorológicas sobre a variabilidade pluviométrica ($p < 0.001$) (Tabela 4.4),

destacando forte contribuição do fator estação e da interação entre produto e estação.

Os resultados demonstraram que o ERA5-LAND apresentou melhor desempenho durante os meses de transição e redução gradual da estação chuvosa, especialmente em junho e outubro, quando houve maior concordância estatística entre observado e reanálise. Entretanto, durante o pico pluviométrico entre julho e setembro, o modelo apresentou forte tendência de subestimação dos eventos extremos, baixa capacidade explicativa e elevada instabilidade temporal, evidenciando limitações importantes na representação dos máximos pluviométricos severos na estação de Suzana.

4.6 Desempenho das Reanálises para Curvas de Tendência e Extrapolação

4.6.1 MSWEP V2

4.6.1.1 *Máximas Anuais de Precipitação, Extrapolações até 2030 e Avaliação do Desempenho das Reanálises*

A análise das máximas anuais de precipitação feito de dados de reanálise MSWEP V2 evidenciou elevada variabilidade interanual e forte influência dos eventos extremos pluviométricos em todas as regiões da Guiné-Bissau. Os ajustes cúbicos aplicados às séries temporais mostraram-se adequados para representar o comportamento não linear da precipitação, permitindo identificar tendências futuras dos extremos até 2030 (Figura 19a). Em geral, as extrapolações indicaram aumento gradual das máximas anuais em diversas estações, sobretudo nas regiões interiores, sugerindo possível intensificação futura dos eventos extremos de precipitação.


As métricas estatísticas reforçaram a consistência dos ajustes realizados. Em praticamente todas as estações, os coeficientes de determinação (R^2) (Tabela 8) variaram entre aproximadamente 0,68 e 0,85, indicando elevada capacidade do MSWEP V2 em reproduzir a variabilidade observada das máximas anuais. As correlações lineares apresentaram valores moderados a fortes, demonstrando boa concordância estatística entre observado e reanálise. Os menores valores de *MAE* e *RMSE* na ocorrência principalmente durante os períodos de transição da estação chuvosa, enquanto os maiores erros estiveram associados aos meses centrais da estação no período mais úmida, refletindo maior dificuldade da reanálise em representar adequadamente os extremos pluviométricos mais severos. Os valores de *Bias* mostraram alternância entre subestimação e superestimação das precipitações, dependendo da estação e do período. Além disso, nas estações como Bissau, Mansabá e Suzana, o alargamento do intervalo de confiança de 95% (IC95%) demonstra aumento da incerteza associada às extrapolações, reforçando que as projeções devem ser interpretadas como cenários probabilísticos e não como previsões determinísticas. E ainda (IC95%)

permaneceram relativamente estreitos nos restantes das estações, evidenciando estabilidade estatística dos ajustes e robustez dos parâmetros analisados na (Figura 19 ; Figura 20)).


4.6.1.2 *Extrapolação das Máximas Anuais até 2030*

As extrapolações das curvas ajustadas até 2030 mostraram comportamento espacialmente distinto entre as estações. Nas estações interiores, representadas por Bafatá, Bigene, Farim, Gabú e Mansabá na (Figura 19a, b ; Figura 20b, c , d)), observou-se tendência predominante de crescimento gradual das máximas anuais ao longo das próximas décadas. Em Bafatá e Bigene (Figura 19a , b), após uma fase inicial de estabilidade ou leve redução até o início dos anos 2000, as curvas cúbicas passaram a indicar crescimento progressivo das precipitações extremas, com projeções superiores aos máximos registrados recentemente. Esse comportamento sugere possível intensificação futura dos eventos extremos nessas regiões, acompanhada de elevada concordância estatística entre observado e reanálise.


Farim na (Figura 20b) apresentou tendência ascendente mais moderada, porém relativamente consistente, indicando aumento gradual da frequência de eventos intensos até 2030. Apesar disso, a inclinação inferior à unidade e os *Bias* negativos na (Tabela 16) revelaram tendência persistente de subestimação dos máximos extremos pelo MSWEP V2. Gabú e Mansabá (Figura 20c e d) apresentaram extrapolações mais suavizadas, caracterizadas por redução inicial seguida de recuperação gradual das máximas anuais. Embora o crescimento projetado nessas estações seja menos intenso, os elevados valores de correlação e R^2 (Tabela 8), indicaram boa representação da variabilidade temporal da precipitação pelas reanálises.




(a) Estação de Bafatá



(b) Estação de Bigene




(c) Estação de Bissau




(d) Estação de Bolama


Figura 19 – Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).




(a) Estação de Catió




(b) Estação de Farim



(c) Estação de Gabú



(d) Estação de Mansabá



(e) Estação de Suzana

Figura 20 – Total anual de precipitação (mm) e extrapolação até 2030, ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana.

Fonte: dos autores (2025)

Nas estações costeiras, Bissau, Bolama, Catió e Suzana apresentaram padrões distintos associados à forte influência marítima. Em Bissau observou-se crescimento expressivo das máximas anuais principalmente após os anos 2000, mantendo elevados acumulados extremos até 2030. Embora as extrapolações indiquem possível estabilização futura, os níveis permanecem elevados, sugerindo persistência de alto risco climático. Bolama e Catió apresentaram tendência de estabilização ou leve redução das máximas anuais futuras, comportamento associado à elevada variabilidade interanual observada nessas regiões costeiras.

Suzana destacou-se por apresentar os maiores máximos anuais e a maior amplitude interanual entre todas as estações analisadas (Figura 20e). A extrapolação até 2030 indicou continuidade do crescimento dos extremos pluviométricos, com projeções próximas ou superiores a 700 mm. Apesar do elevado desempenho estatís-

tico global do MSWEP V2 nessa estação, os elevados RMSE (Tabela 19), os Bias negativos e os baixos percentuais próximos ao fator 2 evidenciaram persistente subestimação dos eventos extremos mais severos. De maneira geral, as extrapolações revelaram tendência de intensificação dos extremos pluviométricos principalmente nas regiões interiores e de transição, enquanto algumas estações costeiras apresentaram comportamento mais estabilizado ou oscilatório.

4.6.1.3 *Variabilidade Mensal e Estrutura Sazonal*

A análise sazonal confirmou forte concentração da precipitação entre julho, agosto e setembro, correspondentes ao acumulo da estação chuvosa. Os maiores picos mensais ocorreram justamente nesses meses, contribuindo diretamente para o crescimento das máximas anuais projetadas pelas extrapolações. Embora o MSWEP V2 tenha reproduzido adequadamente a estrutura sazonal da precipitação, persistiram limitações importantes na representação quantitativa dos picos extremos, refletidas pelo aumento dos valores de RMSE, MAE, e dispersão estatística durante os períodos mais chuvosos.

Os resultados da ANOVA complementaram essas análises, demonstrando que tanto os produtos de reanálise quanto as estações meteorológicas exerceram influência estatisticamente significativa sobre a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total, evidenciando forte influência das características climáticas regionais sobre o comportamento da precipitação extrema. Além disso, a interação significativa entre produto e estação confirmou que o desempenho das reanálises varia espacialmente conforme as características locais de cada região analisada. Esses resultados reforçam que, embora o MSWEP V2 apresente boa capacidade geral de representação da precipitação e da sazonalidade climática, persistem limitações importantes na reprodução quantitativa da magnitude e frequência dos eventos extremos pluviométricos severos.

4.6.2 **ERA5**

4.6.2.1 *Variabilidade das máximas anuais de precipitação*

A análise das máximas anuais de precipitação derivadas da reanálise ERA5 para o período de 1990 a 2022 evidenciou elevada variabilidade interanual e forte influência dos eventos extremos pluviométricos em todas as estações analisadas. As diferenças espaciais observadas refletem a atuação combinada de fatores oceânicos e continentais, resultando em contrastes importantes entre regiões costeiras, interiores e zonas de transição.


As estações costeiras, como Bissau, Bolama e Catió na (Figura 21d ; Figura 22a), apresentaram as maiores magnitudes absolutas das máximas anuais, frequentemente superiores a 600 mm e com eventos extremos acima de 800 mm em alguns anos es-

pecíficos. No entanto as estações interiores, como Bafatá, Farim, Gabú e Mansabá na (Figura 21a ; Figura 22b, c e d), apresentaram máximas anuais mais moderadas, geralmente entre 200 e 600 mm, enquanto Bigene e Suzana na (Figura 21b ; Figura 22e) exibiram comportamento intermediário, caracterizado por elevada dispersão temporal e forte variabilidade interanual.


As métricas estatísticas reforçaram a robustez dos resultados obtidos com a ERA5. Os coeficientes de determinação (R^2) (Tabela 9) variaram, em geral, entre valores moderados e elevados, indicando boa capacidade da reanálise em reproduzir a variabilidade temporal das máximas anuais observadas. As correlações lineares apresentaram desempenho satisfatório na maior parte das estações, demonstrando coerência estatística entre observado e reanálise. Além disso, os menores valores de MAE e RMSE na (Tabela 20; 26; 25; 27) ocorreram principalmente nas estações interiores e nos períodos de menor intensidade pluviométrica, enquanto os maiores erros foram observados durante eventos extremos severos, sobretudo nas regiões costeiras. Os valores de Bias revelaram predominância de viés negativo sistemático, evidenciando tendência da ERA5 em suavizar ou subestimar os maiores extremos pluviométricos.

As inclinações das regressões lineares permaneceram sistematicamente inferiores à unidade, confirmando a subestimação progressiva dos maiores acumulados extremos pela reanálise. O aumento gradual da largura dos intervalos de confiança de 95% (IC95%) em maioria das estações como (Bissau, Bolama, Catió, Gabú, Mansabá e Suzana) evidencia que a incerteza cresce à medida que a extrapolação se afasta dos dados observados, no entanto (IC95%) na (Figura 21 ; Figura 22) mostraram-se as estações de (Bafatá, Bigene e Farim) relativamente estreitos, indicando estabilidade estatística dos ajustes lineares e boa robustez dos parâmetros. Esse comportamento demonstra que, embora persistam limitações na magnitude dos extremos das reanálises, a ERA5 reproduz adequadamente a estrutura temporal e sazonal da precipitação observada.


O ajuste cúbico aplicado às séries temporais revelou comportamento climático relativamente consistente ao longo do período analisado. Observou-se inicialmente uma fase de estabilidade ou leve redução das máximas anuais durante a década de 1990, seguida por recuperação gradual a partir dos anos 2000 e intensificação mais evidente após 2010. Esse aumento progressivo das máximas anuais está associado à maior frequência de anos extremos recentes, especialmente nas estações costeiras e de transição.




(a) Estação de Bafatá



(b) Estação de Bigene




(c) Estação de Bissau




(d) Estação de Bolama


Figura 21 – Total anual da precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bissau; d)Bolama. Fonte: dos autores (2025).




(a) Estação de Catió




(b) Estação de Farim



(c) Estação de Gabú



(d) Estação de Mansabá



(e) Estação de Suzana

Figura 22 – Total anual da precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)

4.6.2.2 Extrapolação das máximas anuais de precipitação até 2030

As extrapolações realizadas até 2030 indicaram manutenção ou intensificação moderada dos extremos pluviométricos na maior parte das estações. Nas regiões costeiras na (Figura 21c, d ; Figura 22a, e), os valores projetados permaneceram elevados, frequentemente acima de 550 e 600 mm, com sinais de estabilização ou leve crescimento em algumas localidades. Entretanto, a análise conjunta de RMSE (Tabela 22; 23; 24), Bias, inclinação da regressão e FAT2 na (Tabela 9) indicou que esses extremos futuros devem ser interpretados com cautela, pois a ERA5 tende a suavizar os maiores picos pluviométricos.

Nas estações de transição, como Bigene e Suzana, as extrapolações mostraram máximas anuais próximas ou superiores a 500 mm na (Figura 21b ; Figura 22e), acompanhadas de elevada dispersão e maior variabilidade temporal. Apesar dos elevados

coeficientes de correlação e R^2 (Tabela 9), os baixos percentuais próximos ao fator 2 evidenciaram limitações importantes na reprodução quantitativa dos eventos extremos mais severos. Já nas estações interiores, as projeções indicaram crescimento gradual das máximas anuais até 2030, com valores frequentemente entre 450 e 600 mm na (Figura 21a ; Figura 22b, c e d). Nessas regiões, o desempenho estatístico foi relativamente mais consistente, apresentando menores RMSE na (Tabela 21; 28), menor dispersão e melhor concordância temporal entre observado e reanálise.

4.6.2.3 Variabilidade mensal da precipitação

A análise da variabilidade mensal confirmou forte sazonalidade da precipitação em todas as estações. Os maiores acumulados ocorreram entre junho e setembro, com máximos mais intensos em julho e agosto, caracterizando o acumulo da estação chuvosa. Nas regiões costeiras, os totais mensais frequentemente ultrapassaram 400 mm em anos específicos, enquanto nas regiões interiores os máximos mensais permaneceram geralmente entre 250 e 350 mm.

Em termo estatístico, a ERA5 apresentou boa capacidade de reproduzir a sazonalidade da precipitação mensal, refletida pelas correlações moderadas a fortes observadas na maior parte das estações. Entretanto, os maiores volumes mensais continuaram sendo sistematicamente suavizados pela reanálise, sobretudo durante os meses mais chuvosos. Esse comportamento resultou em aumento dos valores de RMSE e MAE nos períodos associados aos extremos mais intensos, além de baixos percentuais próximos ao fator 2 nas estações costeiras e de transição.

Os resultados da ANOVA complementaram essas análises, mostrando que tanto os produtos de reanálise quanto as estações meteorológicas exerceram influência estatisticamente significativa sobre a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total, evidenciando forte influência das características climáticas regionais sobre os extremos de precipitação. Além disso, a interação significativa entre produto e estação demonstrou que o desempenho da ERA5 varia espacialmente conforme as condições locais de cada região. Em conjunto, os resultados evidenciam que a ERA5 apresenta boa capacidade geral de representação da sazonalidade, da variabilidade temporal e das tendências de longo prazo da precipitação, embora persistam limitações importantes na reprodução quantitativa dos extremos pluviométricos mais severos.

4.6.3 ERA5-LAND

4.6.3.1 Variabilidade das máximas anuais de precipitação

A análise das máximas anuais de precipitação obtidas a partir das reanálises ERA5-LAND para as estações de Bafatá, Bigene, Bolama, Catió, Farim, Gabú, Mansabá e Suzana, no período de 1990 a 2022, evidenciou elevada variabilidade intera-

nual em todas as localidades analisadas. Os valores máximos apresentaram ampla dispersão ao longo da série temporal, refletindo a natureza altamente irregular dos eventos extremos de precipitação na região.

Essa elevada variabilidade foi acompanhada, entretanto, por associações estatísticas robustas entre os dados observados e os valores das reanálises, com coeficientes de correlação elevados e coeficientes de determinação (R^2) variando, de modo geral, entre aproximadamente 0,59 e 0,86 (Tabela 10). Esses resultados indicam que o ERA5-LAND foi capaz de reproduzir grande parte da variabilidade temporal das máximas anuais, embora persistam limitações importantes na representação quantitativa da magnitude dos extremos mais intensos. As métricas estatísticas complementares reforçaram essa interpretação, com valores de RMSE e MAE relativamente moderados na maior parte das estações, especialmente nas regiões interiores, enquanto os maiores erros foram observados nas estações costeiras associadas aos eventos pluviométricos mais severos. Os valores de Bias mostraram predominância de subestimação sistemática dos máximos extremos, principalmente em Bolama, Catió e Suzana, indicando tendência da reanálise em suavizar precipitações muito intensas.

Em geral, observou-se que as estações costeiras (Bolama, Catió e Suzana) na (Figura 23c, e; Figura 24d) apresentaram máximas anuais mais elevadas e maior amplitude de variação quando comparadas às estações do interior, como Bafatá, Gabú, Mansabá e Farim. Em Bolama e Catió (Figura 23a ; Figura 24a, b, c), foram registrados eventos extremos com valores superiores a 700 mm, enquanto nas estações interiores as máximas tenderam a concentrar-se em faixas inferiores, ainda que com episódios pontuais de intensificação significativa. Estatisticamente, essas diferenças regionais refletiram-se em inclinações de regressão sistematicamente inferiores à unidade, indicando subestimação progressiva dos menores valores pelas reanálises, sobretudo nas regiões costeiras. Além disso, os intervalos de confiança de 95% (IC95%) permaneceram relativamente estreitos nas estações de (Suzana e Mansabá), evidenciando estabilidade estatística dos ajustes. Por outro lado, estações como Bafatá, Farim, Bigene e Gabú exibem intervalos de confiança significativamente mais amplos, evidenciando maior variabilidade interanual das precipitações extremas.


As estações de transição, representadas por Bigene e Suzana (Figura 23b ; Figura 24d), exibiram comportamento intermediário, combinando elevada variabilidade interanual com máximas anuais que, em determinados anos, se aproximaram dos valores observados nas áreas costeiras. Esse padrão sugere a influência simultânea de processos oceânicos e continentais sobre o regime pluviométrico dessas localidades, refletindo-se em valores elevados de R^2 , porém acompanhados de maior dispersão, RMSE na (Tabela 30; 37) relativamente elevados e menor aderência ao comportamento idealizado representado pelo fator 2.

O ajuste cúbico aplicado às séries de máximas anuais revelou comportamentos


não lineares consistentes em todas as estações analisadas. De forma recorrente, observou-se uma fase inicial de redução ou relativa estabilização das máximas anuais entre o início da série e o final da década de 1990 ou início dos anos 2000. Esse período foi seguido por uma inflexão positiva, a partir da qual as curvas ajustadas passaram a indicar aumento progressivo das máximas anuais até o final do período observado.

Nas estações costeiras, o ajuste cúbico evidenciou intensificação mais pronunciada dos extremos pluviométricos a partir da década de 2000, culminando em valores elevados nas décadas recentes. Em Bolama, Catió e Suzana, esse aumento ocorreu de forma mais acentuada, refletindo a maior disponibilidade de umidade associada à proximidade do oceano Atlântico e à atuação de sistemas convectivos intensos. Apesar do bom ajuste estatístico global, os elevados valores de RMSE na (Tabela 32; 33; 37) e as inclinações das regressões significativamente inferiores à unidade confirmaram que os valores máximos mais elevados continuam sendo suavizados pelas reanálises ERA5-LAND.


Nas estações do interior, como Bafatá, Farim, Gabú e Mansabá, o ajuste cúbico também indicou tendência positiva nas últimas décadas, embora com inclinações mais suaves. Ainda assim, a recorrência de valores elevados após 2010 sugeriu intensificação gradual dos extremos pluviométricos mesmo em áreas afastadas da costa. Estatisticamente, essas estações apresentaram elevados coeficientes de correlação, menores RMSE na (Tabela 29; 35; 34; 36) relativos e valores de R^2 relativamente altos, indicando melhor concordância entre observado e reanálise quando comparadas às estações




(a) Estação de Bafatá



(b) Estação de Bigene



(c) Estação de Bolama



(d) Estação de Catió

Figura 23 – Total anual de precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Bafatá; b)Bigene; c)Bolama; d)Catió. Fonte: dos autores (2025).




Figura 24 – Total anual de precipitação (mm), ao longo de séries temporais mensais, para estações de: a)Catió; b)Farim; c)Gabú; d)Mansabá; e)Suzana. Fonte: dos autores (2025)

4.6.3.2 Extrapolação das máximas anuais até 2030

A extrapolação das curvas cúbicas até 2030 sugeriu, de forma geral, a manutenção de valores elevados das máximas anuais de precipitação em todas as estações. Entretanto, os resultados indicaram diferenças importantes entre os grupos regionais, em consonância com os padrões estatísticos identificados.

Nas estações costeiras, especialmente Bolama, Catió e Suzana (Figura 23c, e; Figura 24d), a extrapolação apontou para persistência de máximas anuais elevadas, com tendência à estabilização ou leve redução após os picos recentes. Esse comportamento sugere manutenção dos extremos pluviométricos em patamares elevados nas próximas décadas, embora sem crescimento abrupto adicional no curto prazo. Em termo estatístico, os elevados valores de RMSE, Bias negativos e baixos percentuais próximos ao fator 2 indicaram limitações importantes da reanálise na reprodução das amplitudes extremas mais severas.

Nas estações de transição, como Bigene e Suzana (Figura 23b ; Figura 24d), as projeções indicaram continuidade da tendência positiva, com valores extrapolados superiores aos observados nas décadas iniciais da série. Em Suzana, por exemplo, os valores projetados situaram-se em torno de 520–530 mm, refletindo persistência de condições favoráveis à ocorrência de eventos extremos intensos. Apesar disso, os elevados RMSE, a dispersão crescente dos dados e as inclinações reduzidas das regressões confirmaram subestimação sistemática dos maiores extremos pela ERA5-

LAND.

Nas estações do interior, incluindo Bafatá, Farim, Gabú e Mansabá (Figura 23a ; Figura 24a, b, c), a extrapolação até 2030 sugeriu aumento gradual das máximas anuais, com valores projetados superiores aos mínimos históricos, porém inferiores aos extremos observados nas áreas costeiras. Esse padrão mostrou-se coerente com os elevados valores de correlação, menores erros estatísticos e melhor aderência temporal observada entre os dados observados e reanalisados.

4.6.3.3 Sazonalidade mensal da precipitação

A análise da precipitação mensal ao longo dos anos confirmou a forte sazonalidade do regime pluviométrico em todas as estações. Os máximos mensais concentraram-se de forma consistente durante os meses centrais da estação chuvosa, especialmente entre julho, agosto e setembro, enquanto os meses da estação seca apresentaram valores próximos de zero.

Apesar da manutenção do padrão sazonal ao longo de toda a série temporal, observou-se aumento da amplitude dos picos mensais nos anos mais recentes, particularmente nas estações costeiras e de transição. Esse comportamento mostrou-se consistente com a intensificação das máximas anuais identificada nas análises de extremos e refletiu-se nos elevados coeficientes de correlação mensal entre observado e reanálise. Entretanto, a análise conjunta de RMSE, MAE, Bias e inclinações das regressões indicou que os picos mensais mais intensos continuaram sendo sistematicamente subestimados pelas reanálises, contribuindo diretamente para a divergência observada nos extremos absolutos.

Os resultados da ANOVA complementaram essas análises, demonstrando que tanto os produtos de reanálise quanto as estações meteorológicas exerceram influência estatisticamente significativa sobre a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total, evidenciando forte influência das características climáticas regionais sobre o comportamento dos extremos de precipitação. Além disso, a interação significativa entre produto e estação confirmou que o desempenho da ERA5-LAND varia espacialmente conforme as condições climáticas locais de cada região analisada. Esses resultados reforçam que, embora a ERA5-LAND apresente boa capacidade geral de representação da sazonalidade e da variabilidade temporal da precipitação, persistem limitações importantes na reprodução quantitativa da magnitude e frequência dos eventos extremos pluviométricos mais severos.

4.7 Discussão: Comparação do desempenho das reanálises MSWEP V2, ERA5 e ERA5-LAND

A análise comparativa entre os produtos de reanálise MSWEP, ERA5 e ERA5-LAND revelou diferenças importantes na capacidade de representação da precipitação observada nas estações meteorológicas da Guiné-Bissau entre os meses de maio e novembro. De forma geral, os resultados mostraram que o desempenho das reanálises variou significativamente em função da intensidade sazonal das chuvas, da ocorrência de eventos extremos e das características regionais de cada estação.

Entre os três reanálises analisados, o MSWEP apresentou o melhor desempenho geral na representação da precipitação observada, demonstrando maior capacidade de reproduzir tanto os padrões médios sazonais quanto os eventos extremos associados ao período chuvoso. O ERA5 apresentou desempenho intermediário, enquanto o ERA5-LAND mostrou maior variabilidade estatística e maiores limitações durante os meses de precipitação extrema, sobretudo em agosto e setembro.

O melhor desempenho do MSWEP esteve associado principalmente aos menores valores médios de MAE, RMSE e NRMSE observados na maior parte das estações analisadas. Além disso, a reanálise apresentou correlações mais elevadas e coeficientes de determinação superiores, as inclinações das regressões entre observado e MSWEP V2 tendem a se aproximar mais da unidade em comparação aos demais reanálises (Tabela 9) tanto costeiras quanto interiores, indicando maior capacidade explicativa da variabilidade pluviométrica observada. Em diversas estações, o MSWEP conseguiu representar adequadamente os eventos intensos associados ao percentil 90 (P90), reproduzindo com maior consistência temporal os máximos pluviométricos observados.

O ERA5 apresentou desempenho relativamente satisfatório em várias estações, principalmente durante os meses de transição climática, como maio, junho e outubro. Os resultados indicaram correlações moderadas, e em fator 2 a reanálise ERA5 apresenta desempenho intermediário. Os valores de correlação e R^2 são elevados e comparáveis aos do MSWEP V2 em várias estações, sobretudo nas regiões interiores e de transição. No entanto, as inclinações das regressões são sistematicamente inferiores à unidade. Então os erros RMSE e MAE inferiores aos observados no ERA5-LAND em diversos casos. Entretanto, o produto apresentou tendência recorrente de subestimação dos eventos extremos durante o pico da estação chuvosa, sobretudo entre julho e setembro. Embora o ERA5 tenha conseguido representar razoavelmente a variabilidade média da precipitação, persistiram limitações importantes na reprodução da magnitude dos máximos extremos observados.

O ERA5-LAND apresentou desempenho mais heterogêneo entre as estações analisadas. Apesar de apresentar resultados satisfatórios em alguns meses específicos,

especialmente junho e outubro, a reanálise mostrou maiores dificuldades na representação dos extremos pluviométricos severos. Em várias estações, o ERA5-LAND apresentou elevados valores de RMSE e NRMSE, além de fortes tendências de subestimação ou superestimação da precipitação. Os maiores problemas ocorreram principalmente durante agosto e setembro, meses associados ao pico da estação chuvosa, quando diversos eventos extremos superiores a 700 mm, 900 mm e até 1200 mm não foram adequadamente reproduzidos pela reanálise.

A comparação dos boxplots evidenciou que as três reanálises apresentaram comportamento de suavização estatística da precipitação em relação aos dados observados. Entretanto, essa característica foi mais pronunciada no ERA5-LAND e parcialmente no ERA5, enquanto o MSWEP apresentou distribuições mais próximas das observações, maior amplitude interquartil e melhor representação dos outliers extremos. Os coeficientes de correlação reforçaram essa diferença de desempenho na (Tabela 9; Tabela 10). O MSWEP apresentou os maiores valores médios de correlação entre observado e reanálise, indicando melhor capacidade de reproduzir a variabilidade temporal das chuvas. O ERA5 ocupou posição intermediária, enquanto o ERA5-LAND apresentou frequentemente correlações fracas ou estatisticamente não significativas durante os meses mais extremos e na fator 2 as inclinações das regressões indicam valores mais moderado Tabela 10.

Os testes estatísticos também evidenciaram diferenças importantes entre as reanálises. O MSWEP apresentou maior estabilidade estatística, com melhor comportamento em relação à homogeneidade das variâncias e menor persistência temporal dos resíduos em várias estações. O ERA5 mostrou desempenho intermediário, enquanto o ERA5-LAND apresentou maior frequência de autocorrelação positiva dos resíduos, indicando persistência temporal dos erros e maior dificuldade em representar adequadamente sequências prolongadas de eventos convectivos intensos.

Durante os meses de menor intensidade pluviométrica, especialmente maio e novembro, as três reanálises apresentaram desempenho relativamente semelhante, embora o MSWEP ainda tenha mantido vantagem estatística em diversas estações. Contudo, durante o pico da estação chuvosa, entre julho e setembro, as diferenças tornaram-se mais evidentes. Nesse período, o MSWEP demonstrou maior capacidade de representar eventos extremos e variabilidade interanual, enquanto ERA5 e ERA5-LAND apresentaram forte tendência de subestimação dos máximos pluviométricos e redução da amplitude das chuvas observadas.

As diferenças entre as reanálises são mais pronunciadas nas estações costeiras (Bissau, Bolama, Catió e Suzana), onde a precipitação extrema na (Figura 28; 30; 32 e 40) é fortemente influenciada por processos convectivos e pela disponibilidade de umidade oceânica. Nessas regiões, o MSWEP V2 apresenta clara vantagem, reproduzindo melhor tanto a magnitude quanto a variabilidade dos extremos. Nas estações do

interior (Bafatá, Farim, Gabú e Mansabá) na (Figura 12; 34; 36 e 38), as diferenças entre MSWEP V2 e ERA5 são menores, embora o ERA5-LAND continue apresentando desempenho inferior.

De forma geral, os resultados indicam que o MSWEP foi o melhor desempenho para representação da precipitação na Guiné-Bissau, apresentando maior consistência estatística, melhor capacidade de representação dos eventos extremos e menores erros médios em comparação ao ERA5 e ao ERA5-LAND. O ERA5 apresentou desempenho intermediário e relativamente satisfatório na reprodução da variabilidade sazonal média, enquanto o ERA5-LAND mostrou maiores limitações na representação da magnitude e frequência dos extremos pluviométricos, sobretudo durante o pico da estação chuvosa.

Esses resultados demonstram que a reanálise com maior integração de dados observados, como o MSWEP, tendem a representar de forma mais consistente os regimes pluviométricos tropicais altamente convectivos da Guiné-Bissau. Por outro lado, os produtos ERA5 e ERA5-LAND, apesar de úteis para análises climáticas regionais e também na análise de tendências e avaliação de extremos de precipitação, apresentam limitações importantes na representação de eventos extremos locais e sistemas convectivos intensos característicos da região tropical oeste-africana.

5 CONCLUSÃO

Para concluir, visto que o estudo sobre a precipitação na Guiné-Bissau, um país situado na zona tropical da África Ocidental, tem um grande importância. Muito embora seja uma zona de pouco estudos devido à escassez dos dados.

Os resultados obtidos através da estatística descritiva foram importantes para entender o comportamento espaço temporal da precipitação na Guiné-Bissau. A estação de Catió, na região sul do país, as médias e medianas apresentaram forte sazonalidade, com maiores valores de acumulados entre os meses de junho a outubro, com valores ultrapassando 1000 mm em determinados meses. Enquanto os desvios padrão permaneceram elevados durante os períodos mais chuvosos, refletindo grande dispersão dos dados e forte influência dos extremos pluviométricos. Os coeficientes de variação indicaram elevada heterogeneidade temporal da precipitação, sobretudo nas estações costeiras e de transição climática.

A aplicação do modelo de um polinômio de terceira ordem se demonstrou adequado para identificar os meses de julho, agosto e setembro como os mais chuvosos.

A análise das métricas estatísticas revelou forte dependência sazonal do desempenho de reanálise. Durante julho, agosto e setembro, correspondentes ao maior acúmulo da estação chuvosa, ocorreram os maiores valores de RMSE e MAE, acompanhados de aumento da dispersão estatística e redução da capacidade explicativa das reanálises. Em diversas estações, agosto apresentou os maiores erros absolutos e maior dificuldade de representação dos extremos severos, evidenciando as limitações dos modelos nos eventos convectivos intensos.

Os boxplots mostraram predominância de distribuições assimétricas positivas, forte dispersão interquartil e elevada presença de outliers superiores associados aos eventos extremos pluviométricos. As estações costeiras, como Bolama, Catió e Suzana, apresentaram os maiores extremos anuais e mensais, frequentemente superiores a 600 mm e, em alguns casos, próximos ou superiores a 700 mm. Em contrapartida, as estações interiores apresentaram máximas anuais relativamente menores, embora também tenham demonstrado intensificação gradual dos extremos nas últimas décadas.

Os testes estatísticos complementaram as análises descritivas e inferenciais. O teste de Shapiro-Wilk mostrou predominância de distribuições não normais em diversos meses, sobretudo durante os períodos associados aos extremos pluviométricos mais intensos. O teste de Levene indicou predominância de homogeneidade das variâncias na maior parte das estações e meses, embora algumas estações costeiras tenham apresentado diferenças significativas entre as dispersões observadas e reanalisadas. Já o teste de Durbin-Watson mostrou independência residual satisfatória em boa parte dos casos, mas revelou autocorrelação positiva significativa durante o pico da estação chuvosa, especialmente em agosto.

Sendo agosto o mês que registra os maiores acumulados e os picos mais intensos de precipitação em todas as estações analisadas. A comparação entre as estações evidencia que as regiões litorâneas como Bissau (centro), Bolama e Catió (sul) e Suzana (norte) apresentam volumes de precipitação superiores aos observados nas áreas centrais do país.

As tendências pluviométricas indicam ainda comportamentos semelhantes entre alguns grupos de estações: Bafatá (interior) e Bolama (litoral) apresentam padrões próximos; Bigene (norte), Bissau e Catió (litoral), e Gabú (interior) formam outro conjunto com características similares; enquanto Farim, Mansabá e Suzana, situadas na porção norte, apresentam dinâmicas pluviométricas semelhantes entre si.

A modelagem e os testes estatísticos indicam que as reanálises representam, de modo geral, de forma satisfatória os dados observados nas estações analisadas: a comparação entre as reanálises MSWEP V2, ERA5 e ERA5-LAND nas estações da Guiné-Bissau revela que todas apresentam boa capacidade de reproduzir a variabilidade temporal e a sazonalidade da precipitação, com correlações elevadas em relação aos dados observados. Contudo, diferenças importantes surgem na representação da magnitude e dos extremos pluviométricos. Os melhores desempenhos ocorreram durante os períodos de transição sazonal, especialmente nos meses de maio, junho e outubro, quando foram observados menores valores de RMSE, MAE e NRMSE, além de correlações moderadas a fortes entre os dados observados e reanalisados.

As análises de regressão linear mostraram elevada concordância estatística entre observado e reanálise, com coeficientes de determinação frequentemente elevados e elevada significância estatística dos ajustes lineares. Entretanto, a análise do fator 2 (FAT2) mostrou que parte significativa dos extremos permaneceu afastada do comportamento idealizado, confirmando persistência de dispersão elevada nos eventos mais intensos.

Os resultados da ANOVA de dois fatores com interação demonstraram que tanto os produtos de reanálise quanto as estações meteorológicas exerceram influência estatisticamente significativa sobre a variabilidade pluviométrica ($p < 0,001$). O fator estação apresentou maior contribuição para a variabilidade total dos dados, evidenci-

ando forte influência das características climáticas regionais sobre o comportamento da precipitação extrema. Além disso, a interação significativa entre produto e estação confirmou que o desempenho das reanálises varia espacialmente conforme as características locais de cada região analisada.

O MSWEP V2 apresenta o melhor desempenho global, com maiores valores de correlação e R^2 , além de inclinações mais próximas da unidade, reproduzindo de forma mais fiel a variabilidade e os picos de precipitação. O ERA5 apresenta desempenho intermediário, capturando bem a variabilidade temporal, mas com tendência à subestimação dos totais mais elevados e menor aderência aos extremos. Já o ERA5-LAND mostra desempenho inferior, com menores valores de R^2 e maiores limitações na representação da magnitude dos eventos intensos. Além disso, os valores de Bias mostraram alternância entre subestimação e superestimação da precipitação, dependendo do mês e da estação analisada.

As diferenças entre as reanálises são mais evidentes nas estações costeiras, onde o MSWEP V2 se destaca na reprodução dos extremos, enquanto nas estações do interior as diferenças entre MSWEP V2 e ERA5 são menores. De modo geral, o MSWEP V2 é o produto mais adequado para estudos climáticos e análise de extremos na Guiné-Bissau, seguido pelo ERA5, enquanto o ERA5-LAND deve ser utilizado com cautela, especialmente em análises de eventos intensos.

Para MSWEP V2, nas estações interiores, projeta-se aumento das máximas anuais de precipitação até 2030, com boa representação da variabilidade pelas reanálises, embora com subestimação dos valores mais elevados. Nas estações costeiras, os extremos permanecem mais intensos e heterogêneos, com tendência de estabilização em algumas áreas e maiores volumes em Suzana. De forma geral, apesar do bom desempenho estatístico, as reanálises apresentam viés persistente na representação dos eventos extremos, sobretudo nas regiões costeiras.

As extrapolações das máximas anuais de precipitação até 2030 indicam continuidade ou intensificação moderada dos extremos na maioria das estações. Nas regiões costeiras, os valores projetados permanecem mais elevados, enquanto nas áreas de transição e do interior observa-se aumento progressivo, porém com magnitudes relativamente menores. Em geral, a reanálise ERA5 reproduz bem a variabilidade temporal e as tendências da precipitação, mas apresenta limitações na representação dos eventos extremos mais intensos, especialmente nas zonas costeiras. Os intervalos de confiança de 95% (IC95%) permaneceram relativamente estreitos em algumas estações, evidenciando robustez estatística e estabilidade dos parâmetros, e nas outras, mais amplos, evidenciando maior variabilidade interanual das precipitações extremas.

A extrapolação das curvas cúbicas até 2030 indica a manutenção de valores elevados das máximas anuais de precipitação em todas as estações, com diferenças regionais bem definidas. Nas áreas costeiras, projeta-se persistência de extremos

elevados, com tendência à estabilização ou leve redução. Nas estações de transição, observa-se continuidade da tendência positiva, enquanto no interior as projeções indicam aumento gradual das máximas anuais, porém com magnitudes inferiores às regiões costeiras. De modo geral, os resultados mantêm coerência com os padrões estatísticos observados, embora as reanálises ERA5-LAND apresentem limitações na representação dos extremos mais intensos.

REFERÊNCIAS

ARNASTAUSKAITĖ, J.; RUZGAS, T.; BRAŽĖNAS, M. An Exhaustive Power Comparison of Normality Tests. **Mathematics**, v.9, n.7, p.788, 2021.

BECK, H. E.; PAN, M.; ROY, T.; WEEDON, G. P.; PAPPENBERGER, F.; VAN DIJK, A. I.; HUFFMAN, G. J.; ADLER, R. F.; WOOD, E. F. Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for the CONUS. **Hydrology and Earth System Sciences**, v.23, n.1, p.207–224, 2019.

BECK, H. E.; VERGOPOLAN, N.; PAN, M.; LEVIZZANI, V.; VAN DIJK, A. I.; WEEDON, G. P.; BROCCA, L.; PAPPENBERGER, F.; HUFFMAN, G. J.; WOOD, E. F. Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. **Hydrology and Earth System Sciences**, v.21, n.12, p.6201–6217, 2017.

BECK, H. E.; WOOD, E. F.; PAN, M.; FISHER, C. K.; MIRALLES, D. G.; VAN DIJK, A. I.; MCVICAR, T. R.; ADLER, R. F. MSWEP V2 global 3-hourly 0.1 precipitation: methodology and quantitative assessment. **Bulletin of the American Meteorological Society**, v.100, n.3, p.473–500, 2019.

BERTHOU, S.; ROWELL, D. P.; KENDON, E. J.; ROBERTS, M. J.; STRATTON, R. A.; CROOK, J. A.; WILCOX, C. Improved climatological precipitation characteristics over West Africa at convection-permitting scales. **Climate Dynamics**, v.53, p.1991–2011, 2019.

BROWN, M. B.; FORSYTHE, A. B. Robust Tests for the Equality of Variances. **Journal of the American Statistical Association**, v.69, n.346, p.364–367, 1974.

BURDEN, R. L.; FAIRES, J. D. **Numerical Analysis**. 4th.ed. Boston: PWS-Kent Publishing Company, 1989.

CHANG, J. C.; HANNA, S. R. Air Quality Model Performance Evaluation. **Meteorology and Atmospheric Physics**, v.87, n.1–3, p.167–196, 2004.

DALY, C.; HALBLEIB, M.; SMITH, J. I.; GIBSON, W. P.; DOGGETT, M. K.; TAYLOR, G. H.; CURTIS, J.; PASTERIS, P. P. Physiographically sensitive mapping of climatological temperature and precipitation across the conterminous United States. **International Journal of Climatology: a Journal of the Royal Meteorological Society**, v.28, n.15, p.2031–2064, 2008.

DIEDHIOU, A.; BICHET, A.; WARTENBURGER, R.; SENEVIRATNE, S. I.; ROWELL, D. P.; SYLLA, M. B.; DIALLO, I.; TODZO, S.; TOURÉ, N. E.; CAMARA, M. et al. Changes in climate extremes over West and Central Africa at 1.5 C and 2 C global warming. **Environmental Research Letters**, v.13, n.6, p.065020, 2018.

DURBIN, J.; WATSON, G. S. Testing for Serial Correlation in Least Squares Regression. I. **Biometrika**, v.37, n.3–4, p.409–428, 1950.

DURBIN, J.; WATSON, G. S. Testing for Serial Correlation in Least Squares Regression. II. **Biometrika**, v.38, n.1–2, p.159–177, 1951.

EYRING, V.; BONY, S.; MEEHL, G. A.; SENIOR, C. A.; STEVENS, B.; STOUFFER, R. J.; TAYLOR, K. E. Visão geral do projeto experimental e organização da Fase 6 do Projeto de Intercomparação de Modelos Acoplados (CMIP6). **Desenvolvimento de Modelos Geocientíficos**, v.9, n.5, p.1937–1958, 2016.

EYRING, V.; BONY, S.; MEEHL, G. A.; SENIOR, C. A.; STEVENS, B.; STOUFFER, R. J.; TAYLOR, K. E. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) Experimental Design and Organization. **Geoscientific Model Development**, v.9, n.5, p.1937–1958, 2016.

FAO. Food and Agriculture Organization of the United Nations. **URL: <http://faostat.fao.org>**, 2018.

GEBRECHORKOS, S. H.; LEYLAND, J.; DADSON, S. J.; COHEN, S.; SLATER, L.; WORTMANN, M.; ASHWORTH, P. J.; BENNETT, G. L.; BOOTHROYD, R.; CLOKE, H. et al. Global scale evaluation of precipitation datasets for hydrological modelling. **Hydrology and Earth System Sciences Discussions**, v.2023, p.1–33, 2023.

HANNA, S.; CHANG, J. Acceptance Criteria for Urban Dispersion Model Evaluation. **Meteorology and Atmospheric Physics**, v.116, n.3, p.133–146, 2012.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2.ed. New York, NY: Springer, 2009.

HELSEL, D.; HIRSCH, R.; RYBERG, K.; ARCHFIELD, S.; GILROY, E. **Statistical methods in water resources**: US Geological Survey Techniques and Methods, book 4, chap. A3, 458 p., accessed September 20, 2021.

HEROLD, N.; ALEXANDER, L.; DONAT, M.; CONTRACTOR, S.; BECKER, A. How much does it rain over land? **Geophysical Research Letters**, v.43, n.1, p.341–348, 2016.

HERSBACH, H.; BELL, B.; BERRISFORD, P.; HIRAHARA, S.; HORÁNYI, A.; MUÑOZ-SABATER, J.; NICOLAS, J.; PEUBEY, C.; RADU, R.; SCHEPERS, D. et al. The ERA5 global reanalysis. **Quarterly journal of the royal meteorological society**, v.146, n.730, p.1999–2049, 2020.

HESSION, S. L.; MOORE, N. A spatial regression analysis of the influence of topography on monthly rainfall in East Africa. **International journal of climatology**, v.31, n.10, p.1440–1456, 2011.

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

JAMIESON, P. D. et al. A Comparison of Methods for Estimating the Standard Error of the NRMSE. **Agricultural and Forest Meteorology**, v.56, p.1–11, 1991.

KIDD, C.; LEVIZZANI, V. Status of satellite precipitation retrievals. **Hydrology and Earth System Sciences**, v.15, n.4, p.1109–1116, 2011.

KIRSCHBAUM, D. B.; HUFFMAN, G. J.; ADLER, R. F.; BRAUN, S.; GARRETT, K.; JONES, E.; MCNALLY, A.; SKOFRONICK-JACKSON, G.; STOCKER, E.; WU, H. et al. NASA's remotely sensed precipitation: A reservoir for applications users. **Bulletin of the American Meteorological Society**, v.98, n.6, p.1169–1184, 2017.

KLEIN, C.; HEINZELLER, D.; BLIEFERNICHT, J.; KUNSTMANN, H. Variability of West African monsoon patterns generated by a WRF multi-physics ensemble. **Climate Dynamics**, v.45, p.2733–2755, 2015.

KLUTSE, N. A. B.; QUAGRAINE, K. A.; NKRUMAH, F.; QUAGRAINE, K. T.; BERKHO-OFORIWAA, R.; DZROBI, J. F.; SYLLA, M. B. The climatic analysis of summer monsoon extreme precipitation events over West Africa in CMIP6 simulations. **Earth Systems and Environment**, v.5, p.25–41, 2021.

KRISHNAMURTHY, V.; AJAYAMOHAN, R. Composite structure of monsoon low pressure systems and its relation to Indian rainfall. **Journal of Climate**, v.23, n.16, p.4285–4305, 2010.

KUCERA, P. A.; EBERT, E. E.; TURK, F. J.; LEVIZZANI, V.; KIRSCHBAUM, D.; TAPIADOR, F. J.; LOEW, A.; BORSCHE, M. Precipitation from space: Advancing Earth system science. **Bulletin of the American Meteorological Society**, v.94, n.3, p.365–375, 2013.

LAPPONI, J. C. **Estatística usando excel**. Rio de Janeiro: Elsevier Brasil, 2005.

LEE, S. W. Methods for Testing Statistical Differences between Groups in Medical Research. **Life Cycle**, v.2, p.1–12, 2022.

LEVENE, H. Robust Tests for Equality of Variances. , p.278–292, 1960.

MADSEN, H.; MIKKELSEN, P. S.; ROSBJERG, D.; HARREMOËS, P. Regional estimation of rainfall intensity-duration-frequency curves using generalized least squares regression of partial duration series statistics. **Water Resources Research**, v.38, n.11, p.21–1, 2002.

MENDES, O. Indicadores das Mudanças Climáticas no Leste da Guiné-Bissau e Adaptação Camponesa. **Sintidus**, n.1, p.108–139, 2018.

MENDES, O.; FRAGOSO, M. Assessment of the Record-Breaking 2020 Rainfall in Guinea-Bissau and Impacts of Associated Floods. **Geosciences**, v.13, n.2, p.25, 2023.

MICHAELIDES, S.; LEVIZZANI, V.; ANAGNOSTOU, E.; BAUER, P.; KASPARIS, T.; LANE, J. Precipitation: Measurement, remote sensing, climatology and modeling. **Atmospheric Research**, v.94, n.4, p.512–533, 2009.

MONTGOMERY, D. C. **Design and analysis of experiments**. Hoboken, NJ: John wiley & sons, 2017.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 5.ed. Hoboken, NJ: John Wiley & Sons, 2012.

MOREIRA, E. E.; AUGUSTO, V. Assessing changes in intra-and inter-annual precipitation variability using advanced statistical inference techniques. **Journal of Water and Climate Change**, v.15, n.10, p.4936–4951, 2024.

MORIASI, D. N. et al. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. **Transactions of the ASABE**, v.50, n.3, p.885–900, 2007.

MUÑOZ-SABATER, J.; DUTRA, E.; AGUSTÍ-PANAREDA, A.; ALBERGEL, C.; ARDUINI, G.; BALSAMO, G.; BOUSSETTA, S.; CHOULGA, M.; HARRIGAN, S.; HERSBACH, H. et al. ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. **Earth system science data**, v.13, n.9, p.4349–4383, 2021.

NICHOLSON, S. E.; PALAO, I. M. A re-evaluation of rainfall variability in the sahel. Part I. Characteristics of rainfall fluctuations. **International journal of climatology**, v.13, n.4, p.371–389, 1993.

NOONI, I. K.; OGOU, F. K.; CHAIBOU, A. A. S.; NAKOTY, F. M.; GNITOU, G. T.; LU, J. Evaluating CMIP6 historical mean precipitation over Africa and the Arabian Peninsula against satellite-based observation. **Atmosphere**, v.14, n.3, p.607, 2023.

NOVELLA, N. S.; THIAW, W. M. African rainfall climatology version 2 for famine early warning systems. **Journal of Applied meteorology and Climatology**, v.52, n.3, p.588–606, 2013.

OMOTOSHO, J.; ABIODUN, B. J. A numerical study of moisture build-up and rainfall over West Africa. **Meteorological Applications: A journal of forecasting, practical applications, training techniques and modelling**, v.14, n.3, p.209–225, 2007.

PALIT, A. K.; POPOVIC, D. **Computational intelligence in time series forecasting: theory and engineering applications**. New York: Springer Science & Business Media, 2006.

PORTUGUEZ-MAURTUA, M.; ARUMI, J. L.; LAGOS, O.; STEHR, A.; MONTALVO ARQUINIGO, N. Filling gaps in daily precipitation series using regression and machine learning in Inter-Andean Watersheds. **Water**, v.14, n.11, p.1799, 2022.

PREIN, A. F.; GOBIET, A. Impacts of uncertainties in European gridded precipitation observations on regional climate analysis. **International Journal of Climatology**, v.37, n.1, p.305–327, 2017.

QUADROS, R.; BUSKE, D.; CEZIMBRA, R. Modelo analítico de dispersão de poluentes considerando o efeito de ascensão da pluma. **Anais do Congresso de Iniciação Científica – CIC/UFPEL**, 2006.

RAZALI, N. M.; WAH, Y. B. Power Comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling Tests. **Journal of Statistical Modeling and Analytics**, v.2, n.1, p.21–33, 2011.

RUGGIERO, M. A. G.; ROCHA LOPES, V. L. da. **Cálculo numérico: aspectos teóricos e computacionais**. São Paulo: Pearson/Makron, 1998.

SAMBÚ, F. B. **Variabilidade Climática da Precepitação na Região da Guiné-Bissau: Situação Sinóptica e a Influência dos Sistemas Convectivos**. 2003. Dissertação (Mestrado em Ciência da Computação) — Universidade de Évora.

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality. **Biometrika**, v.52, n.3/4, p.591–611, 1965.

SIVAKUMAR, M. V.; COLLINS, C.; JAY, A.; HANSEN, J. Regional priorities for strengthening climate services for farmers in Africa and South Asia. **CGIAR Research Program on Climate Change, Agriculture and Food Security (CCAFS)**, n.71, 2014.

STEPHENS, G. L.; L'ECUYER, T.; FORBES, R.; GETTELMEN, A.; GOLAZ, J.-C.; BODAS-SALCEDO, A.; SUZUKI, K.; GABRIEL, P.; HAYNES, J. Dreary state of precipitation in global models. **Journal of Geophysical Research: Atmospheres**, v.115, n.D24, 2010.

SULTAN, B.; JANICOT, S.; DROBINSKI, P. Characterization of the diurnal cycle of the West African monsoon around the monsoon onset. **Journal of climate**, v.20, n.15, p.4014–4032, 2007.

SUN, H.; SAEEDI, P.; KARURANGA, S.; PINKEPANK, M.; OGURTSOVA, K.; DUNCAN, B. B.; STEIN, C.; BASIT, A.; CHAN, J. C.; MBANYA, J. C. et al. IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045. **Diabetes research and clinical practice**, v.183, p.109119, 2022.

SYLLA, M. B.; PAL, J. S.; FAYE, A.; DIMOBE, K.; KUNSTMANN, H. Climate change to severely impact West African basin scale irrigation in 2 C and 1.5 C global warming scenarios. **Scientific Reports**, v.8, 2018.

SYLLA, M.; GAYE, A.; PAL, J. S.; JENKINS, G.; BI, X. High-resolution simulations of West African climate using regional climate model (RegCM3) with different lateral boundary conditions. **Theoretical and Applied Climatology**, v.98, p.293–314, 2009.

TA, S.; KOUADIO, K.; ALI, K.; TOUALY, E.; AMAN, A.; YOROBA, F. West Africa extreme rainfall events and large-scale ocean surface and atmospheric conditions in the tropical Atlantic. **Advances in Meteorology**, v.2016, n.1, p.1940456, 2016.

TANIMOUNE, L. I.; ABIODUN, B. J.; POUWEREU, N.; KUNSTMANN, H.; SMIA-TEK, G.; AJAYI, V. O.; SANDA, I. S. How well does MPAS simulate the West African Monsoon? **Journal of Earth System Science**, v.133, n.2, p.56, 2024.

TAPIADOR, F. J.; TURK, F. J.; PETERSEN, W.; HOU, A. Y.; GARCÍA-ORTEGA, E.; MACHADO, L. A.; ANGELIS, C. F.; SALIO, P.; KIDD, C.; HUFFMAN, G. J. et al. Global precipitation measurement: Methods, datasets and applications. **Atmospheric Research**, v.104, p.70–97, 2012.

TIAN, Y.; PETERS-LIDARD, C. D. A global map of uncertainties in satellite-based precipitation measurements. **Geophysical Research Letters**, v.37, n.24, 2010.

TREPPIEDI, D.; CIPOLLA, G.; FRANCIPANE, A.; NOTO, L. Detecting precipitation trend using a multiscale approach based on quantile regression over a Mediterranean area. **International Journal of Climatology**, v.41, n.13, p.5938–5955, 2021.

WANG, Y.; GIL, P. Rodríguez de; CHEN, Y.-H.; KROMREY, J. D.; KIM, E. S.; PHAM, T.; ROMANO, J. L. Comparing the Performance of Approaches for Testing the Homogeneity of Variance Assumption in One-Factor ANOVA Models. **Educational and Psychological Measurement**, v.77, n.2, p.305–329, 2017.

WEISBERG, S. **Applied Linear Regression**. 4.ed. Hoboken, NJ: John Wiley & Sons, 2014.

WILKS, D. S. **Statistical Methods in the Atmospheric Sciences**. 3.ed. Amsterdam: Academic Press, 2011.

XIE, P.; JOYCE, R.; WU, S.; YOO, S.-H.; YAROSH, Y.; SUN, F.; LIN, R. Reprocessed, bias-corrected CMORPH global high-resolution precipitation estimates from 1998. **Journal of Hydrometeorology**, v.18, n.6, p.1617–1641, 2017.

YIN, Y. Model-Free Tests for Series Correlation in Multivariate Linear Regression. **Journal of Statistical Planning and Inference**, v.206, p.179–195, 2020.

ZAR, J. H. **Biostatistical Analysis**. 5.ed. Upper Saddle River, NJ: Pearson, 2010.

ZWIERS, F. Interannual variability and predictability in an ensemble of AMIP climate simulations conducted with the CCC GCM2. **Climate Dynamics**, v.12, n.12, p.825–847, 1996.

6 UM ANEXO

6.1 TABELA E GRÁFICOS DE REANÁLISE MSWEP V2

TABELAS DE MÉTRICAS ESTATÍSTICAS — MSWEP v2

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	19.20	-6.32	29.30	32.08	0.91	0.45	0.20	0.0094
Junho	47.27	-2.07	58.26	49.10	1.19	0.42	0.17	0.0157
Julho	66.85	40.54	98.25	94.05	1.04	0.60	0.36	0.0002
Agosto	135.47	111.32	166.20	97.74	1.70	0.13	0.02	0.4730
Setembro	74.18	9.63	100.42	81.43	1.23	0.11	0.01	0.5495
Outubro	56.04	17.22	73.23	77.44	0.95	0.51	0.26	0.0026
Novembro	11.12	10.24	16.24	10.95	1.48	0.59	0.34	0.0003

Tabela 11 – Métricas estatísticas mensais de MSWEP v2 para a estação de Bafatá.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	4.55	-2.25	8.45	11.45	0.74	0.70	0.49	0.0000
Junho	37.78	15.78	52.39	55.18	0.95	0.52	0.27	0.0020
Julho	124.15	86.59	147.41	101.36	1.45	0.27	0.07	0.1360
Agosto	215.04	200.64	243.14	105.17	2.31	0.06	0.00	0.7287
Setembro	126.38	101.88	157.56	97.10	1.62	0.19	0.04	0.2951
Outubro	50.11	3.81	71.64	75.61	0.95	0.33	0.11	0.0633
Novembro	8.69	6.12	13.32	9.24	1.44	0.31	0.10	0.0743

Tabela 12 – Métricas estatísticas mensais de MSWEP v2 para a estação de Bigene.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	16.57	-14.87	30.94	28.22	1.10	0.22	0.05	0.2200
Junho	67.48	-45.73	109.90	106.09	1.04	0.37	0.14	0.0343
Julho	102.29	53.18	124.94	125.99	0.99	0.64	0.41	0.0001
Agosto	128.03	112.57	172.23	121.74	1.41	0.42	0.18	0.0144
Setembro	100.65	7.88	123.46	126.78	0.97	0.43	0.18	0.0133
Outubro	47.72	-13.48	58.86	77.33	0.76	0.66	0.44	0.0000
Novembro	18.27	2.79	28.79	31.40	0.92	0.38	0.15	0.0279

Tabela 13 – Métricas estatísticas mensais de MSWEP v2 para a estação de Bissau.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	16.58	-4.00	32.99	36.86	0.90	0.46	0.21	0.0074
Junho	65.35	-5.65	79.58	77.21	1.03	0.43	0.18	0.0136
Julho	126.94	-33.19	157.77	167.89	0.94	0.53	0.28	0.0016
Agosto	125.35	68.14	156.15	128.39	1.22	0.43	0.19	0.0115
Setembro	95.66	1.55	117.87	111.84	1.05	0.32	0.10	0.0721
Outubro	65.99	13.85	82.48	100.21	0.82	0.57	0.32	0.0006
Novembro	25.29	16.74	30.51	27.66	1.10	0.46	0.21	0.0075

Tabela 14 – Métricas estatísticas mensais de MSWEP v2 para a estação de Bolama.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	91.81	-86.90	134.98	103.06	1.31	0.02	0.00	0.8902
Junho	214.77	-160.79	269.91	233.21	1.16	0.33	0.11	0.0583
Julho	251.62	80.59	305.71	211.27	1.45	-0.09	0.01	0.6314
Agosto	307.58	291.03	350.09	147.10	2.38	0.15	0.02	0.4196
Setembro	193.84	176.38	226.70	132.61	1.71	0.33	0.11	0.0603
Outubro	184.38	184.38	202.02	63.89	3.16	0.15	0.02	0.4002
Novembro	36.30	35.83	41.91	15.07	2.78	0.33	0.11	0.0626

Tabela 15 – Métricas estatísticas mensais de MSWEP v2 para a estação de Catió.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	7.96	0.71	12.82	12.15	1.06	0.35	0.13	0.0434
Junho	57.49	-4.98	73.24	69.72	1.05	0.27	0.07	0.1306
Julho	78.71	18.60	98.00	133.54	0.73	0.68	0.46	0.0000
Agosto	130.99	21.54	169.53	168.09	1.01	0.22	0.05	0.2172
Setembro	116.97	-46.91	179.73	189.18	0.95	0.37	0.14	0.0350
Outubro	55.26	1.85	80.34	79.50	1.01	0.22	0.05	0.2219
Novembro	10.67	9.29	16.29	5.44	3.00	-0.02	0.00	0.9193

Tabela 16 – Métricas estatísticas mensais de MSWEP v2 para a estação de Farim.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	15.86	-8.64	21.77	28.07	0.78	0.69	0.48	0.0000
Junho	67.50	-40.49	78.93	54.70	1.44	0.22	0.05	0.2248
Julho	71.56	14.60	101.34	94.80	1.07	0.39	0.15	0.0238
Agosto	83.13	38.22	100.16	101.74	0.98	0.49	0.24	0.0035
Setembro	115.27	23.54	135.05	116.52	1.16	-0.01	0.00	0.9641
Outubro	71.37	42.61	87.59	64.88	1.35	0.35	0.12	0.0474
Novembro	10.61	9.71	15.55	11.57	1.34	0.64	0.41	0.0001

Tabela 17 – Métricas estatísticas mensais de MSWEP v2 para a estação de Gabú.


Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	11.45	-1.64	16.52	18.26	0.90	0.48	0.23	0.0052
Junho	46.75	1.27	57.61	59.57	0.97	0.49	0.24	0.0040
Julho	100.65	3.93	128.14	140.69	0.91	0.46	0.21	0.0070
Agosto	158.24	97.49	196.84	157.77	1.25	0.19	0.04	0.2777
Setembro	92.75	11.26	113.30	119.23	0.95	0.42	0.18	0.0139
Outubro	58.92	-12.22	80.66	85.12	0.95	0.38	0.14	0.0300
Novembro	16.42	9.28	23.87	19.37	1.23	0.30	0.09	0.0911

Tabela 18 – Métricas estatísticas mensais de MSWEP v2 para a estação de Mansabá.


Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	19.93	-19.36	34.71	30.31	1.15	0.43	0.18	0.0136
Junho	46.61	34.64	66.00	38.73	1.70	0.55	0.30	0.0009
Julho	106.56	-1.14	157.10	113.73	1.38	0.42	0.18	0.0150
Agosto	148.57	-73.34	183.35	158.29	1.16	0.23	0.05	0.2055
Setembro	92.13	-16.53	115.21	112.24	1.03	0.48	0.23	0.0048
Outubro	47.05	-42.76	67.81	76.24	0.89	0.72	0.52	0.0000
Novembro	26.51	-13.04	54.93	54.18	1.01	0.08	0.01	0.6606

Tabela 19 – Métricas estatísticas mensais de MSWEP v2 para a estação de Suzana.


Bigene Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 25 – Distribuição mensal da precipitação na estação de Bigene para os meses de maio a novembro.


Bigene Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 26 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Bigene para os meses de maio a novembro.


Bissau Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 27 – Distribuição mensal da precipitação na estação de Bissau para os meses de maio a novembro.


Bissau Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 28 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Bissau para os meses de maio a novembro.


Bolama Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 29 – Distribuição mensal da precipitação na estação de Bolama para os meses de maio a novembro.


Bolama Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 30 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Bolama para os meses de maio a novembro.


Catió Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 31 – Distribuição mensal da precipitação na estação de Bigene para os meses de maio a novembro.


catiό Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 32 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Catiό para os meses de maio a novembro.


Farim Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 33 – Distribuição mensal da precipitação na estação de Farim para os meses de maio a novembro.


Farim Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 34 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Farim para os meses de maio a novembro.


Gabú Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 35 – Distribuição mensal da precipitação na estação de Gabú para os meses de maio a novembro.


Gabú Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 36 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Gabú para os meses de maio a novembro.


Mansabá Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 37 – Distribuição mensal da precipitação na estação de Mansabá para os meses de maio a novembro.

Mansabá Extremo




Figura 38 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Mansabá para os meses de maio a novembro.

Suzana Boxplot




Figura 39 – Distribuição mensal da precipitação na estação de Suzana para os meses de maio a novembro.

Suzana Extremo




Figura 40 – Série temporal de distribuição mensal dos extremos da precipitação na estação de Suzana para os meses de maio a novembro.

6.2 TABELA E GRÁFICOS DE REANÁLISE ERA5

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	17.66	-13.14	31.35	32.08	0.98	0.45	0.20	0.0093
Junho	54.58	-42.57	64.24	49.10	1.31	0.41	0.17	0.0166
Julho	54.45	-2.96	82.10	94.05	0.87	0.60	0.36	0.0002
Agosto	90.41	-17.09	110.53	97.74	1.13	0.13	0.02	0.4710
Setembro	99.89	-84.54	126.09	81.43	1.55	0.04	0.00	0.8228
Outubro	60.51	-42.39	78.31	77.44	1.01	0.51	0.26	0.0026
Novembro	10.47	9.60	15.32	10.95	1.40	0.59	0.35	0.0003

Tabela 20 – Métricas estatísticas mensais de ERA5 para estação de Bafatá.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	4.82	-3.15	9.03	11.43	0.79	0.70	0.49	0.001
Junho	30.78	-11.81	48.08	55.14	0.87	0.52	0.27	0.0019
Julho	114.21	71.49	136.45	101.11	1.35	0.26	0.07	0.1382
Agosto	163.16	134.96	186.29	105.25	1.77	0.06	0.00	0.7364
Setembro	113.59	86.36	144.60	96.84	1.49	0.20	0.04	0.2730
Outubro	50.15	4.30	71.43	76.01	0.94	0.33	0.11	0.0584
Novembro	9.29	6.95	14.22	9.23	1.54	0.31	0.10	0.0794

Tabela 21 – Métricas estatísticas mensais de ERA5 para estação de Bigene.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	15.69	-11.86	29.59	28.18	1.05	0.23	0.05	0.2045
Junho	74.36	-55.95	115.02	106.42	1.08	0.32	0.10	0.0713
Julho	82.88	-23.33	99.79	126.24	0.79	0.67	0.45	0.001
Agosto	87.11	-25.95	112.39	121.93	0.92	0.55	0.31	0.0008
Setembro	112.32	-52.29	143.67	127.20	1.13	0.32	0.10	0.0736
Outubro	50.29	-21.81	64.37	77.55	0.83	0.61	0.37	0.001
Novembro	21.51	8.38	29.76	31.33	0.95	0.42	0.17	0.0155

Tabela 22 – Métricas estatísticas mensais de ERA5 para estação de Bissau.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	17.28	-8.77	33.46	36.77	0.91	0.46	0.21	0.0075
Junho	66.85	-32.82	81.26	77.31	1.05	0.43	0.18	0.0125
Julho	150.33	-108.13	182.06	168.13	1.08	0.53	0.28	0.0016
Agosto	134.85	-113.20	166.62	128.17	1.30	0.44	0.19	0.0105
Setembro	103.89	-35.67	124.42	112.09	1.11	0.27	0.07	0.1289
Outubro	63.08	-0.37	82.26	100.31	0.82	0.55	0.31	0.0008
Novembro	27.70	20.28	33.10	27.58	1.20	0.46	0.21	0.0072

Tabela 23 – Métricas estatísticas mensais de ERA5 para estação de Bolama.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	95.46	-92.95	138.15	103.09	1.34	0.03	0.00	0.8883
Junho	245.08	-219.48	308.71	233.42	1.32	0.33	0.11	0.0584
Julho	223.63	-73.27	272.46	211.39	1.29	-0.09	0.01	0.6338
Agosto	139.61	50.54	172.77	147.12	1.17	0.15	0.02	0.4140
Setembro	147.75	113.85	176.68	132.84	1.33	0.33	0.11	0.0592
Outubro	131.28	129.11	149.13	64.02	2.33	0.13	0.02	0.4684
Novembro	36.01	35.53	41.57	15.06	2.76	0.33	0.11	0.0613

Tabela 24 – Métricas estatísticas mensais de ERA5 para estação de Catió.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	7.07	-1.62	11.66	12.11	0.96	0.35	0.12	0.0440
Junho	61.64	-38.17	77.81	69.43	1.12	0.27	0.07	0.1309
Julho	75.09	-2.81	96.61	133.63	0.72	0.68	0.46	0.001
Agosto	129.21	-48.10	171.57	168.21	1.02	0.22	0.05	0.2121
Setembro	115.76	-66.81	184.03	188.99	0.97	0.39	0.15	0.0244
Outubro	52.22	-6.82	79.51	79.51	1.00	0.22	0.05	0.2167
Novembro	9.95	8.53	15.10	5.43	2.78	-0.02	0.00	0.9131

Tabela 25 – Métricas estatísticas mensais de ERA5 para estação de Farim.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	17.10	-12.78	23.65	28.15	0.84	0.71	0.51	0.001
Junho	70.31	-54.61	81.33	54.58	1.49	0.27	0.07	0.1251
Julho	74.74	20.57	103.28	94.75	1.09	0.36	0.13	0.0384
Agosto	76.04	-11.75	95.90	101.89	0.94	0.43	0.18	0.0129
Setembro	104.92	-52.77	139.30	116.08	1.20	-0.09	0.01	0.6099
Outubro	55.12	7.57	68.67	64.78	1.06	0.30	0.09	0.0875
Novembro	13.85	13.11	17.83	11.58	1.54	0.69	0.48	0.001

Tabela 26 – Métricas estatísticas mensais de ERA5 para estação de Gabú.


Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	10.70	-5.73	16.85	18.32	0.92	0.47	0.22	0.0053
Junho	49.30	-38.33	64.54	59.76	1.08	0.49	0.24	0.0041
Julho	100.15	-12.52	127.38	139.98	0.91	0.46	0.21	0.0072
Agosto	96.31	-7.99	162.03	157.31	1.03	0.20	0.04	0.2745
Setembro	87.43	-29.81	113.92	118.67	0.96	0.41	0.17	0.0178
Outubro	58.64	-32.02	84.61	85.46	0.99	0.38	0.14	0.0293
Novembro	14.54	6.89	21.71	19.38	1.12	0.30	0.09	0.0906

Tabela 27 – Métricas estatísticas mensais de ERA5 para estação de Mansabá.


Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	20.01	-19.48	34.85	30.29	1.15	0.43	0.19	0.0124
Junho	28.75	3.17	36.67	38.59	0.95	0.55	0.30	0.0009
Julho	133.43	-96.95	160.71	113.99	1.41	0.42	0.18	0.0150
Agosto	193.26	-174.56	236.36	158.63	1.49	0.23	0.05	0.1959
Setembro	105.32	-73.25	129.56	112.66	1.15	0.47	0.22	0.0061
Outubro	50.89	-49.29	71.71	76.28	0.94	0.74	0.55	0.001
Novembro	26.88	-12.27	54.84	54.12	1.01	0.07	0.01	0.6803

Tabela 28 – Métricas estatísticas mensais de ERA5 para estação de Suzana.


Bafatá Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 41 – Distribuição mensal da precipitação de ERA5 na estação de Bafatá para os meses de maio a novembro.


Bafatá Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 42 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bafatá para os meses de maio a novembro.


Bigene Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 43 – Distribuição mensal da precipitação de ERA5 na estação de Bigene para os meses de maio a novembro.


Bigene Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 44 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bigene para os meses de maio a novembro.


Bissau Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 45 – Distribuição mensal da precipitação de ERA5 na estação de Bissau para os meses de maio a novembro.


Bissau Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 46 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bissau para os meses de maio a novembro.


Bolama Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 47 – Distribuição mensal da precipitação de ERA5 na estação de Bolama para os meses de maio a novembro.


Bolama Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 48 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Bolama para os meses de maio a novembro.


Catió Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 49 – Distribuição mensal da precipitação de ERA5 na estação de Catió para os meses de maio a novembro.


Catió Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 50 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Catió para os meses de maio a novembro.

Farim Boxplot






Figura 51 – Distribuição mensal da precipitação de ERA5 na estação de Farim para os meses de maio a novembro.


Farim Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 52 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Farim para os meses de maio a novembro.


Gabú Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 53 – Distribuição mensal da precipitação de ERA5 na estação de Gabú para os meses de maio a novembro.


Gabú Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 54 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Gabú para os meses de maio a novembro.

Mansabá Boxplot






Figura 55 – Distribuição mensal da precipitação de ERA5 na estação de Mansabá para os meses de maio a novembro.


Mansabá Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 56 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Mansabá para os meses de maio a novembro.


Suzana Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 57 – Distribuição mensal da precipitação de ERA5 na estação de Suzana para os meses de maio a novembro.

Suzana Extremo




Figura 58 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5 na estação de Suzana para os meses de maio a novembro.

6.3 TABELA E GRÁFICOS DE REANÁLISE ERA5-LAND

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R^2	p-valor
Maio	17.53	-13.73	31.53	32.08	0.98	0.46	0.21	0.0066
Junho	54.44	-40.89	64.12	49.10	1.31	0.40	0.16	0.0213
Julho	52.92	2.53	81.68	94.05	0.87	0.62	0.38	0.001
Agosto	90.70	-9.91	110.87	97.74	1.13	0.14	0.02	0.4465
Setembro	104.39	-86.00	134.05	81.43	1.65	-0.12	0.01	0.5130
Outubro	59.82	-42.82	77.35	77.44	1.00	0.54	0.29	0.0013
Novembro	10.65	9.88	15.44	10.95	1.41	0.58	0.34	0.0004

Tabela 29 – Métricas estatísticas mensais do ERA5-LAND na estação de Bafatá.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	4.57	-2.45	8.43	11.43	0.74	0.73	0.53	0.001
Junho	30.08	-5.32	46.36	55.14	0.84	0.54	0.29	0.0012
Julho	128.23	90.21	148.90	101.11	1.47	0.23	0.05	0.1957
Agosto	170.64	149.84	196.41	105.25	1.87	0.09	0.01	0.6350
Setembro	116.93	91.83	147.03	96.84	1.51	0.23	0.05	0.2022
Outubro	52.15	12.84	73.08	75.34	0.97	0.33	0.11	0.0617
Novembro	10.40	9.28	15.39	9.21	1.67	0.46	0.21	0.0073

Tabela 30 – Métricas estatísticas mensais do ERA5-LAND na estação de Bigene.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	15.52	-11.53	29.15	28.18	1.03	0.24	0.06	0.1834
Junho	73.81	-54.81	114.31	106.42	1.07	0.33	0.11	0.0674
Julho	81.74	-19.82	98.16	126.24	0.78	0.65	0.42	0.001
Agosto	84.94	-20.41	110.82	121.93	0.91	0.56	0.31	0.0007
Setembro	110.88	-48.03	142.19	127.20	1.12	0.33	0.11	0.0683
Outubro	49.17	-18.95	63.41	77.55	0.82	0.63	0.40	0.001
Novembro	20.84	7.82	28.93	31.33	0.92	0.44	0.19	0.0104

Tabela 31 – Métricas estatísticas mensais do ERA5-LAND na estação de Bissau.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	17.01	-8.22	33.08	36.77	0.90	0.47	0.22	0.0058
Junho	65.49	-29.59	79.57	77.31	1.03	0.44	0.19	0.0109
Julho	146.60	-99.93	177.60	168.13	1.06	0.52	0.27	0.0017
Agosto	130.29	-104.10	162.00	128.17	1.26	0.43	0.18	0.0127
Setembro	110.15	-35.48	132.96	112.09	1.19	0.20	0.04	0.2692
Outubro	68.01	-0.08	85.15	100.31	0.85	0.51	0.26	0.0024
Novembro	28.36	20.92	33.95	27.58	1.23	0.45	0.20	0.0088

Tabela 32 – Métricas estatísticas mensais do ERA5-LAND na estação de Bolama.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	96.43	-94.27	138.83	103.09	1.35	0.03	0.00	0.8492
Junho	249.34	-224.25	312.89	233.42	1.34	0.32	0.10	0.0723
Julho	219.43	-69.18	269.93	211.39	1.28	-0.08	0.01	0.6653
Agosto	138.41	57.26	175.78	147.12	1.19	0.18	0.03	0.3182
Setembro	147.64	102.07	175.76	132.84	1.33	0.28	0.08	0.1139
Outubro	124.85	115.64	141.26	64.02	2.21	-0.01	0.00	0.9555
Novembro	32.80	32.10	38.35	15.06	2.54	0.30	0.09	0.0877

Tabela 33 – Métricas estatísticas mensais do ERA5-LAND na estação de Catió.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	7.12	-1.34	11.65	12.15	0.96	0.36	0.13	0.0391
Junho	61.42	-37.39	77.72	69.72	1.11	0.26	0.07	0.1458
Julho	77.56	-3.04	99.34	133.55	0.74	0.66	0.43	0.001
Agosto	129.66	-52.59	171.28	168.08	1.02	0.24	0.06	0.1758
Setembro	121.19	-75.53	190.67	189.18	1.01	0.34	0.12	0.0504
Outubro	54.23	-9.50	86.22	79.50	1.08	0.05	0.00	0.7634
Novembro	9.90	8.51	15.04	5.44	2.77	-0.01	0.00	0.9574

Tabela 34 – Métricas estatísticas mensais do ERA5-LAND na estação de Farim.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	17.77	-14.10	24.72	28.07	0.88	0.71	0.51	0.001
Junho	77.34	-65.02	88.30	54.70	1.61	0.24	0.06	0.1850
Julho	70.69	2.92	96.95	94.80	1.02	0.37	0.14	0.0325
Agosto	72.56	-26.36	94.33	101.74	0.93	0.47	0.22	0.0057
Setembro	110.01	-72.31	154.53	116.52	1.33	-0.26	0.07	0.1464
Outubro	56.09	-6.26	70.38	64.88	1.08	0.26	0.07	0.1487
Novembro	11.70	10.87	15.68	11.57	1.36	0.68	0.46	0.001

Tabela 35 – Métricas estatísticas mensais do ERA5-LAND na estação de Gabú.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	10.73	-5.79	16.77	18.26	0.92	0.49	0.24	0.0041
Junho	49.28	-40.36	65.21	59.57	1.09	0.50	0.25	0.0030
Julho	100.10	-21.86	126.82	140.70	0.90	0.47	0.22	0.0057
Agosto	96.42	-19.83	163.56	157.77	1.04	0.16	0.03	0.3663
Setembro	91.62	-43.61	119.55	119.23	1.00	0.38	0.15	0.0278
Outubro	61.45	-39.78	88.21	85.12	1.04	0.37	0.14	0.0337
Novembro	13.81	5.73	20.92	19.37	1.08	0.30	0.09	0.0931

Tabela 36 – Métricas estatísticas mensais do ERA5-LAND na estação de Mansabá.

Mês	MAE	BIAS	RMSE	D.P._Obs	NRMSE	r	R²	p-valor
Maio	20.03	-19.27	34.70	30.31	1.14	0.40	0.16	0.0212
Junho	28.61	2.89	36.18	38.73	0.93	0.54	0.30	0.0011
Julho	136.94	-104.01	165.52	113.73	1.46	0.41	0.17	0.0178
Agosto	196.27	-178.85	238.31	158.29	1.51	0.25	0.06	0.1665
Setembro	107.38	-75.87	133.07	112.26	1.19	0.44	0.19	0.0112
Outubro	50.18	-48.19	72.60	76.24	0.95	0.70	0.50	0.001
Novembro	26.97	-11.58	54.54	54.18	1.01	0.10	0.01	0.5983

Tabela 37 – Métricas estatísticas mensais do ERA5-LAND na estação de Suzana.

Bafatá Boxplot






Figura 59 – Distribuição mensal da precipitação de ERA5-LAND na estação de Bafatá para os meses de maio a novembro.


Bafatá Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 60 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Bafatá para os meses de maio a novembro.

Bigene Boxplot






Figura 61 – Distribuição mensal da precipitação de ERA5-LAND na estação de Bigene para os meses de maio a novembro.


Bigene Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 62 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Bigene para os meses de maio a novembro.


Bissau Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 63 – Distribuição mensal da precipitação de ERA5 na estação de Bissau para os meses de maio a novembro.


Bolama Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 64 – Distribuição mensal da precipitação de ERA5-LAND na estação de Bolama para os meses de maio a novembro.


Bolama Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 65 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Bolama para os meses de maio a novembro.


Catió Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 66 – Distribuição mensal da precipitação de ERA5-LAND na estação de Catió para os meses de maio a novembro.


Catió Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 67 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Catió para os meses de maio a novembro.

Farim Boxplot






Figura 68 – Distribuição mensal da precipitação de ERA5-LAND na estação de Farim para os meses de maio a novembro.


Farim Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 69 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Farim para os meses de maio a novembro.


Gabú Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 70 – Distribuição mensal da precipitação de ERA5-LAND na estação de Gabú para os meses de maio a novembro.


Gabú Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 71 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Gabú para os meses de maio a novembro.

Mansabá Boxplot






Figura 72 – Distribuição mensal da precipitação de ERA5-LAND na estação de Mansabá para os meses de maio a novembro.


Mansabá Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 73 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Mansabá para os meses de maio a novembro.


Suzana Boxplot




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro




(f) Outubro




(g) Novembro

Figura 74 – Distribuição mensal da precipitação de ERA5-LAND na estação de Suzana para os meses de maio a novembro.


Suzana Extremo




(a) Maio




(b) Junho




(c) Julho




(d) Agosto



(e) Setembro



(f) Outubro



(g) Novembro

Figura 75 – Série temporal de distribuição mensal dos extremos da precipitação de ERA5-LAND na estação de Suzana para os meses de maio a novembro.