

UNIVERSIDADE FEDERAL DO PARANÁ

PYETRA APARECIDA STROPARO

DESAGREGAÇÃO TEMPORAL DE CHUVAS DIÁRIAS PARA ESCALAS
SUBDIÁRIAS: AVALIAÇÃO DO MÉTODO DOS FRAGMENTOS E DO MODELO
BARTLETT-LEWIS MODIFICADO NO SUL DO BRASIL

CURITIBA

2025

PYETRA APARECIDA STROPARO

DESAGREGAÇÃO TEMPORAL DE CHUVAS DIÁRIAS PARA ESCALAS
SUBDIÁRIAS: AVALIAÇÃO DO MÉTODO DOS FRAGMENTOS E DO MODELO
BARTLETT-LEWIS MODIFICADO NO SUL DO BRASIL

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental, Setor de Tecnologia da Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia de Recursos Hídricos e Ambiental.

Orientador: Prof. Dr. Daniel Henrique Marco Detzel

Coorientador: Prof. Dr. Júlio Gomes

CURITIBA

2025

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Stroparo, Pyetra Aparecida

Desagregação temporal de chuvas diárias para escalas subdiárias:
avaliação do método dos fragmentos e do modelo Bartlett-Lewis modificado
no sul do Brasil / Pyetra Aparecida Stroparo. – Curitiba, 2025.

1 recurso on-line : PDF.

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de
Tecnologia, Programa de Pós-Graduação em Engenharia de Recursos
Hídricos e Ambiental.

Orientador: Daniel Henrique Marco Detzel

Coorientador: Júlio Gomes

1. Precipitação (Meteorologia). 2. Precipitação (Meteorologia) – Método
comparativo. 3. Chuvas. 4. Estações meteorológicas. I. Universidade Federal
do Paraná. II. Programa de Pós-Graduação em Engenharia de Recursos
Hídricos e Ambiental. III. Detzel, Daniel Henrique Marco. IV. Gomes, Júlio. V.
Título.

Bibliotecário: Douglas Lenon da Silva CRB-9/1892

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA DE RECURSOS HÍDRICOS E AMBIENTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **PYETRA APARECIDA STROPARO**, intitulada: **Desagregação temporal de chuvas diárias para escalas subsidiárias: avaliação do Método dos Fragmentos e do Modelo BartlettLewis Modificado no Sul do Brasil**, sob orientação do Prof. Dr. DANIEL HENRIQUE MARCO DETZEL, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestra está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 01 de Outubro de 2025.

Assinatura Eletrônica

08/10/2025 07:42:32.0

DANIEL HENRIQUE MARCO DETZEL
Presidente da Banca Examinadora

Assinatura Eletrônica

13/10/2025 09:48:36.0

TAMARA LEITZKE CALDEIRA BESKOW
Avaliador Externo (UNIVERSIDADE FEDERAL DE PELOTAS)

Assinatura Eletrônica

09/10/2025 14:02:21.0

REGINA TIEMY KISHI
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

08/10/2025 09:21:40.0

CLAUDIO MARCHAND KRÜGER
Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

AGRADECIMENTOS

Agradeço a Deus pelo dom da vida e por cada etapa dessa caminhada. Aos meus pais, Kacyane e Gerson, meu amor e eterna gratidão. Obrigada por sempre acreditarem em mim e por nunca medirem esforços para que eu pudesse sonhar alto. Vocês são exemplos de profissionais e seres humanos, e foi me espelhando em vocês que construí minhas bases.

À minha família, especialmente minhas tias e avós, que estiveram sempre em oração. Aos meus amados Hector e Lorenzo, espero que, um dia, eu possa ser inspiração para os caminhos que escolherem trilhar. À minha fiel escudeira Eleanor, que não escreveu uma linha, mas esteve presente em todas elas.

Ao meu noivo, Gustavo, agradeço por todo amor e apoio, mesmo nos momentos em que precisei estar distante para seguir este sonho.

De forma especial, agradeço ao professor Acinir Sikora, meu primeiro professor de física, que, ainda no ensino fundamental, despertou em mim o interesse pelas exatas. Aos professores Geraldo Krebsbach e Rafael Tozzi, da graduação, que, com excelência, ensinaram Mecânica dos Fluidos e Recursos Hídricos – disciplinas que acenderam em mim a paixão pela hidrologia e hidráulica.

Ao professor Daniel Detzel, meu orientador, pela orientação firme e generosa, pela confiança e por me guiar com sabedoria neste processo de amadurecimento acadêmico. Ao professor Júlio Gomes, meu coorientador, pelo apoio técnico e contribuições ao trabalho.

À equipe da Intertechne, em especial ao José Rodolfo e Renato Grube pelos aprendizados e pela oportunidade de atuar na área que tanto amo – e à Edilaine Santos, por sua dedicação e apoio no meu início na hidrologia.

Às queridas Isabela Poyer e Denise Latreille, amigas que o trabalho me deu, e à Lívia Taborda e à Renata Álvaro, parceiras de mestrado – obrigada por tornarem mais leve essa jornada com conselhos, aprendizados e boas risadas.

A todos que, de alguma forma, contribuíram para a realização deste trabalho, o meu mais sincero agradecimento.

RESUMO

A desagregação temporal da precipitação surge como uma ferramenta essencial à superação das limitações impostas pela escassez de dados pluviométricos de alta resolução temporal, realidade verificada em países como o Brasil, cuja rede de monitoramento, apesar de crescente, ainda apresenta falhas e heterogeneidades. Este trabalho avaliou a aplicabilidade de dois modelos amplamente utilizados na literatura: o Método dos Fragmentos (MOF) e o Modelo Bartlett–Lewis Modificado (MBL), com foco na região Sul do Brasil. Para tanto, foram selecionadas três estações automáticas do Instituto Nacional de Meteorologia, cujas séries abrangeram oito anos de dados consistidos, sendo sete utilizados como base histórica para a desagregação e um reservado para validação. O MOF foi testado em seis combinações de parâmetros de janela histórica (l de 15 e 30 dias) e número de vizinhos (k de 5, 10 e 15), enquanto o MBL foi avaliado em duas configurações de calibração (anual e mensal). A validação considerou estatísticas de verificação padrão, incluindo variância horária, proporção de horas secas, autocorrelação lag-1, além do horário de pico diário e das chuvas máximas horárias diárias. Os resultados indicaram que o MOF, apresentou desempenho superior na reprodução das estatísticas analisadas. O MBL, por sua vez, mostrou-se sensível ao critério de calibração, sendo que a calibração mensal reduziu erros sistemáticos em comparação à anual, mas ainda apresentou limitações na representação de extremos. Ressalta-se, contudo, que a curta extensão das séries históricas impõe restrições à robustez dos modelos. Ainda assim, os resultados evidenciam tendências claras quanto ao comportamento de cada modelo, apontando o MOF como alternativa mais promissora para aplicações práticas na região Sul do Brasil.

Palavras-chave: Precipitação horária; Modelos estocásticos; Modelo de Bartlett-Lewis Modificado; Método dos Fragmentos.

ABSTRACT

Rainfall disaggregation is an important approach to address the limited availability of high-resolution rainfall data, a situation often found in countries such as Brazil, where the monitoring network, although expanding, still presents gaps and inconsistencies. This study evaluated the application of two models commonly used in the literature: the Method of Fragments (MOF) and the Modified Bartlett-Lewis Model (MBL), focusing on Southern Brazil. Three automatic stations from the National Institute of Meteorology were selected, with eight years of consistent hourly records; seven years were used as the historical basis for disaggregation and one year was reserved for validation. The MOF was applied under six parameter settings, combining historical windows lengths l (15 and 30 days) and numbers of neighbors k (5, 10, and 15). The MBL was tested under two calibration approaches, annual and monthly. Validation included hourly variance, proportion of dry hours, lag-1 autocorrelation, as well as the time of daily rainfall peak and maximum hourly rainfall. Results showed that the MOF performed better in reproducing the analyzed statistics, especially in preserving intraday variability. The MBL proved dependent on the calibration method, with the monthly approach reducing systematic errors compared to the annual one but still showing limitations in representing extremes. However, it should be noted that the relatively short time series impose restrictions on the validity of the models. Even so, the results reveal consistent trends in model performance, with the MOF identified as the most promising option for practical applications in Southern Brazil.

Key-words: Hourly precipitation; Stochastic models; Modified Bartlett-Lewis Model; Method of Fragments.

LISTA DE FIGURAS

FIGURA 1 – TIPOS DE PRECIPITAÇÃO.....	21
FIGURA 2 – DISTRIBUIÇÃO ESPACIAL DAS ESTAÇÕES PLUVIOMÉTRICAS DA REDE OPERADA PELO INSTITUTO NACIONAL DE METEOROLOGIA (INMET) E PARCEIROS.....	22
FIGURA 3 – DIFERENTES RESOLUÇÕES TEMPORAIS DA PRECIPITAÇÃO.....	24
FIGURA 4 – ESQUEMA MOSTRANDO O PROCESSO DE NEYMAN-SCOTT.....	31
FIGURA 5 – DISTRIBUIÇÃO TEMPORAL DAS TEMPESTADES DO PRIMEIRO QUARTIL DO MÉTODO DE HUFF.....	32
FIGURA 6 – EXEMPLO DE CASCATA ALEATÓRIA MULTIPLICATIVA COM NÚMERO DE RAMIFICAÇÃO $b=2$ E GERADOR DE CASCATA W PARA ESCALAS $n = 0, 1$ E 2	33
FIGURA 7 – SEMELHANÇA GEOMÉTRICA ENTRE OS PADRÕES PLUVIOMÉTRICOS EXTERNOS E INTERNOS PARA AS SEIS CLASSES DE PADRÃO, SEGUNDO ORMSBEE (1989).....	35
FIGURA 8 – PRINCIPAIS DIFERENÇAS ENTRE OS MÉTODOS BARTLETT-LEWIS E FRAGMENTOS.....	36
FIGURA 9 – REGIÕES HIDROGRÁFICAS NA REGIÃO SUL DO BRASIL.....	38
FIGURA 10 – TOTAL DE PRECIPITAÇÃO PLUVIOMÉTRICA ANUAL NA REGIÃO SUL DO BRASIL.....	39
FIGURA 11 – ESTAÇÕES AUTOMÁTICAS DO INMET COM DADOS DISPONÍVEIS NA REGIÃO SUL.....	40
FIGURA 12 – FREQUÊNCIA DAS ESTAÇÕES CONFORME EXTENSÃO TOTAL DAS SÉRIES – PR, RS, SC.....	44
FIGURA 13 – FREQUÊNCIA DAS ESTAÇÕES CONFORME PORCENTAGEM DE FALHAS NAS SÉRIES – PR, RS, SC.....	45
FIGURA 14 – DISTRIBUIÇÃO DO NÚMERO DE ANOS SEM FALHAS NAS SÉRIES POR ESTADO.....	46
FIGURA 15 – LOCALIZAÇÃO DAS ESTAÇÕES SELECIONADAS.....	47
FIGURA 16 – CURVA DE PERMANÊNCIA – ESTAÇÃO A871 – JAPIRA/PR.....	50
FIGURA 17 – CURVA DE PERMANÊNCIA – ESTAÇÃO A880 – VACARIA/RS.....	51
FIGURA 18 – CURVA DE PERMANÊNCIA – ESTAÇÃO A868 – ITAJAÍ/SC.....	51

FIGURA 19 – ESQUEMA DO MODELO BARTLETT-LEWIS DO PULSO RETANGULAR	53
FIGURA 20 – ESQUEMA DO MÉTODO DOS FRAGMENTOS	58
FIGURA 21 – MBL – VARIÂNCIA MENSAL – ESTAÇÃO A871 (JAPIRA/PR)	70
FIGURA 22 – MBL – VARIÂNCIA ANUAL – ESTAÇÃO A871 (JAPIRA/PR).....	71
FIGURA 23 – MBL – VARIÂNCIA MENSAL – ESTAÇÃO A880 (VACARIA/RS).....	72
FIGURA 24 – MBL – VARIÂNCIA ANUAL – ESTAÇÃO A880 (VACARIA/RS).....	72
FIGURA 25 – MBL – VARIÂNCIA MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC).....	73
FIGURA 26 – MBL – VARIÂNCIA ANUAL – ESTAÇÃO A68 (ITAJAÍ/SC).....	74
FIGURA 27 – MBL – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A871 (JAPIRA/PR).....	77
FIGURA 28 – MBL – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A871 (JAPIRA/PR).....	77
FIGURA 29 – MBL – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A880 (VACARIA/RS).....	78
FIGURA 30 – MBL – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A880 (VACARIA/RS).....	78
FIGURA 31 – MBL – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC).....	79
FIGURA 32 – MBL – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC).....	80
FIGURA 33 – MBL – AUTOCORRELAÇÃO MENSAL – ESTAÇÃO A871 (JAPIRA/PR).....	83
FIGURA 34 – MBL – AUTOCORRELAÇÃO ANUAL – ESTAÇÃO A871 (JAPIRA/PR)	84
FIGURA 35 – MBL – AUTOCORRELAÇÃO MENSAL – ESTAÇÃO A880 (VACARIA/RS).....	85
FIGURA 36 – MBL – AUTOCORRELAÇÃO ANUAL – ESTAÇÃO A880 (VACARIA/RS).....	85
FIGURA 37 – MBL – AUTOCORRELAÇÃO MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)	86
FIGURA 38 – MBL – AUTOCORRELAÇÃO ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC)	86
FIGURA 39 – MBL – HORÁRIO DE PICO – ESTAÇÃO A871 (JAPIRA/PR).....	90

FIGURA 40 – MBL – HORÁRIO DE PICO – ESTAÇÃO A880 (VACARIA/RS).....	91
FIGURA 41 – MBL – HORÁRIO DE PICO – ESTAÇÃO A868 (ITAJAÍ/SC)	92
FIGURA 42 – MBL – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A871 (JAPIRA/PR)	94
FIGURA 43 – MBL – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A880 (VACARIA/RS).....	95
FIGURA 44 – MBL – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A868 (ITAJAÍ/SC).....	96
FIGURA 45 – MOF – VARIÂNCIA MENSAL – ESTAÇÃO A871 (JAPIRA/PR)	103
FIGURA 46 – MOF – VARIÂNCIA ANUAL – ESTAÇÃO A871 (JAPIRA/PR)	104
FIGURA 47 – MOF – VARIÂNCIA MENSAL – ESTAÇÃO A880 (VACARIA/RS) ...	105
FIGURA 48 – MOF – VARIÂNCIA ANUAL – ESTAÇÃO A880 (VACARIA/RS)	105
FIGURA 49 – MOF – VARIÂNCIA MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)	106
FIGURA 50 – MOF – VARIÂNCIA ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC)	107
FIGURA 51 – MOF – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A871 (JAPIRA/PR).....	111
FIGURA 52 – MOF – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A871 (JAPIRA/PR)	112
FIGURA 53 – MOF – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A880 (VACARIA/RS).....	113
FIGURA 54 – MOF – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A880 (VACARIA/RS).....	113
FIGURA 55 – MOF – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC).....	114
FIGURA 56 – MOF – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC).....	115
FIGURA 57 – MOF – AUTOCORRELAÇÃO LAG-1 MENSAL – ESTAÇÃO A871 (JAPIRA/PR)	119
FIGURA 58 – MOF – AUTOCORRELAÇÃO LAG-1 ANUAL – ESTAÇÃO A871 (JAPIRA/PR)	120
FIGURA 59 – MOF – AUTOCORRELAÇÃO LAG-1 MENSAL – ESTAÇÃO A880 (VACARIA/RS).....	121
FIGURA 60 – MOF – AUTOCORRELAÇÃO LAG-1 ANUAL – ESTAÇÃO A880 (VACARIA/RS).....	121

FIGURA 61 – MOF – AUTOCORRELAÇÃO LAG-1 MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC).....	122
FIGURA 62 – MOF – AUTOCORRELAÇÃO LAG-1 ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC).....	123
FIGURA 63 – MOF – HORÁRIO DE PICO – ESTAÇÃO A871 (JAPIRA/PR).....	126
FIGURA 64 – MOF – HORÁRIO DE PICO – ESTAÇÃO A880 (VACARIA/RS).....	127
FIGURA 65 – MOF – HORÁRIO DE PICO – ESTAÇÃO A868 (ITAJAÍ/SC).....	128
FIGURA 66 – MOF – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A871 (JAPIRA/PR).....	131
FIGURA 67 – MOF – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A880 (VACARIA/RS).....	133
FIGURA 68 – MOF – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A868 (ITAJAÍ/SC).....	134
FIGURA 69 – RESUMO DAS PRINCIPAIS DIFERENÇAS ENTRE O MBL E MOF	138

LISTA DE TABELAS

TABELA 1 – ESTAÇÕES AUTOMÁTICAS DO INMET EM OPERAÇÃO NO PARANÁ ATÉ 2024	41
TABELA 2 – ESTAÇÕES AUTOMÁTICAS DO INMET EM OPERAÇÃO NO RIO GRANDE DO SUL ATÉ 2024.....	42
TABELA 3 – ESTAÇÕES AUTOMÁTICAS DO INMET EM OPERAÇÃO EM SANTA CATARINA ATÉ 2024	43
TABELA 4 – NÚMERO DE HORAS COM DADOS AUSENTES	48
TABELA 5 – DADOS HISTÓRICOS DAS ESTAÇÕES	50
TABELA 6 – ANOS SELECIONADOS PARA COMPOR A BASE HISTÓRICA E ANO DE VALIDAÇÃO EM CADA ESTAÇÃO.....	52
TABELA 7 – PARÂMETROS DE CALIBRAÇÃO DO MODELO BARTLETT-LEWIS MODIFICADO – ESTAÇÕES A871, A880 E A868.....	67
TABELA 8 – MODELO BARTLETT-LEWIS – VARIÂNCIA (mm ²) – ESTAÇÕES A871, A880 E A868.....	69
TABELA 9 – MODELO BARTLETT-LEWIS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA VARIÂNCIA – ESTAÇÕES A871, A880 E A868.....	69
TABELA 10 – MODELO BARTLETT-LEWIS – PROPORÇÃO DE HORAS SECAS – ESTAÇÕES A871, A880 E A868	76
TABELA 11 – MODELO BARTLETT-LEWIS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA PROPORÇÃO DE HORAS SECAS – ESTAÇÕES A871, A880 E A868.....	76
TABELA 12 – MODELO BARTLETT-LEWIS – AUTOCORRELAÇÃO – ESTAÇÕES A871, A880 E A868.....	82
TABELA 13 – MODELO BARTLETT-LEWIS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA AUTOCORRELAÇÃO – ESTAÇÕES A871, A880 E A868	82
TABELA 14 – MODELO BARTLETT-LEWIS – PADRÃO HORÁRIO DE OCORRÊNCIA DO PICO DIÁRIO – ESTAÇÕES A871, A880 E A868	89
TABELA 15 – MODELO BARTLETT-LEWIS – ESTATÍSTICAS DA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÕES A871, A880 E A868.....	93

TABELA 16 – MÉTODO DOS FRAGMENTOS – VARIÂNCIA – ESTAÇÕES A871, A880 E A868.....	101
TABELA 17 – MÉTODO DOS FRAGMENTOS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA VARIÂNCIA – ESTAÇÕES A871, A880 E A868.....	102
TABELA 18 – MÉTODO DOS FRAGMENTOS – PROPORÇÃO DE HORAS SECAS – ESTAÇÕES A871, A880 E A868	109
TABELA 19 – MÉTODO DOS FRAGMENTOS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA PROPORÇÃO DE HORAS SECAS – ESTAÇÕES A871, A880 E A868.....	110
TABELA 20 – MÉTODO DOS FRAGMENTOS – AUTOCORRELAÇÃO LAG-1 – ESTAÇÕES A871, A880 E A868	117
TABELA 21 – MÉTODO DOS FRAGMENTOS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA AUTOCORRELAÇÃO LAG-1 – ESTAÇÕES A871, A880 E A868	118
TABELA 22 – MÉTODO DOS FRAGMENTOS – PADRÃO HORÁRIO DE OCORRÊNCIA DO PICO DIÁRIO – ESTAÇÕES A871, A880 E A868	125
TABELA 23 – MÉTODO DOS FRAGMENTOS – ESTATÍSTICAS DA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÕES A871, A880 E A868.....	130

LISTA DE ABREVIATURAS OU SIGLAS

BLPRM	- Modelo Bartlett-Lewis do Pulso Retangular Modificado
CST	- Modelo de Desagregação Constante
EMBRAPA	- Empresa Brasileira de Pesquisa Agropecuária
IBGE	- Instituto Brasileiro de Geografia e Estatística
INMET	- Instituto Nacional de Meteorologia
IDF	- Intensidade-Duração-Frequência
IPCC	- Painel Intergovernamental sobre Mudanças Climáticas
KNN	- K-Nearest Neighbors
MBL	- Modelo Bartlett-Lewis Modificado
MOF	- Método dos Fragmentos
OD	- Modelo Linear de Ormsbee
SWAT	- Soil and Water Assessment Tool

SUMÁRIO

1 INTRODUÇÃO	16
1.1 HIPÓTESE.....	17
1.2 OBJETIVOS GERAL E ESPECÍFICOS.....	18
2 REVISÃO DE LITERATURA	19
2.1 PRECIPITAÇÃO	19
2.1.1 Classificação dos Tipos de Precipitação	19
2.1.2 Medição da Precipitação	21
2.2 DIFERENTES RESOLUÇÕES TEMPORAIS DE PRECIPITAÇÃO.....	22
2.2.1 Precipitação Anual	25
2.2.2 Precipitação Mensal	25
2.2.3 Precipitação Diária	26
2.2.4 Precipitação Horária.....	28
2.3 DESAGREGAÇÃO DA PRECIPITAÇÃO	29
2.4 MODELOS DE DESAGREGAÇÃO DA PRECIPITAÇÃO	30
3 MATERIAL E MÉTODOS	38
3.1 ÁREA DE ESTUDO	38
3.2 FONTE DE DADOS	40
3.2.1 Estações Adotadas	46
3.2.1.1 Critério de elegibilidade das estações	46
3.2.1.2 Tratamento de falhas.....	48
3.2.1.3 Determinação do ano-base para avaliação	49
3.2.1.4 Definição da base histórica e do ano de validação	51
3.3 MODELO BARTLETT-LEWIS MODIFICADO.....	52
3.3.1 Calibrações avaliadas	55
3.4 MÉTODO DOS FRAGMENTOS.....	57
3.4.1 Configurações de l e k	60
3.5 VALIDAÇÃO DOS MODELOS	61
3.5.1 Ano de Referência para Validação	62
3.5.2 Estatísticas de Validação Padrão	62
3.5.3 Horário de Pico Diário	63
3.5.4 Chuva Horária Máxima Diária	64
4 RESULTADOS	66

4.1 MODELO BARTLETT-LEWIS MODIFICADO.....	66
4.1.1 Calibração.....	66
4.1.2 Estatísticas de Validação Padrão.....	67
4.1.2.1 Variância.....	67
4.1.2.2 Proporção de Horas Secas.....	75
4.1.2.3 Autocorrelação.....	81
4.1.2.4 Conclusão geral da análise das três métricas.....	88
4.1.3 Horário de Pico Diário.....	89
4.1.4 Chuva Horária Máxima Diária.....	93
4.1.5 Conclusões Gerais Modelo Bartlett-Lewis Modificado.....	98
4.2 MÉTODO DOS FRAGMENTOS.....	99
4.2.1 Estatísticas de Validação Padrão.....	99
4.2.1.1 Variância.....	99
4.2.1.2 Proporção de Horas Secas.....	108
4.2.1.3 Autocorrelação Lag-1.....	115
4.2.1.4 Conclusão geral da análise das três métricas.....	124
4.2.2 Horário de Pico Diário.....	124
4.2.3 Chuva Horária Máxima Diária.....	129
4.2.4 Conclusões Gerais Método dos Fragmentos.....	135
4.3 COMPARAÇÕES ENTRE MODELOS.....	136
4.4 LIMITAÇÕES E IMPLICAÇÕES.....	139
5 DISCUSSÃO.....	141
6 CONCLUSÕES.....	143
REFERÊNCIAS.....	146

1 INTRODUÇÃO

A determinação de volumes precipitados, abrangendo diferentes escalas temporais, é um elemento primordial que afeta diretamente a eficácia de pesquisas e trabalhos técnicos em inúmeras áreas. Ainda assim, a coleta de dados pluviométricos precisos e de alta resolução temporal se mostra um obstáculo constante para pesquisadores e responsáveis pela tomada de decisões.

A importância dessa estimativa se estende desde escalas locais, abrangendo estudos voltados ao manejo agrícola e à delimitação de planícies de inundação, até escalas regionais, consistindo na determinação de estratégias relacionadas ao planejamento do meio ambiente, no projeto de obras de infraestrutura e na formulação de políticas voltadas à gestão de recursos hídricos.

A confiabilidade e a precisão dos dados pluviométricos são ainda mais relevantes ao se tratar de estudos voltados ao dimensionamento de obras hidráulicas, dado que a ausência, ou até mesmo a inadequação dos dados, é passível de resultar em projetos subdimensionados ou superestimados. Cenário esse, que compromete não apenas a eficiência operacional e viabilidade econômica da estrutura em si, mas pode acarretar falhas que colocam em risco o meio ambiente e vidas humanas.

Muitas das aplicações que demandam informações pluviométricas dependem de dados de precipitação com alta resolução temporal, devido à necessidade de compreender os padrões de precipitação para determinados períodos de tempo. Contudo, no Brasil, a disponibilidade de dados subsidiários de precipitação ainda é limitada. Isso se deve, em grande parte, à escassez de equipamentos propícios para a aquisição de registros contínuos e, quando existentes, os dados majoritariamente se resumem em séries curtas e/ou com excessivas falhas de registro (Depiné, 2014).

Tucci (1997) enfatiza a dificuldade de obtenção de dados de precipitação de longo prazo e consistentes, especialmente para dados de registros de pluviógrafos, essenciais para o estudo de eventos de curta duração. Em países continentais como o Brasil, a rede de monitoramento existente não é suficiente para cobrir todas as regiões de maneira homogênea (Pereira, 2013; Melati, 2016), sendo o problema agravado ao se tratar de dados de precipitação horária. Estudos recentes reforçam que a limitação de dados pluviométricos com alta resolução temporal ainda constitui um dos principais desafios para a hidrologia moderna. Mesmo com a expansão de redes automáticas, como as do INMET e do CEMADEN, a disponibilidade de séries

consistidas e contínuas ainda é restrita (Freitas *et al.*, 2020; Meira *et al.*, 2022). Nesse sentido, esses fatores tornam-se um grande obstáculo ao desenvolvimento de pesquisas relacionadas a eventos chuvosos em escalas subdiárias em nível nacional.

É nesse cenário que surge a necessidade da utilização de modelos robustos que possam desagregar a precipitação diária em intervalos menores, permitindo uma melhor compreensão dos padrões temporais da chuva e aprimorando as análises de eventos extremos, modelagem hidrológica, dimensionamento de obras e planejamento urbano.

No entanto, observa-se uma lacuna metodológica relevante em relação à escassez de estudos que comparam de forma sistemática diferentes modelos de desagregação temporal aplicados à realidade brasileira. A maior parte das pesquisas concentra-se na aplicação isolada de um único modelo, o que dificulta a identificação de qual abordagem apresenta melhor desempenho frente às condições pluviométricas nacionais. Essa ausência de comparações abrangentes reduz o potencial de avanço científico e tecnológico na representação de eventos de chuva em escalas finas, impactando diretamente a modelagem hidrológica e o planejamento de sistemas de drenagem.

Neste contexto, o presente trabalho avalia a aplicabilidade de dois modelos de desagregação temporal de precipitação diária em escalas subdiárias – o Modelo Bartlett-Lewis Modificado (MBL) e o Método dos Fragmentos (MOF) – em três estações automáticas localizadas na região Sul do Brasil. A avaliação contempla a aplicação dos modelos com base em séries históricas de sete anos, bem como a validação frente a um ano de referência (2019), adotado como série observada. Com isso, analisa-se em que medida os modelos são capazes de reproduzir as principais propriedades estatísticas da precipitação horária, contribuindo para o avanço do conhecimento sobre ferramentas aplicáveis em regiões com limitações de dados de alta resolução.

1.1 HIPÓTESE

A desagregação de precipitação diária em escalas subdiárias pode ser representada de forma consistente tanto pelo Método dos Fragmentos quanto pelo Modelo Bartlett-Lewis Modificado, preservando as principais características estatísticas observadas em estações localizadas no Sul do Brasil.

1.2 OBJETIVOS GERAL E ESPECÍFICOS

O objetivo principal desta dissertação é avaliar a capacidade do Modelo Bartlett-Lewis Modificado (MBL) e do Método dos Fragmentos (MOF) em desagregar chuvas diárias em séries horárias, utilizando dados de três estações automáticas do Instituto Nacional de Meteorologia (INMET) na região Sul do Brasil.

Para tanto, podem ser citados ainda como objetivos específicos: (1) mapear a existência de postos pluviométricos e avaliar a disponibilidade e a qualidade das séries de precipitação em escala subdiária na região Sul do Brasil; (2) analisar, para o Modelo Bartlett-Lewis Modificado, os efeitos da calibração mensal e anual sobre o desempenho do modelo na representação das estatísticas pluviométricas e; (3) investigar, no âmbito do Método dos Fragmentos, a sensibilidade do modelo frente a diferentes combinações dos parâmetros de janela histórica l e número de fragmentos k .

2 REVISÃO DE LITERATURA

Neste capítulo, apresenta-se uma revisão da literatura sobre os principais conceitos existentes relacionadas à precipitação, suas escalas temporais e os métodos de desagregação temporal.

Inicialmente, discute-se a precipitação e seus diferentes tipos, abordando os mecanismos atmosféricos que originam sua formação, bem como os métodos convencionais de medição. Em seguida, são exploradas as diferentes escalas temporais da precipitação, com ênfase nos impactos da resolução dos dados na modelagem hidrológica. Por fim, é discutida a necessidade da desagregação de precipitação como alternativa à escassez de registros horários e sub-horários, explorando metodologias utilizadas na literatura.

2.1 PRECIPITAÇÃO

Em hidrologia, a precipitação refere-se como toda forma de água proveniente da atmosfera que atinge a superfície terrestre. Esse fenômeno pode manifestar-se de diversas formas, incluindo chuva, neblina, granizo, saraiva, orvalho, geada e neve (Tucci, 1997). Entretanto, a precipitação em forma de chuva é mais observada, especialmente em regiões tropicais e subtropicais (Mello; Silva; Beskow, 2022), como é o caso do Brasil. Assim sendo, os itens que se seguem focam nesse tipo de precipitação.

2.1.1 Classificação dos Tipos de Precipitação

A maior parte das precipitações ocorre devido ao resfriamento adiabático do ar, que provoca a condensação do vapor d'água em gotículas. Esse processo está associado ao movimento vertical das massas de ar, geralmente impulsionado por correntes ascendentes. Dependendo do mecanismo que gera esse movimento e das características físicas envolvidas, as precipitações podem ser classificadas em três tipos principais: ciclônicas, orográficas e convectivas (Mello; Silva; Beskow, 2022).

As chuvas ciclônicas resultam do deslocamento de massas de ar de regiões com alta pressão para regiões com baixa pressão atmosférica. Tais precipitações podem ainda ser classificadas como frontais ou não frontais (Villella; Mattos, 1975),

conforme os mecanismos atmosféricos que as originam. A chuva não frontal resulta da convergência horizontal de massas de ar quentes e úmidas, as quais ascendem, promovendo o subsequente resfriamento e a condensação. No entanto, Mello *et al.* (2022) afirmam que esse tipo de sistema atmosférico é raro no Brasil. Por outro lado, as chuvas frontais consistem no encontro entre duas massas de ar de diferentes temperaturas, geralmente uma massa de ar frio e outra de ar quente. A massa de ar mais quente é forçada a subir sobre a massa de ar frio, resultando na condensação do vapor d'água e na formação de nuvens de chuva. Chuvas frontais são caracterizadas por serem de grande duração e com intensidade moderada, atingindo grandes áreas (Chow; Maidment; Mays, 1988; Tucci, 1997; Mello; Silva; Beskow, 2022).

Ao se tratar de chuvas convectivas, Villela e Mattos (1975) relatam que tais são decorrentes do aquecimento da superfície terrestre, que aquece o ar adjacente, podendo gerar camadas de ar com equilíbrio instável. Ao se perturbar esse equilíbrio, ocorre uma rápida ascensão local do ar mais denso, que atinge o ponto de condensação, levando à formação de nuvens e, frequentemente, à ocorrência de precipitações. Os autores ainda afirmam que chuvas convectivas podem ser caracterizadas por apresentarem uma alta intensidade, curta duração e estarem concentradas em pequenas áreas, portanto, podendo provocar inundações de grandes dimensões em pequenas bacias.

As chuvas orográficas, em contrapartida, ocorrem quando massas de ar úmido encontram uma barreira natural, como uma cadeia de montanhas, sendo forçadas a subir (Maidment, 1993). Ao ascender, o ar se resfria e se condensa, resultando em precipitação. Conforme posto por Tucci (1997), essas chuvas costumam ser de baixa intensidade e longa duração, e atingindo pequenas áreas.

A FIGURA 1 ilustra, de forma esquemática, os três tipos de precipitação descritos: frontal, convectiva e orográfica.

FIGURA 1 – TIPOS DE PRECIPITAÇÃO



FONTE: Collischonn e Dornelles (2015).

2.1.2 Medição da Precipitação

Dado que no Brasil a precipitação ocorre quase exclusivamente na forma de chuva, representando mais de 99% do total, com eventuais ocorrências de granizo, para medir a precipitação, utiliza-se, de maneira convencional, instrumentos como pluviômetros e pluviógrafos (Santos *et al.*, 2001). Embora, ambos os instrumentos apresentem a mesma finalidade, acabam se diferindo no tipo de registro e no modo em que apresentam os dados.

Os pluviômetros são instrumentos mais comuns e simples, os quais possuem como finalidade coletar e armazenar a precipitação acumulada durante um período de tempo para posterior medição volumétrica. A operação desses instrumentos, no entanto, depende da atuação de um(a) observador(a) ou leitorista, responsável por realizar leituras diárias – preferencialmente às 7h e 17h – utilizando uma proveta graduada (Santos *et al.*, 2001).

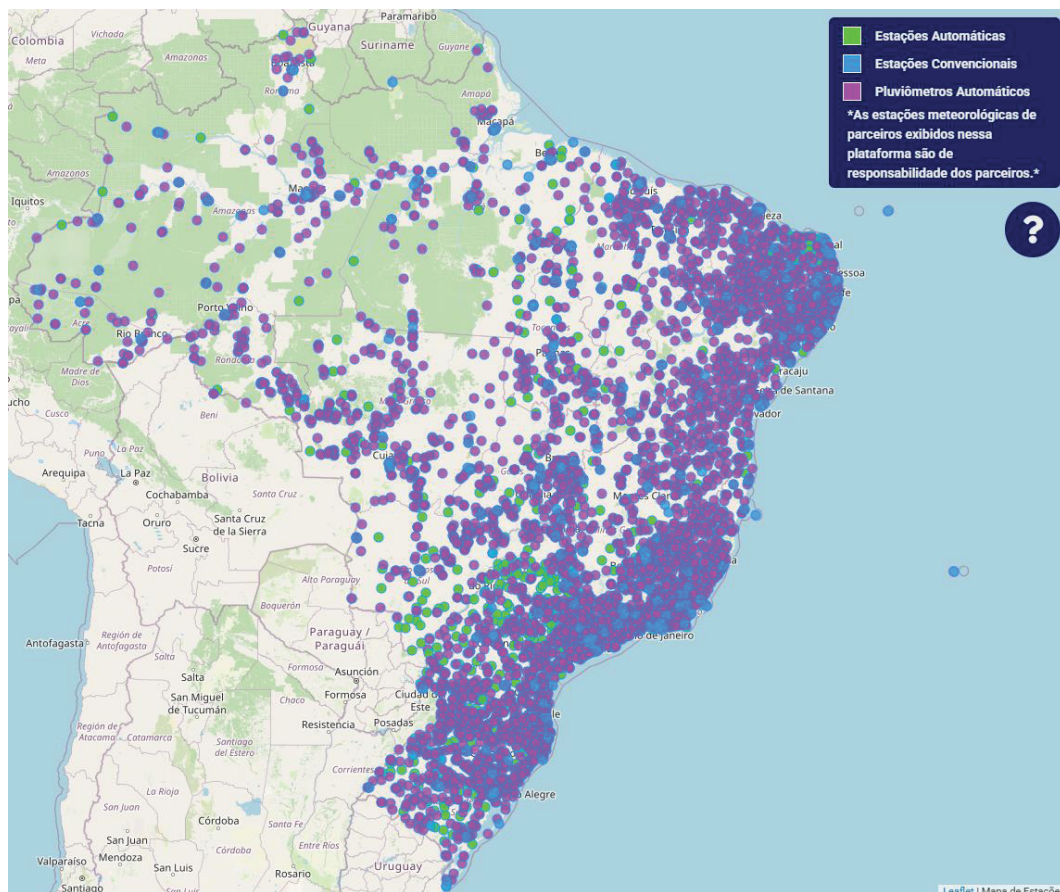
Por outro lado, os pluviógrafos, por serem instrumentos automáticos, registram continuamente a quantidade de chuva recolhida. Sendo assim, dados de pluviógrafos permitem um conhecimento mais preciso da distribuição da precipitação, dessa forma, são essenciais para estudos de pequenas bacias e bacias urbanas (Ramos *et al.*, 1989).

Ainda, Ramos *et al.* (1989) reiteram que para se obter dados com qualidade satisfatória, é necessário se dispor de instrumentos confiáveis que sejam capazes de medir ou registrar os dados pluviométricos com precisão substancial para as condições em que são operados.

Nos últimos anos, observa-se uma tendência crescente de substituição dos pluviômetros convencionais por equipamentos automáticos no Brasil. Essa

modernização reflete a demanda por dados pluviométricos com maior resolução temporal, maior agilidade na disponibilização das informações e menor dependência humana no processo de coleta. Portanto, os pluviógrafos e os sensores automáticos de chuva passam a ser cada vez mais amplamente aceitos como o novo padrão de monitoramento hidrometeorológico no país. A expansão da rede de estações automáticas do Instituto Nacional de Meteorologia (INMET) e de parceiros ilustra esse avanço, como pode ser observado na distribuição espacial das estações pluviométricas automáticas atualmente em operação (FIGURA 2).

FIGURA 2 – DISTRIBUIÇÃO ESPACIAL DAS ESTAÇÕES PLUVIOMÉTRICAS DA REDE OPERADA PELO INSTITUTO NACIONAL DE METEOROLOGIA (INMET) E PARCEIROS



FONTE: INMET – Mapas Interativos (2025).

2.2 DIFERENTES RESOLUÇÕES TEMPORAIS DE PRECIPITAÇÃO

A precipitação, assim como ocorre com outros eventos climáticos naturais, varia ao longo dos anos e das estações do ano. Estudar essas mudanças é crucial para várias áreas de aplicação, podendo ser feito em diferentes escalas temporais,

conforme a demanda da situação real. A escolha da escala temporal mais apropriada – seja anual, mensal, diária ou horária – depende da exigência de compreensão do comportamento e das características dos eventos a serem investigados.

Klemes (1983) discute a importância das escalas temporais na área da hidrologia. O mesmo enfatiza que escolher uma escala temporal não deve ser feito de forma aleatória, isso porque, a resolução desempenha um papel crucial na conceituação e modelagem dos fenômenos hidrológicos. O autor destaca ainda, que os processos naturais estão intimamente ligados à escala temporal em que são observados; assim, variações nessa escala podem levar a conclusões significativamente errôneas sobre o comportamento do sistema.

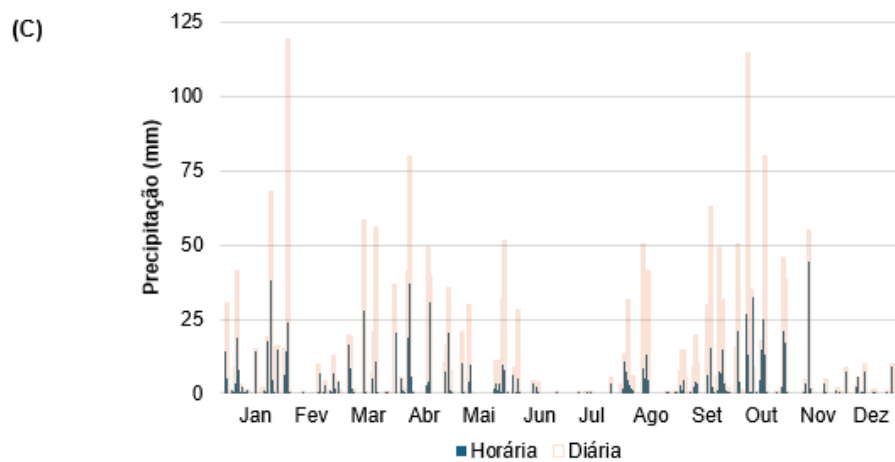


Estudos recentes reforçam essa perspectiva. Ward *et al.* (2018) evidenciam em seu estudo que a utilização de dados com baixa resolução temporal – isto é, com grandes intervalos entre medições consecutivas – compromete a acurácia de modelos hidrológicos e energéticos, podendo resultar na subestimação do escoamento superficial e na superestimação da evaporação, particularmente durante eventos extremos, devido à suavização das intensidades de precipitação e ao consequente aumento da infiltração. Os autores acrescentam ainda, que o tamanho do impacto aumenta à medida que a resolução temporal diminui.

Dessa forma, a compreensão do comportamento da precipitação e, por conseguinte, a determinação das escalas temporais adequadas, não apenas influencia a interpretação dos eventos extremos, mas também impacta diretamente a confiabilidade das aplicações práticas.

A FIGURA 3 apresenta como a agregação dos dados pode influenciar a percepção dos eventos de precipitação ao longo do tempo. A FIGURA 3a apresenta a precipitação mensal para cada mês do ano, juntamente com o total anual, representado pela linha horizontal de referência. Esse contraste permite verificar a sazonalidade e destacar os meses mais e menos chuvosos em relação ao acumulado anual. Na FIGURA 3b, a altura de precipitação diária é sobreposta ao acumulado mensal, mostrando que, mesmo que ocorram fenômenos extremos em um único dia do mês, o efeito é diluído ao longo do mês. A FIGURA 3c, por outro lado, mostra a precipitação horária comparada com a diária e prova que, mesmo que num único dia, a precipitação pode ser muito irregular, ocorrendo chuvas mais intensas em intervalos muito curtos. Posto isso, ressalta-se novamente que compreender a distribuição temporal da precipitação em diferentes escalas é essencial para a modelagem

hidrológica e para a aplicação de técnicas de desagregação que buscam estimar dados em resoluções mais finas a partir de séries mais agregadas.

FIGURA 3 – DIFERENTES RESOLUÇÕES TEMPORAIS DA PRECIPITAÇÃO



FONTE: A autora (2025).

2.2.1 Precipitação Anual

Dados de precipitação anual permitem um entendimento mais abrangente das condições climáticas de uma determinada região, tendo em vista que são séries com uma resolução temporal mais baixa. Ainda que não apresentem uma resolução elevada, sua aplicação é capaz de contribuir em diversas áreas de pesquisa, desde a gestão de recursos hídricos, análise das condições hídricas de uma região, e até para a compreensão de tendências climáticas de longo prazo.

Segundo Garcez e Alvarez (1988), a quantidade total de precipitação acumulada em um ano é uma das características mais interessantes de uma estação pluviométrica, pois oferece uma visão sintética imediata do fenômeno pluviométrico no local.

Ademais, a análise de séries de precipitação anual é fundamental para avaliar a presença de tendências de mudanças nas precipitações ao longo do tempo, conforme apresentado no estudo de Pinheiro *et al.* (2013). Nesta conjuntura, a confiabilidade desses estudos é essencial para a gestão de recursos hídricos, pois permite detectar tendências climáticas (Martini, 2022).

Embora séries anuais ofereçam percepções valiosas para análises de longo prazo, dados com resolução temporal muito baixa possuem limitações quando se trata de análises mais detalhadas como a de eventos extremos e processos hidrológicos de curto prazo. Zanardo *et al.* (2012) apresentam em seu estudo que dados anuais podem mascarar a variabilidade intra-anual, sendo assim, dificultando a observação de eventos críticos.

2.2.2 Precipitação Mensal

Por outro lado, a observação de dados de precipitação em escala mensal proporciona um entendimento um pouco mais detalhado sobre os padrões de precipitação ao longo do tempo, com base em um período menor (Garcez; Alvarez, 1988). Comparado aos dados anuais, que fornecem uma visão mais generalizada, os dados mensais proporcionam uma resolução intermediária, permitindo a identificação de períodos críticos dentro de um ano.

Dados mensais propiciam a definição de padrões sazonais, que são vitais para a gestão de água e a agricultura. Conforme apresentado por Joseph *et al.* (2013),

a observação de tendências sazonais em precipitação, como períodos secos e chuvosos, é fundamental para entender a variabilidade climática e crucial para o planejamento e gestão de recursos hídricos. Entender esses padrões ajuda a planejar atividades agrícolas, dado que o regime de chuvas em uma região está diretamente relacionado à época adequada para o plantio de uma determinada cultura (Silva, 2022).

Além disso, dados com resolução temporal mensal são essenciais para o planejamento e operação de sistemas de irrigação, garantindo que a água disponível seja utilizada de maneira otimizada ao longo das estações do ano (Chow; Maidment; Mays, 1988).

Dados mensais também são frequentemente empregados em estudos de variabilidade climática, uma vez que contribuem com a identificação de padrões de precipitação e indicação de fenômenos climáticos globais, como o El Niño, conforme apresentado nos estudos de Sousa (2015) e Cerón (2019). Da mesma forma, Salviano *et al.* (2016) utilizam dados mensais de precipitação para realizar análises de tendências temporais da precipitação no Brasil, de modo a contribuir com a identificação dos locais em que se observam essas tendências, possibilitando estimar os possíveis danos dessas mudanças.

Embora os dados mensais proporcionem uma visão mais minuciosa que os anuais, é fato que ainda existem limitações nesse tipo de dados, especialmente no que tange à observação de eventos extremos de menor duração. Frequentemente, episódios de precipitação intensa ocorrem em intervalos de tempo reduzidos, restritos a maior parte das vezes em dias ou horas. Dessa maneira seus picos acabam sendo atenuados quando os dados são consolidados em escala mensal. Essa situação compromete a detecção precisa de eventos críticos, como tempestades severas ou inundações repentinas, os quais demandam uma observação temporal diária ou horária para uma avaliação mais acurada e abrangente (Singh, 1992).

2.2.3 Precipitação Diária

Segundo Tucci (1997), dados precipitação diária são de suma importância para o gerenciamento de bacias hidrográficas, pois permitem rastrear a disponibilidade de água ao longo do tempo. Dessa forma, é possível monitorar o uso

da água e garantir o abastecimento humano, industrial e agrícola, com confiança adicional de que os riscos de seca e inundação serão minimizados.

No âmbito da gestão de reservatórios e sistemas de abastecimento hídrico, os dados diários desempenham um papel estratégico. Conforme apresentado nos estudos de Peng *et al.* (2019) e Bosa *et al.* (2024), eles são essenciais para decisões operacionais, como a liberação ou retenção de água. A agilidade em responder às flutuações diárias das precipitações permite um equilíbrio mais preciso entre a oferta e a demanda de recursos hídricos, assegurando a eficiência e a sustentabilidade desses sistemas

Ademais, modelos adotados para estudar processos hidrológicos, como o SWAT (*Soil and Water Assessment Tool*), permitindo a previsão de vazão em rios, dependem de dados diários para realizar simulações de vazão na mesma escala (Jin *et al.*, 2024).

No setor agrícola, dados com essa resolução temporal de precipitação estão entre as informações mais importantes para o planejamento e manejo de culturas. Allen *et al.* (1998), observam que a avaliação da evaporação e evapotranspiração e subsequente planejamento de métodos de irrigação dependem de informação sobre a precipitação recente. Dessa forma, o monitoramento diário da precipitação antecipa indiretamente períodos de seca, o que, por sua vez, informa a opção de reduzir o uso da água ou escolha de culturas resistentes à essa característica climática.

Conforme indicado anteriormente, a precipitação é uma das principais variáveis na investigação sobre o clima e as alterações climáticas. Dessa forma, dados diários são capazes de fornecer uma perspectiva ainda mais detalhada sobre a variabilidade climática a curto prazo e são essenciais para a análise de tendências em escalas maiores. Segundo o relatório do IPCC (2021), o aumento da frequência e intensidade dos extremos de precipitações é uma das consequências previstas no contexto das mudanças climáticas. Logo, dados diários recolhidos sistematicamente não só ajudam a identificar tais características, mas contribuem para a validação de modelos climáticos que buscam determinar previsões de cenários futuros de aquecimento global, juntamente com os impactos regionais.

Embora a sua grande relevância, eventos diários também apresentam limitações, especialmente quando se busca capturar episódios de chuva muito intensos que ocorrem em períodos menores. Eventos críticos de precipitação, como tempestades severas, muitas vezes se concentram em intervalos de minutos ou

horas, o que não é adequadamente refletido pelos dados agregados diários, conforme apresentado por Ward (1967). O autor destaca que essa limitação pode levar a uma subestimação da intensidade e do impacto de eventos extremos, especialmente em regiões onde chuvas convectivas são comuns. Além disso, é ressaltado que a inadequação dos totais diários em estudos de intensidade de precipitação já foi observada, tornando relevante a consideração da frequência de chuvas com durações significativamente mais curtas.

2.2.4 Precipitação Horária

Os dados de precipitação horária são fundamentais para estudos hidrológicos e meteorológicos que exigem uma alta resolução temporal. Enquanto os dados diários representam a precipitação total ocorrida dentro de 24 horas, os dados horários fornecem uma resolução ainda mais fina, permitindo a análise da distribuição e intensidade das chuvas em intervalos menores de tempo (Blenkinsop *et al.*, 2018).

De acordo com Ward (1967), dados horários de chuva são essenciais para o desenvolvimento de curvas intensidade-duração-frequência (IDF), uma vez que a frequência de chuvas de alta intensidade influencia significativamente a suscetibilidade em áreas sujeitas a inundações ou a aumentos repentinos no fluxo dos rios, tornando-se, assim, um aspecto de grande relevância para a hidrologia. Nos sistemas de prevenção e controle de desastres naturais, por exemplo, em que são observadas enchentes repentinas, as medições de precipitação em escalas locais e finas são necessárias (Kidd *et al.*, 2017).

Dados horários também desempenham um papel essencial na previsão de deslizamentos de terra, pois permitem identificar padrões críticos de precipitação em curtos períodos. Scheevel *et al.* (2017) demonstraram que, na região de Seattle, deslizamentos frequentemente ocorrem mesmo com baixos acumulados diários, mas são precedidos por períodos curtos de chuvas intensas. O estudo propôs novos limiares de precipitação baseados em dados horários, melhorando a previsão desses eventos e reforçando a importância de medições de alta resolução temporal para a gestão de riscos geotécnicos. Além disso, a compreensão das características das chuvas de curta duração é fundamental para o desenvolvimento e aprimoramento de sistemas de drenagem em grandes cidades, garantindo uma gestão eficiente dos recursos hídricos e minimizando os impactos de eventos extremos.

Apesar de sua relevância, a obtenção de dados horários enfrenta desafios significativos, especialmente no que tange à disponibilidade e qualidade. Em muitas regiões, a infraestrutura para coleta de dados de alta resolução ainda é insuficiente. Freitas *et al.* (2021) indicam, ainda, que a escassez de dados de precipitação subdiários pode estar atrelada aos custos mais elevados de implementação de pluviógrafos.

Meira *et al.* (2022), por exemplo, analisaram dados de monitoramento automático de precipitação da rede do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), referentes ao período de 2014 a 2020, totalizando 22.777 séries temporais, compostas por registros com resolução sub-horária. Os dados foram provenientes de uma média de 3.000 estações por ano, distribuídas pelo território nacional. No entanto, o estudo revelou que apenas 918 estações operaram por, pelo menos, um ano completo com dados considerados de alta qualidade, e somente duas mantiveram funcionamento contínuo e sem falhas, ao longo dos sete anos analisados. Esses resultados evidenciam a escassez de séries temporais de alta resolução e a dificuldade de obtenção de dados consistentes ao longo do tempo.

2.3 DESAGREGAÇÃO DA PRECIPITAÇÃO

Ao se trabalhar com dados hidrológicos, um dos problemas mais corriqueiros observados é a ausência de dados de alta resolução temporal. Apesar dessa escassez, certas aplicações hidrológicas demandam de dados de precipitação em escalas de tempo subdiária, especialmente estudos que buscam estimar volumes e picos de vazões. Outrossim, conhecer a correta distribuição temporal da chuva para uma região permite uma previsão hidrológica mais precisa em projetos de engenharia (Cruciani, 1986).

Conforme apresentado por Berne *et al.* (2004), dados de precipitação com resolução temporal de alguns minutos são necessários para aplicações hidrológicas em áreas urbanas. No entanto, seja por razões práticas e/ou financeiras, verifica-se uma discrepância entre o que seria um dado ótimo para entrada do modelo e os disponíveis a partir de observações (Berne *et al.*, 2004; Licznar *et al.*, 2011). Estudos demonstram que essa limitação acarreta impactos diretos na estimativa das vazões, por exemplo. Wang, He e Takase (2009), ao avaliarem um modelo chuva-vazão em

diferentes resoluções temporais (diária, horária e sub-horária), evidenciaram que dados de maior detalhe permitem melhor representação dos picos e da recessão dos hidrogramas, enquanto dados em resoluções mais grosseiras tendem a suavizar a resposta hidrológica, subestimando as vazões máximas. Além disso, os autores observaram que parâmetros associados a processos de resposta rápida, como infiltração e escoamento superficial, são altamente sensíveis à resolução temporal.

Dada à frequente indisponibilidade de registros horários de pluviógrafos, diferentes técnicas de desagregação de dados diários de precipitação, medidos em estações pluviométricas, têm sido exploradas na literatura para transformar dados diários em séries horárias (Engida; Esteves, 2011; Pui *et al.*, 2012; Li *et al.*, 2018).

Assim, conforme apresentado por Engida e Esteves (2011), o processo de desagregação da precipitação consiste na transformação de dados de intervalos temporais maiores, como registros diários, em séries de curta duração, como horários ou sub-horários; sendo que esse procedimento possibilita uma análise mais detalhada das características do comportamento dos eventos pluviométricos. Ainda, é de extrema importância que dados decorrentes dessa desagregação sejam consistentes com as séries temporais originais, de forma a garantir que estatísticas relevantes dos processos da precipitação sejam mantidas de forma fidedigna (Li *et al.*, 2018).

Pode-se concluir, portanto, que o uso de modelos de desagregação de chuvas é uma solução encontrada que busca superar a indisponibilidade de dados pluviométricos de alta resolução temporal no Brasil, e em países que enfrentam as mesmas dificuldades, no entanto, precisa ser usado com cautela.


2.4 MODELOS DE DESAGREGAÇÃO DA PRECIPITAÇÃO

A desagregação de precipitação diária em intervalos menores, incluindo a escala horária, é descrita em uma extensa literatura. Como resultado, foram desenvolvidos vários modelos que buscam o mesmo intuito. De acordo com Sharma e Mehrotra (2010), existem diferentes abordagens para a desagregação devido a vários princípios que os fundamentam. Dentre os métodos estudados, os autores citam os modelos estocásticos paramétricos de processo pontual baseados em processos de Poisson, modelos baseados na descrição adimensional de padrões de intensidade da tempestade, modelos de acordo com a teoria de escala invariante, bem

como abordagens paramétricas e não paramétricas. Além disso, como alternativa aos modelos estocásticos, há a possibilidade da adoção de modelos determinísticos.

De acordo com Onof *et al.* (2000), os modelos baseados no processo de Poisson apresentam características correlatas com as observadas nas chuvas, sendo, portanto, apropriados para adoção em modelos hidrológicos. Enquadram-se nessa categoria os modelos de pulso retangular de Neyman-Scott (FIGURA 4) e Bartlett-Lewis, descritos originalmente por Rodríguez-Iturbe *et al.* (1987), os quais estruturam a chuva como eventos estocásticos compostos por células de precipitação aleatórias. Pesquisas recentes vêm buscando aprimorar esses modelos, sendo por meio da regionalização, da inclusão de processos não estacionários ou do ajuste para escalas mais finas (Kaczmariska *et al.*, 2014; Kaczmariska *et al.*, 2015; Kossieris *et al.*, 2018). Kaczmariska *et al.* (2015) analisaram ajustes não estacionários utilizando uma série de 69 anos de dados na cidade de Bochum, na Alemanha, e concluíram que a metodologia proposta é capaz de melhorar a representação da variabilidade interanual da precipitação. Da mesma forma, Kossieris *et al.* (2018) avaliaram uma nova variante do modelo Bartlett-Lewis (BLRPRX), na mesma série de dados, e verificaram que a abordagem proposta melhora significativamente a desagregação da chuva em escalas mais finas, como intervalos de 5 minutos. Embora a sua robustez, os modelos baseados no processo de Poisson ainda apresentam muitos desafios para a calibração de seus parâmetros, de forma a garantir um equilíbrio entre o realismo físico e viabilidade matemática (Onof, 2000).


FIGURA 4 – ESQUEMA MOSTRANDO O PROCESSO DE NEYMAN-SCOTT



Fonte: Favre (2004).

Os modelos adimensionais de padrões de intensidade de tempestade representam uma abordagem fundamental na hidrologia para a compreensão e simulação das características temporais da precipitação. Esses modelos descrevem a distribuição da intensidade das chuvas ao longo do tempo, utilizando curvas adimensionais que permitem generalizar o comportamento das tempestades independentemente de sua duração total ou magnitude. A aplicação desses padrões não se limita apenas à análise das tempestades observadas; eles também podem ser utilizados para a geração sintética de eventos de precipitação, conforme destacado por Sharma e Mehrotra (2010). Entre tais aplicações, pode-se citar o Método de Huff (1967), demonstrado na FIGURA 5, e o Método de Chicago proposto por Keifer e Chu (1957), que decompõem a chuva em frações do tempo total para discernir padrões típicos de intensidade ao longo da tempestade.

FIGURA 5 – DISTRIBUIÇÃO TEMPORAL DAS TEMPESTADES DO PRIMEIRO QUARTIL DO MÉTODO DE HUFF




Fonte: Huff (1967).

Modelos em cascata baseiam-se na invariância de escala da precipitação, permitindo a desagregação de dados por meio de processos multifractais (FIGURA 6). Esses modelos simulam a decomposição da precipitação em escalas menores por processos multiplicativos, podendo ser microcanônicos (que conservam o volume total) ou canônicos (que conservam apenas a média). Segundo Olsson (1998), a abordagem baseada na invariância de escala pressupõe que as propriedades

estatísticas da precipitação em escalas temporais maiores podem ser utilizadas para estimar características em escalas menores, uma vez que ambas seguem a mesma relação de escala. Aplicações práticas desse modelo incluem os estudos de Molnar e Burlando (2005), que avaliaram a performance de modelos canônicos e microcanônicos na Suíça utilizando uma série de 20 anos, e verificaram algumas inconsistências para o modelo na representação dos extremos de precipitação. Estudos como o apresentado por Pui *et al.* (2012), também indicaram que os modelos canônicos e microcanônicos apresentam desempenhos inconsistentes em relação a eventos extremos. Diante dessas limitações, estudos mais recentes buscam aprimorar esses modelos com melhorias na estimativa de extremos, como apresentado por Biswas e Saha (2025), que propuseram a introdução de cópulas para melhorar a representação da variabilidade e extremos da chuva com base em 52 anos de dados da cidade de Kolkata, na Índia, e observaram uma melhora na distorção dos extremos. Ainda, estudos como o de Cappelli *et al.* (2025) propõe uma abordagem parcimoniosa para a calibração de modelos de desagregação multifractal, utilizando apenas os parâmetros das curvas Intensidade-Duração-Frequência (IDF), amplamente acessíveis à comunidade hidrológica. No entanto, desafios persistem, como a dificuldade na reprodução da variabilidade observada e a complexidade da teoria multifractal, que pode limitar sua aplicabilidade prática.

FIGURA 6 – EXEMPLO DE CASCATA ALEATÓRIA MULTIPLICATIVA COM NÚMERO DE RAMIFICAÇÃO $b=2$ E GERADOR DE CASCATA W PARA ESCALAS $n = 0, 1$ E 2



Fonte: Molnar e Burlando (2005).

Os modelos paramétricos de desagregação utilizam distribuições teóricas de probabilidade para representar eventos de precipitação, atribuindo funções

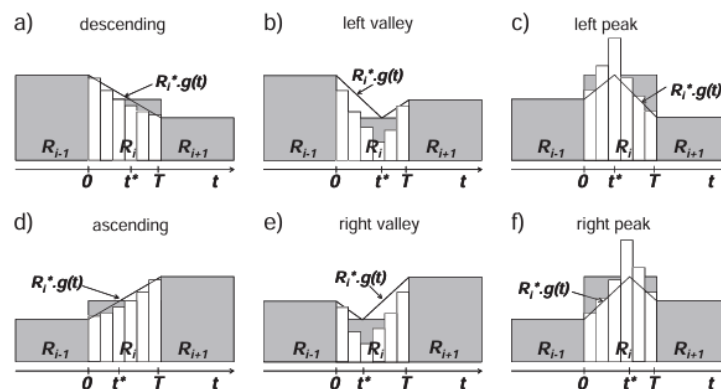
estatísticas a variáveis como tempo de início, volume, intensidade e duração da chuva. Versões iniciais desses modelos foram propostas por Hershenhorn e Woolhiser (1987) e Connolly *et al.* (1998), sendo posteriormente aprimoradas para incluir a dependência entre variáveis, essencial para capturar relações típicas, como a associação entre duração do evento e intensidade da precipitação. A introdução de funções de cópula, aplicadas na hidrologia por De Michele e Salvadori (2003), com dados de precipitação horária da Itália ao longo de 14 anos, permitiu maior flexibilidade na modelagem da dependência entre variáveis, tornando os modelos mais robustos. Modelos hidrológicos modernos já utilizam cópulas de até quatro dimensões, possibilitando uma representação mais fiel da estrutura de dependência entre as variáveis (Pham, 2016). Apesar de sua precisão, os modelos paramétricos apresentam desafios, como excesso de parametrização e maior demanda computacional, o que pode dificultar sua aplicação prática em larga escala.

Os modelos não paramétricos evitam pressuposições sobre a estrutura da precipitação, sendo definidos exclusivamente pelos dados observados e assim evitando a criação de hipóteses sobre a estrutura do modelo (Sharma; Mehrotra, 2010; Li *et al.*, 2018). Entre esses modelos, destaca-se o Método dos Fragmentos, proposto por Svanidze em 1961 para a geração estocástica de vazões (Svanidze, 1980) e posteriormente aplicado à precipitação, desagregando dados diários em escalas menores com base na reamostragem de fragmentos subdiários. A técnica foi aprimorada por Lall e Sharma (1996), que incorporaram um algoritmo baseado em *K-nearest-neighbor* (KNN) para seleção estatística dos fragmentos. Pesquisas subsequentes, como as de Westra *et al.* (2012) e Mehrotra *et al.* (2012), introduziram abordagens regionalizadas, permitindo a aplicação do modelo em locais sem monitoramento direto. Estudos comparativos destacam a robustez do modelo KNN-MOF na preservação das estatísticas da precipitação. Pui *et al.* (2012) testaram o método em quatro localidades na Austrália, utilizando séries superiores a 42 anos, e verificaram sua eficácia na representação de extremos e intervalos secos e úmidos. Da mesma forma, Lu e Qin (2014), ao aplicar o modelo KNN em Singapura com dados de 31 anos, observaram melhor desempenho na preservação da autocorrelação e da probabilidade de ocorrência de chuva. Mais recentemente, Li *et al.* (2018) desenvolveram variantes multivariadas e regionalizadas do Método dos Fragmentos, melhorando a representatividade espacial das séries desagregadas. No entanto, uma

limitação recorrente desses modelos é a dependência dos dados observados, restringindo sua capacidade de extrapolação para eventos extremos não registrados.

Como alternativa aos métodos estocásticos, alguns estudos avaliam métodos determinísticos para a desagregação da chuva, incluindo o Modelo de Desagregação Constante (Modelo CST) e o Modelo Linear de Ormsbee (Modelo OD). O modelo CST é uma abordagem mais simples, o qual assume que a intensidade da precipitação permanece constante ao longo da hora chuvosa, sem variações temporais. Já o modelo OD (FIGURA 7) baseia-se na interpolação linear das intensidades de precipitação, considerando padrões geométricos externos formados pelas precipitações das horas anterior e posterior. Nenhum dos modelos envolve parâmetros ajustáveis e, conforme o estudo de Hingray e Haha (2005), realizado na Suíça com série de 22 anos, ambos apresentaram desempenho insatisfatório, resultando em uma subestimação significativa de algumas estatísticas importantes da precipitação.

FIGURA 7 – SEMELHANÇA GEOMÉTRICA ENTRE OS PADRÕES PLUVIOMÉTRICOS EXTERNOS E INTERNOS PARA AS SEIS CLASSES DE PADRÃO, SEGUNDO ORMSBEE (1989)



Fonte: Hingray e Haha (2005).

Em virtude do exposto, foram selecionados dois métodos distintos para comparação no presente estudo: o modelo de processos pontuais Bartlett-Lewis e o Método de Fragmentos. A escolha dessas abordagens fundamenta-se na necessidade de avaliar técnicas baseadas em diferentes princípios para a distribuição da precipitação ao longo do tempo, permitindo uma análise sobre as vantagens e limitações de cada técnica, bem como da qualidade da desagregação, auxiliando na escolha de metodologias mais adequadas para aplicações hidrológicas.

A adoção desses dois métodos decorre também da análise crítica de outras classes de técnicas de desagregação. Os métodos determinísticos, por exemplo, não têm apresentado resultados satisfatórios na preservação das propriedades estatísticas da chuva, conforme apresentado por Hingray e Haha (2005). Os métodos adimensionais, por sua vez, são mais voltados para a construção de curvas de projeto e aplicações em eventos extremos, não sendo adequados para a geração contínua de séries horárias. Os modelos paramétricos tradicionais exigem elevado esforço de modelagem computacional e calibração, o que limita sua aplicabilidade. Já os métodos canônicos, embora amplamente descritos na literatura, mostraram-se pouco eficientes na representação de chuvas extremas – limitação já apontada por diversos autores, como Molnar e Burlando (2005) e Pui *et al.* (2012) –, motivo pelo qual foram excluídos desta análise. Nesse cenário, a comparação entre o Modelo Bartlett-Lewis e o Método dos Fragmentos, representa uma alternativa equilibrada entre complexidade de aplicação e capacidade de reproduzir a variabilidade intradiária da precipitação.

A FIGURA 8 apresenta uma síntese das principais diferenças entre os dois métodos, destacando suas bases teóricas, tipos de entrada, forma de saída, complexidade de aplicação e sensibilidade à qualidade dos dados, o que evidencia o caráter complementar das abordagens.

FIGURA 8 – PRINCIPAIS DIFERENÇAS ENTRE OS MÉTODOS BARTLETT-LEWIS E FRAGMENTOS

	BARTLETT-LEWIS	FRAGMENTOS
Base teórica	Modelagem de tempestades e células de chuva	Reamostragem de eventos observados
Entrada necessária	Parâmetros estatísticos ajustados	Histórico de dados subdiários
Tipo de saída	Séries sintéticas	Séries baseadas em dias análogos
Complexidade de aplicação	Alta	Baixa
Sensibilidade à qualidade dos dados	Moderada	Alta (qualidade dos fragmento é essencial)

Fonte: A autora (2025).

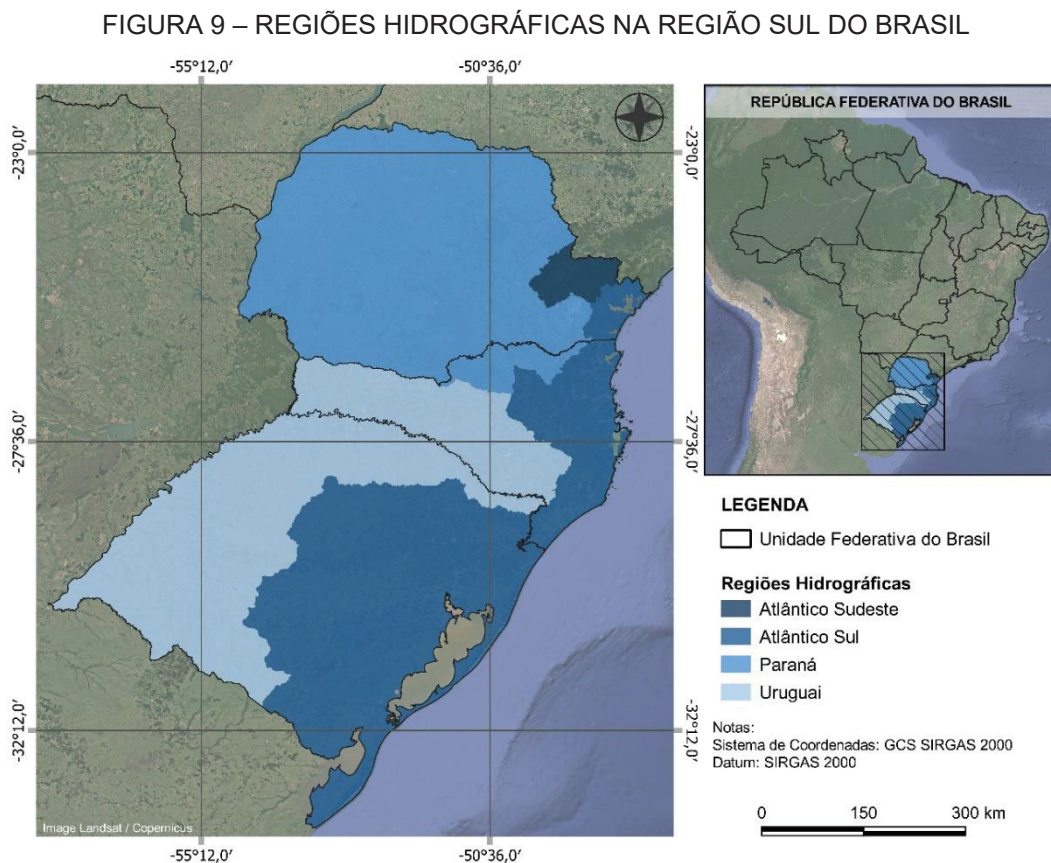
Estudos no Brasil já aplicaram abordagens estocásticas para desagregação ou geração de séries temporais (Back; Dorfman; Clarke, 1999; Cavalcante; Silans, 2012; Aguilar; Costa; 2020). Porém, não foi verificada nenhuma pesquisa que comparasse metodologias distintas. Considerando as particularidades climáticas do país e a variabilidade regional dos regimes de precipitação, é essencial investigar se algum dos modelos apresenta um desempenho superior em determinados contextos. Essa análise é fundamental para direcionar a escolha do método mais apropriado para diferentes regiões, contribuindo para uma representação mais fiel dos padrões pluviométricos e para a melhoria das estimativas hidrológicas.

3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

A região Sul do Brasil, compreendida pelos estados do Paraná, Santa Catarina e Rio Grande do Sul, abrange uma área de cerca de 577 mil km², sendo, portanto, a menor região brasileira em extensão territorial. Outrossim, apresenta uma população estimada em aproximadamente 31 milhões de habitantes, caracterizando-a como a terceira região mais populosa do Brasil (IBGE, 2024).

Apresenta uma rede hidrográfica com grande disponibilidade de água, contemplando quatro regiões hidrográficas: a bacia do Uruguai, a qual drena cerca de 31,0% da região, a do Paraná com 34,5%, a do Atlântico Sul com 32,8% e a do Atlântico Sudeste abrangendo cerca de 1,7% do território, conforme apresentado na FIGURA 9.

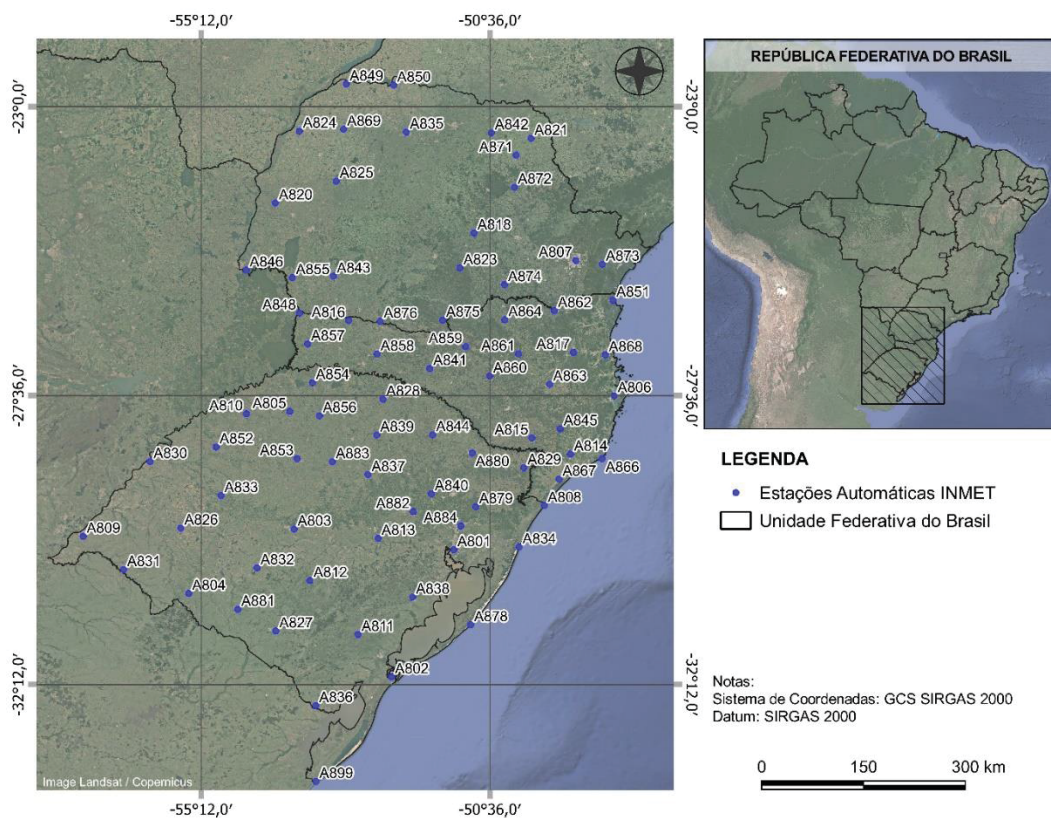


Fonte: A autora (2025).

3.2 FONTE DE DADOS

Os dados de precipitação com resolução horária foram obtidos junto ao Instituto Nacional de Meteorologia (INMET) para toda a região Sul do Brasil. No total, foram identificadas 93 estações, porém apenas 79 possuíam dados disponíveis. A TABELA 1, a TABELA 2 e a TABELA 3 apresentam, respectivamente, as características das estações com dados disponíveis nos estados do Paraná, Santa Catarina e Rio Grande do Sul, e a FIGURA 11 apresenta suas respectivas localizações.

FIGURA 11 – ESTAÇÕES AUTOMÁTICAS DO INMET COM DADOS DISPONÍVEIS NA REGIÃO SUL



Fonte: A autora (2025).

TABELA 1 – ESTAÇÕES AUTOMÁTICAS DO INMET EM OPERAÇÃO NO PARANÁ ATÉ 2024

Código INMET	Localização	Altitude (m)	Ano de Início	Extensão (anos)	Falhas (%)	Anos sem falhas	Anos com até 24h de falha
A869	Cidade Gaúcha	365,8	2008	13,3	19,0	2	1
A876	Clevelândia	966,1	2008	12,6	24,1	1	4
A807	Curitiba	922,9	2003	17,2	21,6	0	0
A849	Diamante do Norte	368,2	2008	11,9	33,0	1	1
A843	Dois Vizinhos	546,0	2007	13,4	24,9	2	2
A846	Foz do Iguaçu	235,1	2008	12,1	30,9	0	0
A875	General Carneiro	1009,0	2008	13,5	15,7	1	2
A825	Goioerê	481,0	2006	10,8	59,0	2	2
A824	Icaraíma	381,3	2006	12,6	36,2	1	1
A823	Inácio Martins	1208,9	2006	16,1	7,2	2	2
A818	Ivaí	803,6	2006	13,9	25,6	0	4
A871	Japira	692,9	2008	14,3	10,6	2	7
A821	Joaquim Tavora	512,7	2006	14,9	14,7	1	4
A820	Marechal Candido Rondon	392,1	2006	16,1	6,3	2	5
A835	Maringá	548,5	2006	15,9	7,6	2	5
A873	Morretes	50,3	2008	14,8	6,5	2	3
A842	Nova Fátima	664,3	2007	12,6	34,3	0	1
A850	Paranapoema	308,7	2008	12,4	28,1	1	1
A855	Planalto	399,1	2007	12,8	26,0	0	2
A874	São Mateus do Sul	780,2	2011	11,3	12,3	2	1
A872	Ventania	1093,4	2011	9,6	31,9	2	4

FONTE: A autora (2025).

TABELA 2 – ESTAÇÕES AUTOMÁTICAS DO INMET EM OPERAÇÃO NO RIO GRANDE DO SUL ATÉ 2024

Código INMET	Localização	Altitude (m)	Ano de Início	Extensão (anos)	Falhas (%)	Anos sem falhas	Anos com até 24h de falha
A826	Alegrete	120,9	2006	16,1	7,3	1	2
A827	Bage	226,2	2007	16,5	3,0	0	5
A840	Bento Gonçalves	623,3	2006	16,6	3,1	0	4
A812	Caçapava do Sul	420,8	2006	16,9	3,5	0	1
A838	Camaquã	92,3	2006	16,1	5,9	0	2
A884	Campo Bom	23,4	2013	10,0	0,5	1	4
A879	Canela	830,9	2008	14,7	4,6	0	9
A811	Canguçu	446,8	2007	15,6	8,6	2	5
A853	Cruz Alta	426,7	2007	16,2	2,6	0	9
A881	Dom Pedrito	150,0	2010	10,4	31,2	1	1
A828	Erechim	777,1	2006	14,6	16,9	1	5
A854	Frederico Westphalen	489,4	2007	15,7	2,1	0	10
A883	Ibirubá	455,3	2012	10,6	4,2	3	2
A836	Jaguarão	31,5	2007	16,0	5,9	2	5
A844	Lagoa Vermelha	833,8	2007	16,3	3,3	0	7
A878	Mostardas	3,8	2008	12,7	24,4	1	4
A856	Palmeira das Missões	614,1	2008	13,5	17,2	0	3
A839	Passo Fundo	680,7	2006	16,9	1,3	0	11
A801	Porto Alegre - Jardim Botânico	41,2	2000	22,5	3,5	0	9
A831	Quarai	113,1	2007	15,1	7,2	0	4
A802	Rio Grande	4,9	2001	19,5	13,6	2	3
A813	Rio Pardo	107,0	2006	16,5	4,8	3	3
A803	Santa Maria	103,1	2001	21,2	4,5	0	5
A810	Santa Rosa	272,8	2006	14,8	16,0	1	3
A899	Santa Vitoria do Palmar – Barra do Chuí	7,4	2008	13,7	15,4	1	2
A804	Santana do Livramento	196,0	2001	17,8	24,2	1	1
A833	Santiago	390,0	2009	13,9	7,4	0	5
A805	Santo Augusto	489,7	2001	19,0	16,2	0	3
A830	São Borja	81,1	2007	14,0	17,4	1	3
A832	São Gabriel	114,9	2007	15,3	7,6	3	5
A829	São José dos Ausentes	1228,6	2006	16,0	7,4	1	5
A852	São Luiz Gonzaga	245,5	2007	14,7	11,5	0	2
A837	Soledade	660,4	2008	15,1	4,7	2	6
A882	Teutônia	81,0	2012	9,6	17,7	1	2
A808	Torres	8,4	2006	16,0	9,6	0	5
A834	Tramandaí	4,6	2008	13,6	16,0	1	3
A809	Uruguaiana	74,3	2006	16,7	3,6	0	6
A880	Vacaria	969,9	2008	15,1	4,0	4	5

FONTE: A autora (2025).


TABELA 3 – ESTAÇÕES AUTOMÁTICAS DO INMET EM OPERAÇÃO EM SANTA CATARINA ATÉ 2024

Código INMET	Localização	Altitude (m)	Ano de Início	Extensão (anos)	Falhas (%)	Anos sem falhas	Anos com até 24h de falha
A867	Araranguá	2,0	2008	14,3	6,4	0	8
A845	Bom Jardim da Serra – Morro da Igreja	1790,4	2007	13,2	25,4	2	3
A859	Caçador	944,3	2008	13,9	13,3	0	4
A860	Curitibanos	978,1	2008	14,7	7,7	2	7
A848	Dionísio Cerqueira	807,5	2008	13,7	13,9	2	3
A806	Florianópolis	4,9	2003	19,5	7,5	0	9
A817	Indaial	72,2	2006	15,5	12,6	0	5
A868	Itajaí	9,8	2010	12,5	8,0	4	4
A851	Itapoá	6,2	2007	13,9	19,3	1	3
A863	Ituporanga	479,8	2008	14,8	7,2	3	6
A841	Joaçaba	767,6	2007	15,5	5,3	1	6
A866	Laguna – Farol de Santa Marta	34,4	2008	13,2	17,9	1	3
A864	Major Vieira	799,6	2009	10,6	40,0	2	3
A816	Novo Horizonte	943,6	2008	12,3	23,8	1	4
A861	Rio do Campo	591,7	2008	12,8	23,4	0	4
A862	Rio Negrinho	800,0	2008	14,5	8,7	1	0
A815	São Joaquim	1400,1	2008	15,2	3,2	1	7
A857	São Miguel do Oeste	700,0	2008	12,4	27,2	0	5
A814	Urussanga	40,6	2008	14,2	9,9	2	3
A858	Xanxerê	878,7	2008	14,7	7,4	1	5

FONTE: A autora (2025).

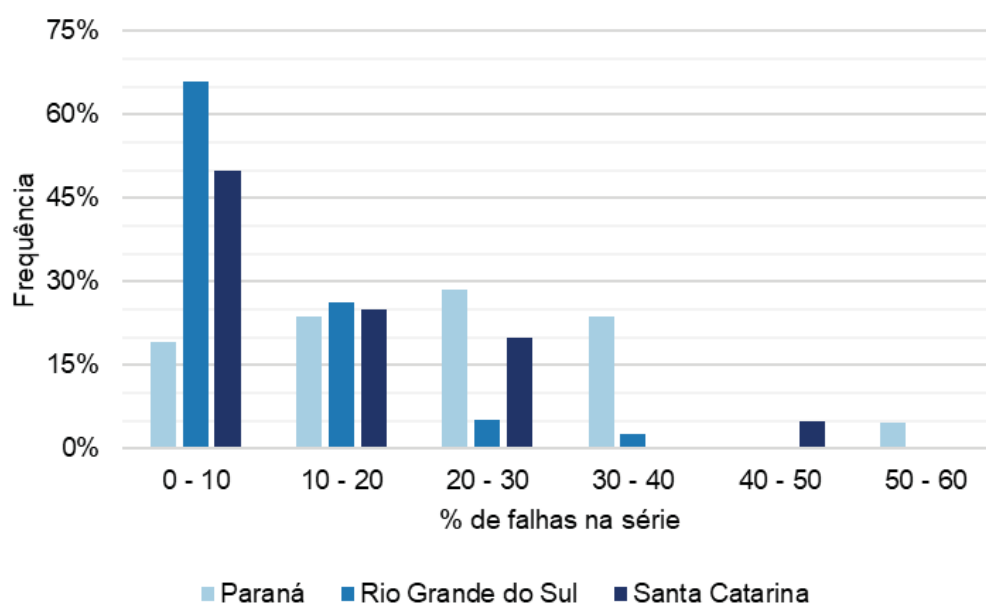
Como o ano de início de monitoramento varia entre as estações, a extensão das séries é bem diversificada. A FIGURA 12 ilustra a distribuição da frequência das estações em função da extensão total das séries de dados. De modo geral, observa-se que a maioria das estações possui séries compreendidas entre 10 e 15 anos, faixa que concentra aproximadamente 76% das estações do Paraná e cerca de 80% das estações de Santa Catarina. No entanto, o comportamento do Rio Grande do Sul difere parcialmente dos demais estados. Embora cerca de 34% das estações também estejam concentradas na faixa de 10 a 15 anos, a maior frequência encontra-se na classe de 15 a 20 anos, que representa aproximadamente 58% das estações gaúchas – o que evidencia uma maior continuidade temporal dos dados neste estado. Além disso, apenas o Rio Grande do Sul conta com estação cuja série ultrapassa os 20 anos de extensão, alcançando 22,5 anos de registros automáticos na estação A801 (Porto Alegre – Jardim Botânico), o que, ainda que pontual, reforça a presença de séries mais longas nessa unidade da federação.

FIGURA 12 – FREQUÊNCIA DAS ESTAÇÕES CONFORME EXTENSÃO TOTAL DAS SÉRIES – PR, RS, SC.



Em relação à porcentagem de falhas observadas nas séries históricas (FIGURA 13), pode-se concluir que a maioria das estações nos três estados apresenta baixos índices de falhas, concentrando-se na faixa de 0 a 10%. Esse comportamento é especialmente evidente no Rio Grande do Sul e em Santa Catarina, onde cerca de 66% e 50% das estações, respectivamente, apresentam até 10% de falhas nos dados. No Paraná, embora essa faixa também seja representativa, observa-se uma distribuição mais dispersa das falhas ao longo das demais classes, com destaque para as faixas entre 20 e 40%, que reúnem aproximadamente 52% das estações do estado. De forma geral, o Rio Grande do Sul apresenta o melhor desempenho em termos de qualidade dos dados, com menor dispersão e maior concentração de séries com baixa taxa de falhas. Em contrapartida, o Paraná apresenta maior variabilidade na distribuição das falhas, o que indica uma menor uniformidade na continuidade dos registros. Essas falhas, frequentemente decorrentes de problemas técnicos, manutenções periódicas e processos de aferição dos medidores, comprometem a integridade e continuidade das séries históricas, impactando diretamente a confiabilidade das análises hidrológicas baseadas nesses dados.

FIGURA 13 – FREQUÊNCIA DAS ESTAÇÕES CONFORME PORCENTAGEM DE FALHAS NAS SÉRIES – PR, RS, SC.




Apesar das falhas nos registros, a maioria das estações apresentam pelo menos um ano sem interrupções. No Paraná, das 21 estações, 16 possuem ao menos um ano de dados completos. No Rio Grande do Sul, esse número é de 15 entre as 33 estações, enquanto em Santa Catarina, 14 das 20 estações registram ao menos um ano sem falhas. A FIGURA 14 apresenta a distribuição percentual das estações em função do número de anos sem falhas nas séries históricas. A análise revela que, embora exista uma parcela significativa de estações com ao menos um ano contínuo de dados, a ocorrência de registros com falhas ao longo de todos os anos ainda é expressiva, especialmente no Rio Grande do Sul, onde cerca de 47% das estações não possuem nenhum ano completo sem interrupções. Em Santa Catarina, essa proporção é próxima de 30%, enquanto no Paraná esse valor é ainda menor, em torno de 24%.

No Paraná, observa-se o melhor desempenho em termos de continuidade, com destaque para a classe de dois anos sem falhas, que concentra aproximadamente 47% das estações – valor superior ao dos demais estados. Santa Catarina também apresenta uma distribuição mais equilibrada, com cerca de 25% das estações possuindo dois anos contínuos, e frequências semelhantes nas classes de zero e um ano. As classes superiores (três e quatro anos sem falhas) apresentam

baixa representatividade, o que reforça os desafios operacionais enfrentados para manter longos períodos de dados completamente contínuos.

FIGURA 14 – DISTRIBUIÇÃO DO NÚMERO DE ANOS SEM FALHAS NAS SÉRIES POR ESTADO



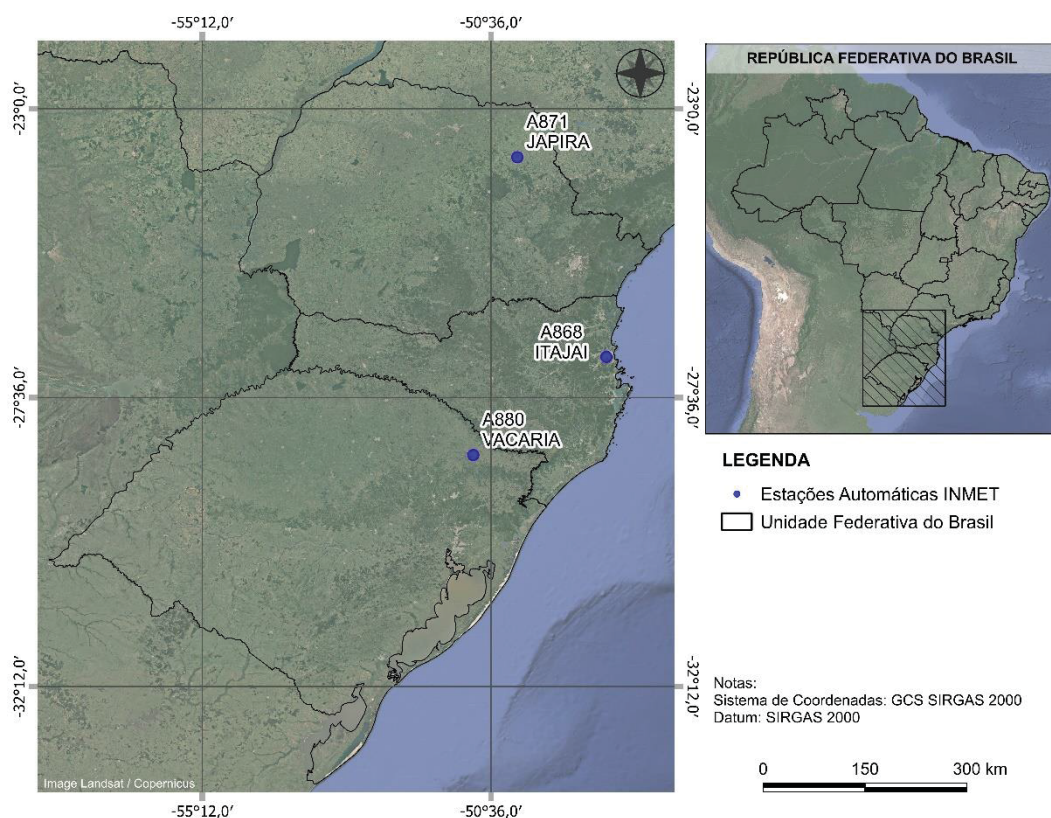
De forma integrada, a FIGURA 12, FIGURA 13 e FIGURA 14 revelam um panorama em que a extensão das séries pluviométricas pode ser considerada razoável, porém a presença de falhas – e principalmente a baixa ocorrência de anos inteiros contínuos – impõe limitações significativas à qualidade dos dados. Essa condição exige atenção redobrada em análises estatísticas e modelagens hidrológicas, especialmente aquelas sensíveis à consistência temporal das séries.

3.2.1 Estações Adotadas

3.2.1.1 Critério de elegibilidade das estações

Para representar a variabilidade espacial da precipitação na região Sul do Brasil, selecionaram-se três estações pluviométricas automáticas do INMET, uma por estado: A871 – Japira (PR), A868 – Itajaí (SC) e A880 – Vacaria (RS). Suas respectivas localizações são indicadas na FIGURA 15.

FIGURA 15 – LOCALIZAÇÃO DAS ESTAÇÕES SELECIONADAS



FONTE: A autora (2025).

A escolha dessas estações foi baseada na qualidade dos dados disponíveis, priorizando aquelas que apresentaram o maior número de anos completos sem falhas; e a qualidade dos registros, considerando como aceitáveis apenas anos com até 24 horas de falhas, o que corresponde a pouco mais de 0,25% do total de registros horários anuais. Nesse sentido, as estações A880 e A871 destacaram-se por apresentarem quatro anos sem falhas, um valor superior à média regional. No Paraná, as estações apresentavam no máximo dois anos completos, sendo a A871 escolhida também por possuir o maior número de anos com falhas inferiores a 24 horas.

Observou-se, entretanto, que Vacaria e Japira apresentavam mais anos elegíveis do que Itajaí (A868), que possuía no máximo oito anos dentro do critério estabelecido. Para garantir equidade estatística na aplicação e calibração dos modelos, adotou-se exatamente oito anos em cada estação. Assim, mesmo havendo anos adicionais adequados em Vacaria e Japira, estes não foram utilizados, de forma a evitar assimetrias metodológicas decorrentes de diferentes volumes amostrais. Ressalta-se que os anos selecionados não coincidem necessariamente entre as estações, uma vez que a consistência dos registros variou entre as localidades. Cada

estação, portanto, foi tratada de forma independente, priorizando-se os anos com menor quantidade de falhas, a fim de assegurar a confiabilidade da base de dados.

A TABELA 4 apresenta o número de horas com dados ausentes no histórico, com destaque dado aos anos selecionados para a base histórica em cada uma das estações analisadas (hachuradas).

TABELA 4 – NÚMERO DE HORAS COM DADOS AUSENTES

Ano	A871 – Japira/PR	A880 – Vacaria/RS	A868 – Itajaí/SC
2008	415	43	-
2009	23	23	-
2010	598	10	67
2011	12	10	15
2012	743	819	3
2013	13	39	19
2014	559	0	1
2015	1	1	0
2016	1	1061	295
2017	996	0	0
2018	0	0	0
2019	0	0	0
2020	5	1140	1469
2021	7142	922	5514
2022	2847	5	834
2023	2	1171	557

FONTE: A autora (2025).

3.2.1.2 Tratamento de falhas

Com o intuito de tratar as falhas pontuais, foi realizada uma verificação cruzada com os dados das estações vizinhas, buscando identificar a possibilidade de preenchimento por analogia espacial. No entanto, constatou-se que, na maioria dos casos, as estações adjacentes também apresentavam registros ausentes ou indicavam precipitação horária inferior a 1 mm nos mesmos períodos. Isso sugere que as falhas nas estações principais provavelmente corresponderam a horas de precipitação nula, não justificando o preenchimento com valores positivos arbitrários.

A única exceção observada foi o caso do dia 28/03/2011 na estação de Japira, que apresentou três horas consecutivas de falha, e uma das estações vizinhas registrou 3,2 mm de chuva em uma dessas horas. Apesar disso, optou-se por manter o valor nulo também nesse caso, considerando que as demais estações vizinhas indicavam precipitação nula nesse mesmo intervalo, e que o episódio representava uma ocorrência isolada e de curta duração. Além disso, dado o reduzido número de

horas faltantes (3h) e o baixo impacto que essa substituição poderia causar na escala anual, entendeu-se que a adoção do valor nulo seria uma abordagem mais consistente com os demais casos.

Dessa forma, todas as falhas horárias identificadas nos anos selecionados foram preenchidas com valor nulo, considerando tanto a insignificância do volume de precipitação ausente quanto a representatividade global da série temporal, que totaliza 8.760 horas por ano. As substituições adotadas representam, portanto, uma fração extremamente pequena do conjunto de dados, não sendo capazes de comprometer as análises subsequentes do presente estudo.

3.2.1.3 Determinação do ano-base para avaliação

Para a avaliação da capacidade dos modelos de desagregação em reproduzir as características da precipitação observada, adotou-se um ano de referência com dados horários disponíveis nas três estações analisadas: A871 (Japira/PR), A880 (Vacaria/RS) e A868 (Itajaí/SC). Dentre os anos comuns às três estações com dados completos ou com número reduzido de falhas, destacam-se os anos de 2011, 2015, 2018 e 2019.

A fim de selecionar o ano mais representativo para as três estações, foram calculadas estatísticas anuais de precipitação, incluindo o total precipitado, o valor máximo de precipitação horária e o número de dias com ocorrência de chuva. Com base na média dos anos disponíveis para cada estação, verificou-se que o ano de 2015, embora próximo às médias dos anos observados, apresentou características extremas em ao menos duas estações, com totais anuais e intensidades horárias significativamente superior aos demais anos analisados, o que pode ser confirmado visualmente nas curvas de permanência anuais (FIGURA 16, FIGURA 17 e FIGURA 18).

Dado o caráter atípico de 2015 – com potencial para enviesar a avaliação ao representar um cenário extremo – optou-se por desconsiderá-lo no cálculo da média representativa. A partir da média recalculada, identificou-se que o ano de 2019 foi o que apresentou maior proximidade às condições médias nas três estações, tanto em termos de volume anual quanto de intensidade horária e frequência de dias chuvosos (TABELA 5).

Por essa razão, o ano de 2019 foi adotado como ano-base para a comparação entre os dados desagregados e os registros horários observados. Essa escolha visa garantir maior neutralidade à análise, representando um ano típico dentro da variabilidade climática local. Afinal, o objetivo principal da validação é verificar se os modelos mantêm as propriedades estatísticas da série original sob condições médias – e não apenas em cenários extremos.

TABELA 5 – DADOS HISTÓRICOS DAS ESTAÇÕES

Ano	A871 – Japira/PR			A880 – Vacaria/RS			A868 – Itajaí/SC		
	Total Anual	Maior Precip. Horária	Dias com chuva	Total Anual	Maior Precip. Horária	Dias com chuva	Total Anual	Maior Precip. Horária	Dias com chuva
2010	-	-	-	2055,6	32,2	222	-	-	-
2011	1300,0	25,0	118	2010,2	40,4	221	2259,6	32,6	234
2012	-	-	-	-	-	-	1436,2	31,6	199
2013	1658,4	34,6	143	-	-	-	1985,0	55,2	223
2014	-	-	-	2283,0	59,8	201	1709,4	61,4	205
2015	2100,6	44,0	170	2324,2	32,6	209	2313,4	44,0	259
2016	1583,4	35,6	130	-	-	-	-	-	-
2017	-	-	-	1714,8	36,6	184	1670,0	40,2	222
2018	1090,0	40,2	125	2015,0	30,4	181	1361,6	45,0	235
2019	1229,6	54,4	117	1721,8	30,2	184	1587,6	31,8	217
2020	1046,0	22,4	112	-	-	-	-	-	-
2021	-	-	-	-	-	-	-	-	-
2022	-	-	-	1898,4	37,2	193	-	-	-
2023	1669,8	44,4	139	-	-	-	-	-	-
Média	1459,7	37,6	132	1790,4	42,7	225	2002,9	37,4	200
Média*	1368,2	36,7	127	1715,6	42,5	220	1956,9	38,1	198

* Média desconsiderando o ano de 2015.

FONTE: A autora (2025).

FIGURA 16 – CURVA DE PERMANÊNCIA – ESTAÇÃO A871 – JAPIRA/PR

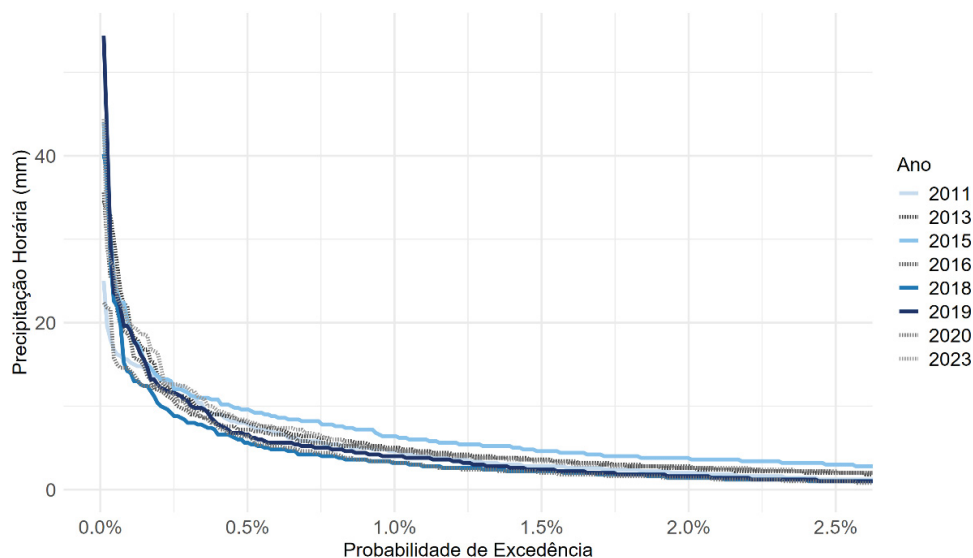


FIGURA 17 – CURVA DE PERMANÊNCIA – ESTAÇÃO A880 – VACARIA/RS





FIGURA 18 – CURVA DE PERMANÊNCIA – ESTAÇÃO A868 – ITAJAÍ/SC



3.2.1.4 Definição da base histórica e do ano de validação

A partir dos critérios de elegibilidade e da análise de consistência, foram inicialmente identificados até oito anos adequados de dados horários em cada estação. Contudo, o ano de 2019 foi excluído dessa base e reservado exclusivamente para a etapa de validação, servindo como série observada de referência. Assim, a base histórica utilizada na aplicação dos modelos de desagregação foi composta por

sete anos em cada estação. A TABELA 6 sintetiza essa seleção, distinguindo os anos que compõem a base histórica e o ano de 2019, adotado como referência observada.

TABELA 6 – ANOS SELECIONADOS PARA COMPOR A BASE HISTÓRICA E ANO DE VALIDAÇÃO EM CADA ESTAÇÃO

Estação	Base histórica (anos)	Ano de validação
A871 – Japira/PR	2011, 2013, 2015, 2016, 2018, 2020 e 2023.	2019
A880 – Vacaria/RS	2010, 2011, 2014, 2015, 2017, 2018 e 2022.	2019
A868 – Itajaí/SC	2011, 2012, 2013, 2014, 2015, 2017 e 2018.	2019

FONTE: A autora (2025).

3.3 MODELO BARTLETT-LEWIS MODIFICADO

A modelagem estocástica da precipitação é uma abordagem amplamente utilizada na hidrologia para representar a variabilidade temporal das chuvas e possibilitar sua simulação em diferentes escalas de tempo. Uma das abordagens mais conhecidas para esse propósito é o Modelo Bartlett-Lewis do Pulso Retangular, originalmente proposto por Rodríguez-Iturbe *et al.* (1987). Esse modelo baseia-se na teoria de processos pontuais de Poisson, nos quais os eventos de precipitação são gerados como agrupamentos (clusters) de células de chuva, cada uma representada por um pulso retangular com intensidade e duração aleatórias.

As suposições gerais do modelo de Bartlett-Lewis podem ser descritas da seguinte maneira e são apresentadas na FIGURA 19:


- As origens das tempestades t_i ocorrem seguindo um processo de Poisson com taxa λ , ou seja, surgem aleatoriamente ao longo do tempo;
- Dentro de cada uma das tempestades i , as origens das células t_{ij} seguem um processo de Poisson com taxa β ;
- A duração de cada tempestade v_i ocorre de forma a seguir uma distribuição exponencial com parâmetro γ ;
- Cada célula de chuva gerada dentro da tempestade i possui uma duração w_{ij} aleatória, que segue uma distribuição exponencial com parâmetro η ;

- Cada célula mantém uma intensidade constante ao longo de sua duração, mas sua magnitude varia entre as células de acordo com uma distribuição exponencial com média μ_X , o que permite representar a variabilidade da intensidade da chuva ao longo do tempo.

O modelo original, caracterizado pelos cinco parâmetros λ , β , γ , η , μ_X , apresentou um bom desempenho na reprodução da precipitação. No entanto, algumas limitações foram identificadas, especialmente na representação da variabilidade temporal das chuvas e da estrutura de dependência entre eventos. Para aprimorar a capacidade do modelo de reproduzir as estatísticas observadas da precipitação, Rodríguez-Iturbe *et al.* (1988) propuseram uma modificação, resultando no Modelo Bartlett-Lewis do Pulso Retangular Modificado (BLPRM).

A principal mudança introduzida foi a substituição da distribuição exponencial para a duração das células por uma distribuição gama, de forma que o parâmetro η passa a ser uma variável aleatória com parâmetros de forma e escala (α e ν). Permitindo, assim, uma melhor representação da alternância entre períodos secos e úmidos e melhorando a aderência dos dados simulados às estatísticas observadas. A parametrização do modelo modificado implicou em uma variação indireta dos parâmetros β e γ , uma vez que η passou a ser uma variável aleatória. No entanto, as razões $\kappa = \beta/\eta$ e $\phi = \gamma/\eta$ são mantidas constantes, garantindo que a estrutura de dependência entre eventos seja preservada.

FIGURA 19 – ESQUEMA DO MODELO BARTLETT-LEWIS DO PULSO RETANGULAR



Fonte: Adaptado de Koutsoyiannis e Onof (2001).

Apesar dessas melhorias, o BLPRM ainda era predominantemente aplicado à simulação de precipitação. A adaptação do modelo para a desagregação de precipitação exigiu modificações adicionais, culminando na abordagem proposta por Koutsoyiannis e Onof (2001), que combinou o modelo Bartlett-Lewis com um procedimento de ajuste para garantir a conservação do total diário da chuva. Essa metodologia garante que a soma da precipitação desagregada em escalas menores seja consistente com os valores medidos diariamente, preservando a variabilidade estatística da chuva. O método de desagregação, propriamente dito, de Koutsoyiannis e Onof (2001) combina o modelo de Pulsos Retangulares de Bartlett-Lewis com um processo iterativo de ajuste, de forma a permitir que as séries sintéticas horárias geradas sejam coerentes com os dados históricos disponíveis.

Inicialmente, o modelo Bartlett-Lewis gera uma série sintética de precipitação subdiária \tilde{Z}_i , a partir dos parâmetros calibrados. Essa série é composta por valores de precipitação acumulada para cada intervalo de tempo menor que o diário.

Após a geração da série sintética, é necessário verificar se os valores diários simulados \tilde{Z}_i estão suficientemente próximos dos valores observados Z_i . Para isso, é utilizado um critério de seleção baseado na similaridade, ou seja, para cada sequência de dias chuvosos, múltiplas realizações horárias são geradas e avaliadas com base em uma métrica de distância d , definida pela equação 3.1.

$$d = \left(\sum_{i=1}^L \ln^2 \left(\frac{Z_i + c}{\tilde{Z}_i + c} \right) \right)^{1/2} \quad 3.1$$

Onde:

- Z_i : total diário observado no dia i ;
- \tilde{Z}_i : total diário gerado pelo modelo antes do ajuste;
- c : constante pequena para evitar problemas numéricos com valores baixos (tipicamente 0,1 mm);
- L : número de dias chuvosos no intervalo analisado.

O critério de seleção baseia-se na minimização da métrica d , ou seja, se $d \leq d_a$ (onde d_a é um limite predefinido), a série sintética é aceita. Caso contrário, novas séries são geradas até encontrar uma que satisfaça o critério. Os autores destacam ainda, que a sequência de d obtida com esse tipo de repetição não é uma sequência

convergente para zero ou d_a , mas sim uma sequência aleatória com uma dada probabilidade de d ser menor ou igual a d_a .

Após a definição da melhor série horária, é aplicado um ajuste proporcional para assegurar que a soma dos valores desagregados seja idêntica ao total diário registrado. Esse ajuste, pode ser descrito pela equação 3.2.

$$X_s = \widetilde{X}_s \left(\frac{\sum_{i=1}^L Z_i}{\sum_{i=1}^L \widetilde{Z}_i} \right) \quad (s = 1, \dots, k) \quad 3.2$$

Onde:

- X_s : série modificada;
- \widetilde{X}_s : série sintética de nível horário;
- Z_i : altura diária original;
- \widetilde{Z}_i : altura diária gerada;
- k : número de variáveis de nível inferior dentro de um período de nível superior.

Esse procedimento de ajuste proporcional é fundamental para que os valores simulados em escalas menores sejam coerentes com os totais diários observados, garantindo a conservação dos volumes de precipitação sem comprometer as estatísticas fundamentais da distribuição da chuva. Além de assegurar a coerência entre as escalas temporalmente agregadas, o método de Koutsoyiannis e Onof (2001) permite a inclusão de níveis de repetição no processo de geração e seleção, otimizando a qualidade estatística das séries desagregadas e assegurando que a estrutura temporal da precipitação seja preservada.

3.3.1 Calibrações avaliadas

Com o intuito de avaliar a influência da sazonalidade na performance do modelo Bartlett-Lewis Modificado, este estudo propõe a realização de duas abordagens distintas de calibração: uma com parâmetros constantes ao longo do ano (calibração anual) e outra com parâmetros específicos para cada mês (calibração mensal). A adoção dessas duas estratégias visa investigar se a incorporação explícita

da variabilidade sazonal contribui significativamente para a melhora na capacidade do modelo em reproduzir as propriedades estatísticas da precipitação horária.

Na abordagem anual, todos os dados disponíveis ao longo do período de calibração são considerados em conjunto para a estimação de um único conjunto de parâmetros representativo do regime médio anual de precipitação. Essa configuração é particularmente atrativa pela sua simplicidade e menor esforço computacional.

Por outro lado, a calibração mensal parte do pressuposto de que os processos geradores da chuva apresentam variações substanciais ao longo do ano, refletindo mudanças nos mecanismos atmosféricos atuantes e nas características típicas de eventos pluviométricos em cada estação. Dessa forma, o modelo é calibrado separadamente para cada mês, resultando em 12 conjuntos distintos de parâmetros. Embora mais onerosa do ponto de vista computacional, essa abordagem tem potencial para capturar com maior fidelidade o comportamento estatístico da precipitação em diferentes períodos do ano, principalmente em regiões com regime fortemente sazonal.

Para ambas as configurações – anual e mensal – são realizadas 100 simulações independentes, com o objetivo de avaliar a estabilidade dos resultados e a variabilidade associada ao processo estocástico de geração das séries horárias. A análise comparativa entre as duas calibrações (anual e mensal) é conduzida por meio da avaliação de métricas estatísticas aplicadas às séries simuladas, com foco em variáveis de validação padrão, horário de pico e extremos horários, conforme definido posteriormente no item 3.5. Essa etapa permite verificar em que medida a consideração da sazonalidade explícita impacta na acurácia do modelo e, por consequência, na sua aplicabilidade em diferentes contextos hidrológicos.

A calibração e a geração das séries horárias pelo modelo Bartlett-Lewis Modificado foram realizadas no ambiente R por meio do pacote *HyetosMinute* (Koutsoyiannis; Onof, 2001). Esse pacote implementa o algoritmo de otimização *Evolutionary Annealing-Simplex* (EAS), que busca minimizar uma função objetivo composta pela soma dos desvios quadráticos normalizados entre estatísticas observadas e simuladas (média, variância, autocorrelação de primeira ordem e proporção de horas secas), avaliadas em diferentes escalas de acumulação (1h, 6h, 12h e 24h).

O resultado de cada calibração é expresso pelo valor denominado *bestval*, que corresponde ao valor mínimo da função objetivo associado ao conjunto ótimo de parâmetros (*bestpar*). Esse valor não deve ser interpretado como um erro absoluto, mas como uma métrica relativa de ajuste: quanto menor o *bestval*, maior a aderência dos parâmetros calibrados às estatísticas observadas. Considerando a natureza estocástica do algoritmo, foram executadas 5 calibrações para cada configuração (mensal e anual), sendo adotada como solução final aquela que apresentou o menor valor de *bestval*.

3.4 MÉTODO DOS FRAGMENTOS

O Método dos Fragmentos (MOF) é uma abordagem não paramétrica de desagregação de precipitação diária, utilizado para gerar séries temporais de precipitação com intervalos de tempo menores, como a escala horária. Ao contrário dos modelos paramétricos, o MOF não faz suposições sobre a estrutura dos dados, mas sim reamostra fragmentos de precipitação a partir de séries temporais passadas, mantendo as dependências temporais observadas.

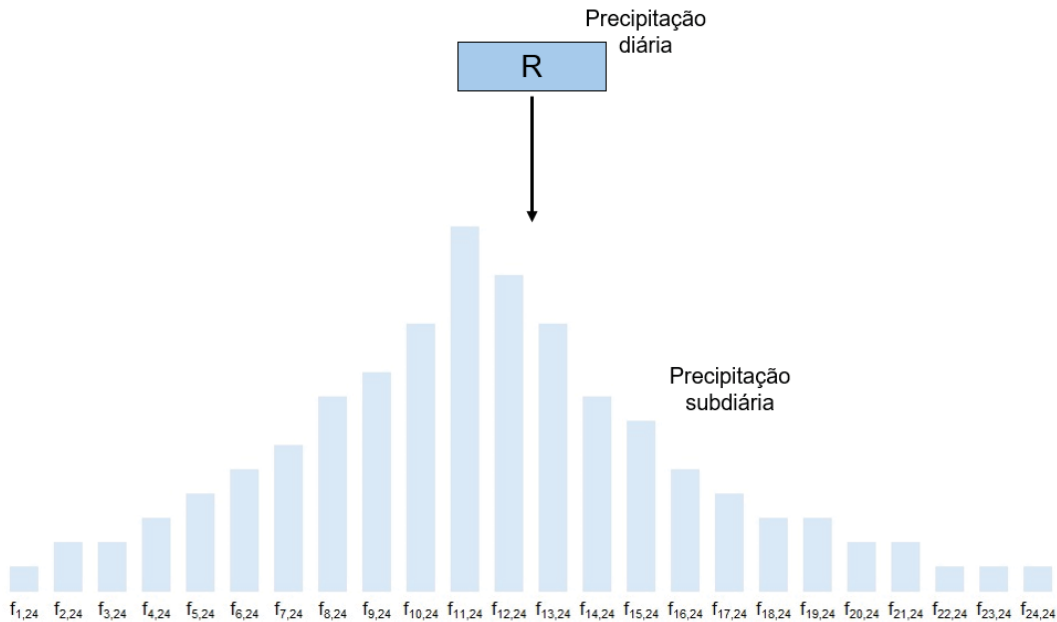
O processo de desagregação no MOF envolve a divisão da precipitação diária em fragmentos que representam a razão entre a precipitação subdiária e a precipitação diária. Por exemplo, para uma série horária em que a precipitação é uniforme ao longo das 24 horas, cada fragmento será ponderado em $1/24$. Esses fragmentos são ajustados de acordo com as condições de precipitação passadas e reamostrados usando uma técnica baseada em k-vizinhos mais próximos, conforme apresentando por Lall e Sharma (1996). O modelo opera dentro de uma janela temporal deslizante, permitindo que os padrões sazonais e a magnitude da precipitação sejam adequadamente representados nas sequências geradas.

Além disso, o MOF é sensível a padrões sazonais e variações na magnitude da precipitação diária, o que permite que o modelo seja adaptado para diferentes condições climáticas e características locais de precipitação. Essa sensibilidade torna o modelo adequado para estudos em diferentes regiões, como áreas tropicais, temperadas ou semiáridas.

A FIGURA 20 é uma representação esquemática do Método dos Fragmentos, no qual a precipitação diária observada R é desagregada em intervalos subdiários

com base na reamostragem de fragmentos extraídos de dias historicamente semelhantes.

FIGURA 20 – ESQUEMA DO MÉTODO DOS FRAGMENTOS



Fonte: A autora (2025).

Sua metodologia pode ser descrita em etapas sucessivas. Primeiramente ocorre a definição dos fragmentos subdiários; sendo assim, para cada dia t , a precipitação diária R_t é associada a um vetor de fragmentos $f_{i,m}$, que representa a proporção da precipitação diária que ocorre em cada intervalo subdiário m do dia. A relação entre a precipitação subdiária $X_{i,m}$ e a precipitação diária R_i pode ser representada pela Equação 3.3.

$$f_{i,m} = \frac{X_{i,m}}{R_i} \quad 3.3$$

Onde:

- $X_{i,m}$: precipitação observada no intervalo subdiário m ;
- R_i : precipitação total do dia i .

Os dias j da série temporal são classificados em quatro classes distintas, baseadas nas condições de precipitação dos dias anteriores e posteriores. Essas

classificações ajudam a identificar padrões de precipitação que são comuns em uma determinada estação ou época do ano, podendo ser classificadas em:

- Classe 1: O dia j apresenta precipitação, entretanto, os dias anterior ($j - 1$) e posterior ($j + 1$) não apresentam;
- Classe 2: O dia j apresenta precipitação, e o dia anterior ($j - 1$) também apresenta, entretanto, o posterior ($j + 1$) não;
- Classe 3: O dia j apresenta precipitação, e o dia posterior ($j + 1$) também apresenta, entretanto, o anterior ($j - 1$) não;
- Classe 4: O dia j apresenta precipitação, e os dias anterior ($j - 1$) e posterior ($j + 1$) também apresentam.

Em seguida, para cada dia t a ser desagregado, é definida uma janela temporal de l dias, centrada no dia t . Essa janela é considerada ao longo de toda a série histórica, e não apenas no ano em análise. Com isso, após identificar a classe c_t do dia t , é realizada a amostragem com base nos vizinhos mais próximos dentro da janela temporal l . Para isso, o algoritmo seleciona os k vizinhos mais próximos da série temporal histórica dentro da janela l , ou seja, os dias cujas precipitações diárias mais se aproximam de R_t . A escolha dos vizinhos é então realizada com base na diferença absoluta entre a precipitação diária R_j e R_t ($|R_j - R_t|$). Os k vizinhos mais próximos são selecionados, e a precipitação diária de cada vizinho é reamostrada com base em uma distribuição de probabilidade associada à classe c_t . Essa probabilidade é estimada através da equação 3.4.

$$p_j = \frac{\frac{1}{j}}{\sum_{i=1}^k \frac{1}{i}} \quad 3.4$$

Onde:

- p_j : probabilidade de seleção do vizinho j , com $j = 1$ para o vizinho com menor saída absoluta;
- k : número total de vizinhos.

Por último, com base nos vizinhos selecionados, os fragmentos $f_{i,m}$ de precipitação subdiária são extraídos e utilizados para construir a série temporal de precipitação subdiária para o dia t . Esse processo garante que a precipitação

subdiária gerada para o dia t reflita o padrão observado no histórico de precipitações para dias com características semelhantes.

Após selecionar e gerar os fragmentos subdiários para o dia de interesse t , os passos são repetidos até que a desagregação completa seja concluída.

3.4.1 Configurações de l e k

A determinação dos parâmetros l (janela de busca) e k (número de vizinhos) no Método dos Fragmentos influencia diretamente a estrutura interna da série desagregada.

O parâmetro l , por sua vez, define o intervalo de dias ao redor da data-alvo dentro do qual os fragmentos candidatos são buscados. A escolha adequada dessa janela está associada ao compromisso entre a representatividade sazonal e a disponibilidade de fragmentos. Janelas muito curtas tendem a preservar a sazonalidade de forma mais estrita, mas podem resultar em um número reduzido de dias com características compatíveis, especialmente em classes de baixa ocorrência. Por outro lado, janelas muito amplas aumentam o número de fragmentos disponíveis, mas podem introduzir ruídos ao considerar eventos com características temporais distintas. Assim, para este estudo, foram testadas duas janelas temporais, 15 e 30 dias. A escolha desses valores visa equilibrar o número de fragmentos disponíveis para cada dia e a preservação de padrões sazonais relevantes. Além disso, Costa (2015) observou que janelas temporais muito pequenas apresentam dificuldades em reproduzir com precisão as estatísticas da série observada, enquanto janelas excessivamente extensas implicam um aumento significativo no esforço computacional, sem proporcionar melhorias substanciais na qualidade da desagregação. Assim, os valores adotados buscam representar cenários contrastantes e operacionais, permitindo uma avaliação robusta da influência desse parâmetro.

Com a janela definida, são selecionados os k fragmentos mais similares ao dia a ser desagregado. Lall e Sharma (1996) sugerem como valor inicial $k = \sqrt{n}$, sendo n o número total de dias classificados como similares. No entanto, os próprios autores apontam que variações moderadas em torno desse valor não comprometem significativamente o desempenho do modelo, recomendando o uso de valores entre 5

e 10 como ponto de partida. Considerando isso, optou-se nesta pesquisa por não adotar a fórmula adaptativa de $k = \sqrt{n}$, uma vez que tal abordagem implicaria um valor diferente de k para cada dia a ser desagregado, o que poderia tornar o modelo desnecessariamente complexo, além de dificultar a reprodutibilidade e a análise comparativa dos resultados. Em seu lugar, foram adotados valores fixos de k , sendo esses 5, 10 e 15, os quais cobrem cenários representativos com diferentes combinações entre a janela de busca l e a classificação dos dias. Por exemplo, no caso mais favorável, com uma janela de 30 dias e sete anos disponíveis (totalizando até 210 fragmentos), considerando que todos os dias fossem classificados como similares, a fórmula indicaria $k \approx 15$. Já para cenários menos favoráveis, como uma janela l de 15 dias com poucos dias classificados como similares (ex.: 3 dias por ano), tem-se um total de 21 fragmentos, para os quais $k \approx 5$ seria mais adequado. Dessa forma, os três valores analisados para k garantem flexibilidade na comparação entre cenários distintos.

Combinando os dois parâmetros, o modelo foi testado em seis configurações distintas, resultantes das combinações entre os valores de $l = 15$ e 30 , e $k = 5$, 10 e 15 . Para cada uma dessas seis configurações, foram realizadas 100 simulações independentes, totalizando 600 simulações para cada estação analisada. Essa abordagem permite avaliar a estabilidade do método frente à natureza probabilística ao selecionar os fragmentos históricos com base em critérios de similaridade e sorteio aleatório, de forma a fornecer uma base estatisticamente robusta para a comparação entre os diferentes cenários analisados.

3.5 VALIDAÇÃO DOS MODELOS

A etapa de validação tem como objetivo avaliar o desempenho dos modelos de desagregação temporal quanto à capacidade de reproduzir as principais características estatísticas da série horária de precipitação observada. Para tanto, adotam-se métricas que capturam diferentes aspectos da estrutura dos dados, com a comparação entre séries observadas e simuladas conduzida por meio de estatísticas de validação padrão – variância horária, proporção de horas secas e autocorrelação de primeira ordem (lag-1) – complementadas pela análise do horário de ocorrência do pico diário e das chuvas máximas horárias diárias.

3.5.1 Ano de Referência para Validação

A validação dos modelos de desagregação foi conduzida a partir da geração da série horária do ano de 2019, adotado como referência observada. Esse ano foi previamente selecionado por apresentar maior proximidade às condições médias de precipitação entre as três estações analisadas, sendo, portanto, representativo da variabilidade climática local, conforme apresentado no item 3.2.1.

Para garantir imparcialidade no processo, 2019 foi excluído da base histórica utilizada na calibração e aplicação dos modelos, a qual foi composta por sete anos em cada estação. Dessa forma, a comparação entre a série desagregada e os dados observados de 2019 permitiu avaliar a capacidade dos modelos em reproduzir propriedades estatísticas típicas da precipitação, sem influência direta do ano de validação no processo de ajuste.

3.5.2 Estatísticas de Validação Padrão

A variância horária foi utilizada como indicativo da dispersão dos valores de precipitação ao longo do tempo, refletindo a capacidade dos modelos em preservar a magnitude da variabilidade intradiária presente nos dados reais. Valores de variância simulada significativamente menores podem indicar uma suavização excessiva da chuva, ao passo que valores superiores podem sugerir uma intensificação artificial da variabilidade pluviométrica.

A proporção de horas secas foi empregada como métrica da intermitência da chuva ao longo do dia, refletindo a frequência relativa de horas sem precipitação. Essa estatística é fundamental para avaliar a capacidade do modelo em reproduzir a alternância entre períodos secos e chuvosos, característica essencial da estrutura de séries horárias realistas.

A autocorrelação de primeira ordem (lag-1) foi empregada como medida da dependência temporal entre os valores de precipitação em horas consecutivas. Essa métrica permite aferir a persistência da chuva dentro de um mesmo evento, sendo essencial para garantir que a estrutura sequencial da série não seja artificialmente distorcida durante a desagregação.

No caso dessas estatísticas de validação padrão, optou-se por realizar a análise em escala mensal, além da anual, com o objetivo de capturar a variabilidade sazonal inerente à precipitação. Tais métricas são altamente influenciadas pelas características climáticas mensais, e sua avaliação isoladamente em escala anual poderia mascarar comportamentos extremos ou inconsistências do modelo em determinados períodos do ano. A análise mensal, portanto, permite identificar padrões sistemáticos de superestimativa ou subestimativa, funcionando como um diagnóstico mais sensível da capacidade do modelo em reproduzir a estrutura estatística da chuva ao longo das diferentes épocas do ano.

Como forma de complemento às análises, foram calculados erros estatísticos clássicos entre os valores simulados e observados para cada indicador, a saber: o erro médio absoluto (MAE), o erro percentual absoluto médio (MAPE), o erro quadrático médio (MSE) e a raiz do erro quadrático médio (RMSE). O MAE fornece uma medida direta do desvio médio entre valores simulados e observados, enquanto o MAPE permite relativizar esse desvio em termos percentuais, facilitando a comparação entre variáveis com diferentes magnitudes. O MSE, por sua vez, penaliza de forma mais severa erros maiores, sendo útil para identificar variações extremas entre os dados. Já o RMSE, ao apresentar os erros na mesma unidade da variável avaliada, fornece uma medida intuitiva da precisão do modelo. A análise conjunta desses indicadores permite uma avaliação abrangente da acurácia dos modelos, destacando não apenas a proximidade dos valores simulados em relação aos observados, mas também a consistência de suas estruturas internas.

3.5.3 Horário de Pico Diário

Adicionalmente, avaliou-se o horário de ocorrência do pico diário de precipitação, indicador que busca verificar a capacidade dos modelos em reproduzir o momento do dia em que ocorrem os maiores volumes de chuva. Diferenças sistemáticas no posicionamento do pico indicam que o modelo pode estar deslocando artificialmente a concentração da precipitação ao longo do dia. Essa análise foi conduzida em escala anual, de modo a maximizar a robustez estatística das estimativas e minimizar os ruídos decorrentes da baixa amostragem mensal. Como a desagregação é realizada a partir de fragmentos diários, o horário de pico é registrado

todos os dias, o que possibilita a construção de uma amostra suficientemente ampla para sustentar a avaliação anual. Assim, a estatística resultante corresponde à síntese dos picos mensais, ainda que não explicitados individualmente, oferecendo uma representação mais estável e consistente do comportamento intradiário das chuvas simuladas.

A identificação do horário de pico diário foi realizada considerando, em cada dia com precipitação total superior a zero, a hora de maior intensidade horária de precipitação. Nos casos em que ocorreram empates entre diferentes horários com o mesmo valor máximo, foi adotado o critério de selecionar a ocorrência observada mais cedo. Uma vez determinado o horário de pico de cada dia, este foi classificado em um dos quatro blocos horários definidos (00-05h, 06-11h, 12-17h e 18-23h).

Para a série observada, a aplicação desse procedimento resultou na distribuição relativa dos picos por bloco horário. Para as séries desagregadas, os horários de pico foram identificados em cada simulação e, em seguida, todos os resultados foram reunidos dentro de cada configuração de calibração. A partir desse conjunto agregado, calculou-se a distribuição relativa da frequência de ocorrência em cada bloco horário para cada configuração e estação. Esse procedimento permitiu sintetizar os resultados, destacando a tendência global de cada configuração, e possibilitou a comparação direta com a distribuição observada, de modo a verificar se há ou não um padrão preferencial de ocorrência dos máximos diários.

3.5.4 Chuva Horária Máxima Diária

Outra métrica fundamental refere-se às chuvas máximas horárias diárias, obtidas a partir da extração do maior valor de precipitação horária registrado em cada dia. Essa análise visa capturar o comportamento extremo da série desagregada, sendo um indicativo da capacidade do modelo em representar eventos de maior intensidade em escala subdiária.

A análise da chuva máxima horária diária foi conduzida em escala anual, uma vez que a natureza da métrica exige um volume amostral elevado para que a distribuição empírica dos valores seja estatisticamente robusta. A avaliação mensal, apesar de possível, poderia introduzir instabilidade nas estimativas devido à baixa frequência de eventos significativos em certos períodos. Assim, a análise anual

permite aferir, de forma mais consistente, a capacidade do modelo em reproduzir a magnitude e a frequência dos eventos mais intensos de precipitação em escala subdiária.

Para avaliar a representação desses eventos extremos simulados, foi realizada uma análise estatística das chuvas máximas horárias diárias, considerando as 100 séries geradas por cada configuração, tanto do MOF como para o MBL. A análise restringiu-se aos dias com ocorrência de chuva, de forma a evitar distorções na distribuição dos valores máximos. Para cada série, foram extraídos os máximos horários diários e calculadas estatísticas descritivas: média, mediana, desvio padrão, quantis 90%, 95% e 99%, além do valor máximo absoluto. Essas mesmas estatísticas foram determinadas para a série observada, permitindo comparações diretas com os dados simulados.

Como complemento à análise, foram elaboradas curvas de permanência a partir das chuvas máximas horárias diárias, extraídas tanto da série observada quanto das 100 simulações de cada configuração (l e k para MOF e calibração mensal e anual para MBL). Para cada simulação gerou-se uma curva de permanência própria; no entanto, para fins de síntese e comparação, adotou-se a mediana e a faixa interquartil (P25-P75) das 100 curvas em cada posição da ordenação. Assim, cada configuração é representada por uma curva-síntese, permitindo avaliar simultaneamente a tendência central e a variabilidade entre execuções. A curva observada, construída pelo mesmo critério, foi sobreposta às simulações, possibilitando verificar a aderência e o viés de cada configuração na representação dos máximos horários diários.

Dessa forma, a aderência dos valores simulados aos observados, por meio de estatísticas descritivas e da curva de permanência, permite avaliar a capacidade dos modelos em representar eventos extremos de forma consistente.

4 RESULTADOS

O presente capítulo está organizado em quatro partes principais, de modo a contemplar de forma sistemática a avaliação dos modelos de desagregação analisados. A primeira parte é dedicada à análise do modelo Bartlett-Lewis Modificado, calibrado em duas maneiras distintas – anual e mensal – permitindo investigar os efeitos da sazonalidade na qualidade da desagregação. Na segunda parte, são apresentados os resultados obtidos a partir de diferentes configurações do Método dos Fragmentos, explorando os impactos da variação dos parâmetros l e k sobre a representação estatística da precipitação horária. Na terceira parte realiza-se a comparação entre os dois modelos, destacando convergências, divergências e implicações práticas para o uso dessas técnicas em aplicações hidrológicas. Por fim, na quarta parte é feita uma breve discussão sobre as limitações e implicações observadas nos modelos estudados.

4.1 MODELO BARTLETT-LEWIS MODIFICADO

4.1.1 Calibração

A calibração do modelo Bartlett-Lewis Modificado apresentou valores da função objetivo entre 4,41 e 5,21, dependendo da estação e da configuração adotada (TABELA 7). Para a calibração anual, cada estação resultou em um conjunto único de parâmetros, com $bestval$ em torno de 5,15 a 5,21. Já a calibração mensal produziu 12 conjuntos de parâmetros distintos, com valores de $bestval$ variando entre 4,41 e 4,74, a partir da utilização da base histórica de sete anos selecionados em cada estação.

De forma geral, observa-se que a calibração mensal resultou em valores de $bestval$ inferiores aos da calibração anual, sugerindo maior aderência estatística quando a sazonalidade é considerada explicitamente. Os parâmetros resultantes de cada calibração foram então empregados para a geração das séries horárias desagregadas, a partir das quais se desenvolveram as análises comparativas das métricas de validação (variância horária, proporção de horas secas, autocorrelação lag-1), além da avaliação do horário de pico e dos extremos de precipitação, apresentadas nas seções subsequentes.

TABELA 7 – PARÂMETROS DE CALIBRAÇÃO DO MODELO BARTLETT-LEWIS MODIFICADO – ESTAÇÕES A871, A880 E A868

Mês	α	λ	ν	κ	ϕ	μ_x	'bestval'	Estação
Jan	2,688	0,008	0,996	2,763	2,315	1,332	4,686	A871 – Japira/PR
Fev	2,898	0,006	0,956	0,492	0,356	1,701	4,674	
Mar	8,016	0,003	0,717	3,331	0,035	0,474	4,574	
Abr	2,491	0,009	0,551	0,571	0,735	2,111	4,736	
Mai	2,664	0,010	0,972	0,030	4,969	2,173	4,705	
Jun	2,680	0,008	0,988	2,692	4,927	1,678	4,695	
Jul	2,710	0,009	0,999	0,851	2,397	1,863	4,701	
Ago	2,635	0,008	0,893	1,464	1,957	1,619	4,699	
Set	2,692	0,009	1,000	0,383	3,066	2,048	4,701	
Out	2,887	0,005	0,911	4,541	0,689	0,665	4,657	
Nov	2,671	0,006	0,681	2,017	0,594	1,145	4,692	
Dez	2,805	0,006	1,000	2,847	0,892	0,955	4,666	
Anual	2,214	0,009	0,931	0,010	4,423	1,384	5,195	
Jan	2,897	0,005	1,000	3,768	2,948	2,243	4,507	A880 – Vacaria/RS
Fev	2,855	0,006	0,960	1,337	3,491	2,936	4,515	
Mar	2,810	0,006	0,883	1,392	2,322	2,789	4,515	
Abr	2,841	0,006	0,882	1,468	4,962	3,442	4,525	
Mai	2,794	0,006	0,845	3,682	3,457	2,391	4,521	
Jun	2,839	0,007	0,967	0,059	1,462	3,447	4,512	
Jul	2,746	0,006	0,820	3,248	4,728	2,920	4,533	
Ago	9,743	0,002	0,230	0,235	0,011	10,532	4,426	
Set	2,877	0,005	1,000	3,792	2,360	1,941	4,500	
Out	2,872	0,005	0,997	4,742	3,119	1,949	4,504	
Nov	2,846	0,007	0,980	0,040	4,459	3,475	4,512	
Dez	2,872	0,005	1,000	4,372	2,552	1,813	4,502	
Anual	2,212	0,011	0,829	2,609	3,995	1,015	5,207	
Jan	9,957	0,003	0,334	0,099	0,013	17,668	4,456	A868 – Itajaí/SC
Fev	4,368	0,003	0,937	3,095	0,188	0,984	4,407	
Mar	3,018	0,004	0,845	4,898	0,741	1,066	4,459	
Abr	2,897	0,007	1,000	2,544	3,965	2,605	4,480	
Mai	2,883	0,007	1,000	1,485	4,353	2,972	4,483	
Jun	3,156	0,004	0,770	4,894	0,499	0,921	4,447	
Jul	3,430	0,004	0,949	0,513	0,278	3,116	4,473	
Ago	3,116	0,003	0,936	4,254	0,779	1,428	4,498	
Set	2,863	0,008	0,970	0,847	3,115	3,010	4,484	
Out	2,912	0,007	1,000	1,726	2,349	2,580	4,479	
Nov	2,762	0,008	0,726	2,045	3,578	3,029	4,519	
Dez	2,948	0,007	0,986	0,169	0,584	3,265	4,479	
Anual	2,233	0,009	0,652	0,973	0,644	1,050	5,155	

4.1.2 Estatísticas de Validação Padrão

4.1.2.1 Variância

Na TABELA 8 são apresentados os valores de variância observados mensalmente, bem como a mediana das 100 séries simuladas em cada configuração, abrangendo as três estações de estudo (A871, A880 e A868) sob as duas formas de

calibração. Complementarmente, a TABELA 9 reúne tanto os erros médios mensais – obtidos pela média dos erros individuais de cada mês – quanto os erros anuais, estes determinados por meio da comparação direta entre os valores anuais observados e as 100 simulações correspondentes para cada configuração.

TABELA 8 – MODELO BARTLETT-LEWIS – VARIÂNCIA (mm²) – ESTAÇÕES A871, A880 E A868

Descrição	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Anual	Estação
Obs	7,201	1,587	0,779	0,391	0,343	0,808	0,167	0,031	0,516	0,123	5,164	2,328	1,628	A871 – Japira/PR
MBL _{Calib. mensal}	1,550	1,194	0,188	0,283	0,464	0,754	0,305	0,021	0,574	0,075	1,810	1,202	0,719	
MBL _{Calib. anual}	1,219	0,908	0,385	0,194	0,327	0,550	0,231	0,021	0,411	0,081	1,727	1,085	0,603	
Obs	2,944	0,864	1,853	0,585	2,765	0,227	0,734	0,366	0,282	2,313	3,577	0,920	1,469	A880 – Vacaria/RS
MBL _{Calib. mensal}	1,850	1,473	1,356	1,344	3,474	0,403	1,414	0,450	0,576	2,677	2,724	0,868	1,569	
MBL _{Calib. anual}	0,870	0,688	0,625	0,581	1,527	0,199	0,599	0,323	0,320	1,299	1,047	0,462	0,729	
Obs	4,217	3,637	1,301	0,705	1,239	0,268	0,558	0,065	0,700	0,849	0,934	0,777	1,266	A868 – Itajaí/SC
MBL _{Calib. mensal}	3,084	1,165	0,913	1,313	1,963	0,473	0,617	0,103	1,592	0,779	2,025	0,842	1,265	
MBL _{Calib. anual}	0,882	0,948	0,609	0,645	0,924	0,313	0,345	0,072	0,712	0,445	0,915	0,408	0,614	

FONTE: A autora (2025).

TABELA 9 – MODELO BARTLETT-LEWIS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA VARIÂNCIA – ESTAÇÕES A871, A880 E A868

Descrição	Erro Médio Mensal			Erro Anual			Estação
	MAE	MAPE	MSE	MAE	MAPE	MSE	
MBL _{Calib. mensal}	0,980	47,0%	3,70	0,998	55,8%	0,828	A871 – Japira/PR
MBL _{Calib. anual}	1,038	44,1%	4,20	1,054	62,6%	1,021	
MBL _{Calib. mensal}	0,544	56,1%	0,47	0,605	7,2%	0,018	A880 – Vacaria/RS
MBL _{Calib. anual}	0,756	38,4%	1,25	0,773	50,1%	0,545	
MBL _{Calib. mensal}	0,693	60,2%	1,06	0,755	9,8%	0,025	A868 – Itajaí/SC
MBL _{Calib. anual}	0,685	38,0%	1,51	0,705	50,4%	0,410	

FONTE: A autora (2025).

Na estação A871 (Japira/PR), ambas as configurações avaliadas (MBL_{Calib. mensal} e MBL_{Calib. anual}), mostraram desempenho limitado em reproduzir a amplitude dessa variabilidade. Em ambos os casos, verificou-se uma subestimação sistemática dos meses de maior variância, especialmente em janeiro e novembro, para os quais os valores simulados ficaram muito abaixo do observado. Em contrapartida, nos meses de baixa variabilidade, em que a previsibilidade é naturalmente maior devido à menor incerteza das chuvas, o modelo apresentou resultados mais consistentes. Assim, embora tenha se mostrado adequado em representar os períodos secos, o modelo não foi capaz de capturar adequadamente os picos de variabilidade associados aos meses chuvosos.

A análise dos erros confirma esse padrão. Em escala mensal (FIGURA 21), o MBL_{Calib. mensal} apresentou desempenho levemente superior em termos de erro absoluto (MAE = 0,98), enquanto o MBL_{Calib. anual} apresentou menor erro relativo (MAPE = 44,1% frente a 47,0%). Em escala anual (FIGURA 22), por sua vez, o MBL_{Calib. mensal} manteve vantagem em termos de erro absoluto (MAE = 0,909 contra 1,020 no MBL_{Calib. anual}), embora ambas as configurações tenham resultado em erros percentuais elevados (MAPE = 55,8% e 62,6%, respectivamente), indicando uma representação insatisfatória da magnitude total da variância.

FIGURA 21 – MBL – VARIÂNCIA MENSAL – ESTAÇÃO A871 (JAPIRA/PR)


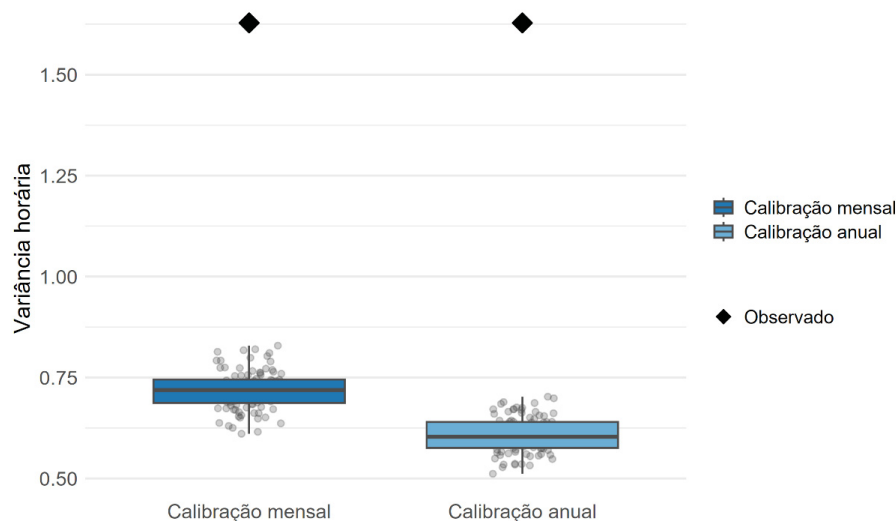


FIGURA 22 – MBL – VARIÂNCIA ANUAL – ESTAÇÃO A871 (JAPIRA/PR)



Na estação A880 (Vacaria/RS), o desempenho do MBL variou significativamente entre as duas configurações de calibração. O $MBL_{Calib. \text{ mensal}}$ apresentou maior proximidade com o observado, reproduzindo de forma razoável a ordem de grandeza dos meses mais variáveis, embora com algumas discrepâncias. Ainda assim, manteve a sazonalidade e apresentou valores mais consistentes que o $MBL_{Calib. \text{ anual}}$. O $MBL_{Calib. \text{ anual}}$, por sua vez, resultou em uma subestimação sistemática, com valores consideravelmente inferiores aos observados em praticamente todos os meses, além de não reproduzir adequadamente a amplitude da variabilidade intradiária. Isso evidenciou a limitação de uma calibração única para capturar a dinâmica mensal da estação.

A análise dos erros reforça essas diferenças. Em escala mensal (FIGURA 23), o $MBL_{Calib. \text{ mensal}}$ apresentou menor erro absoluto ($MAE = 0,544$ contra $0,756$ do $MBL_{Calib. \text{ anual}}$), embora com erro relativo mais elevado ($MAPE = 56,1\%$ frente a $38,4\%$ do $MBL_{Calib. \text{ anual}}$). Isso indica que o $MBL_{Calib. \text{ mensal}}$ foi mais preciso em termos de magnitude, mas o $MBL_{Calib. \text{ anual}}$, por subestimar fortemente os picos, resultou em menor erro proporcional em meses de baixa variância. Em escala anual (FIGURA 24), o contraste entre as duas configurações foi ainda mais evidente. O $MBL_{Calib. \text{ mensal}}$ apresentou erros muito baixos ($MAE = 0,106$; $RMSE = 0,132$; $MAPE = 7,2\%$), praticamente reproduzindo o valor anual observado ($1,469$ contra $1,569$). Já o $MBL_{Calib. \text{ anual}}$ apresentou desempenho insatisfatório, com subestimação expressiva ($0,729$ simulado contra $1,469$ observado) e altos erros relativos ($MAPE = 50,1\%$).

FIGURA 23 – MBL – VARIÂNCIA MENSAL – ESTAÇÃO A880 (VACARIA/RS)





FIGURA 24 – MBL – VARIÂNCIA ANUAL – ESTAÇÃO A880 (VACARIA/RS)



Por fim, na estação A868 (Itajaí/SC), a variância obtida apresentou diferenças significativas entre as configurações. O $MBL_{\text{Calib. mensal}}$ mostrou-se capaz de acompanhar melhor a sazonalidade, ainda que com distorções. Em janeiro, por exemplo, subestimou o valor observado (3,084 contra 4,217), enquanto em setembro e novembro superestimou (1,592 e 2,025 frente a 0,700 e 0,934 observados, respectivamente). No geral, apresentou valores mais próximos do observado ao longo do ano e preservou razoavelmente o padrão de variabilidade. O $MBL_{\text{Calib. anual}}$, por sua vez, resultou em forte subestimação sistemática, com valores muito inferiores aos observados em todos os meses de alta variabilidade (ex.: janeiro: 0,882 contra 4,217;

fevereiro: 0,948 contra 3,637). Esse desempenho sugere que, ao não reproduzir adequadamente os eventos extremos de precipitação típicos do verão, o modelo falha também em captar a variância associada a esses meses. Assim, mais do que uma deficiência em reproduzir a sazonalidade, a limitação está ligada à representação dos extremos, que acabam inflando a variância observada.

A análise dos erros evidencia esse contraste. Em escala mensal (FIGURA 25), os erros absolutos médios foram semelhantes ($MAE \approx 0,69$ em ambas as configurações), mas com comportamentos distintos: o $MBL_{Calib. \text{ mensal}}$ apresentou maior erro relativo ($MAPE = 60,2\%$ contra $38,0\%$ no $MBL_{Calib. \text{ anual}}$), consequência da superestimação em meses de baixa variância. Já o $MBL_{Calib. \text{ anual}}$, por reduzir sistematicamente os valores simulados, obteve MAPE artificialmente menor, apesar de representar mal os meses de maior variabilidade. Em escala anual (FIGURA 26), o $MBL_{Calib. \text{ mensal}}$ apresentou desempenho claramente superior, praticamente reproduzindo o valor observado (1,266 contra 1,265), com erros muito baixos ($MAE = 0,124$; $MAPE = 9,8\%$). O $MBL_{Calib. \text{ anual}}$, por outro lado, subestimou de forma expressiva a variância anual (0,614 contra 1,266), resultando em erros elevados ($MAE = 0,638$; $MAPE = 50,4\%$)

FIGURA 25 – MBL – VARIÂNCIA MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)





FIGURA 26 – MBL – VARIÂNCIA ANUAL – ESTAÇÃO A68 (ITAJAÍ/SC)



A análise da variância horária evidenciou diferenças relevantes no desempenho do modelo Bartlett-Lewis Modificado entre as estações avaliadas.

Na estação A871 (Japira/PR), o modelo foi capaz de preservar a tendência geral sazonal da variância horária, mas não a sua magnitude. O $MBL_{\text{Calib. mensal}}$ apresentou ligeira vantagem em termos de erros absolutos, enquanto o $MBL_{\text{Calib. anual}}$ obteve erro relativo menor em escala mensal, mas com desempenho inferior em termos absolutos. Em ambos os casos, contudo, a incapacidade do modelo em reproduzir os valores elevados de variância nos meses chuvosos reforça sua limitação estrutural em representar adequadamente a amplitude da variabilidade intradiária nesta localidade.

Na estação A880 (Vacaria/RS), os resultados mostraram contraste ainda mais claro entre as configurações. O $MBL_{\text{Calib. mensal}}$ representou de forma consistente a variabilidade intradiária, preservando a sazonalidade e aproximando-se muito do valor anual observado. Já o $MBL_{\text{Calib. anual}}$, apesar de apresentar erro relativo menor em escala mensal, subestimou sistematicamente a variância, falhando em representar a dinâmica real da estação. Esses resultados destacam a importância da calibração mensal para esta localidade, garantindo uma melhor representação da variabilidade intradiária da precipitação.

Na estação A868 (Itajaí/SC), o comportamento foi semelhante ao observado em Vacaria: o $MBL_{\text{Calib. mensal}}$ mostrou-se mais adequado, reproduzindo a sazonalidade e praticamente coincidindo com o valor anual observado, ainda que com distorções

em meses específicos. O $MBL_{Calib. \text{ anual}}$, por sua vez, resultou em uma subestimação acentuada e generalizada, não representando adequadamente a amplitude da variância ao longo do ano.

De modo geral, a comparação entre as três estações indica que o Bartlett-Lewis tende a suavizar a variância horária, sendo incapaz de representar adequadamente os picos sazonais de maior variabilidade. Entre as configurações, o $MBL_{Calib. \text{ mensal}}$ mostrou-se consistentemente superior ao $MBL_{Calib. \text{ anual}}$, apresentando melhor desempenho absoluto e maior fidelidade em escala anual, ainda que com limitações na reprodução de extremos mensais. Já o $MBL_{Calib. \text{ anual}}$ revelou forte limitação estrutural, resultando em subestimações sistemáticas e perda de representatividade dos padrões intradiários.

4.1.2.2 Proporção de Horas Secas

Na TABELA 10, são detalhados os valores observados, tanto mensais quanto anuais, da proporção de horas secas, além da mediana obtida a partir das 100 séries simuladas em cada configuração, considerando as três estações analisadas (A871, A880 e A868). A TABELA 11, por sua vez, apresenta os erros médios mensais – obtidos pela média dos erros individuais de cada mês – quanto os erros anuais, estes determinados por meio da comparação direta entre os valores anuais observados e as 100 simulações correspondentes para cada configuração.

TABELA 10 – MODELO BARTLETT-LEWIS – PROPORÇÃO DE HORAS SECAS – ESTAÇÕES A871, A880 E A868

Descrição	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Anual	Estação
Obs	0,935	0,917	0,958	0,951	0,950	0,953	0,953	0,993	0,933	0,970	0,921	0,903	0,945	A871 – Japira/PR
MBL _{Calib. mensal}	0,923	0,920	0,927	0,971	0,970	0,974	0,985	0,993	0,968	0,973	0,900	0,911	0,951	
MBL _{Calib. anual}	0,917	0,917	0,952	0,963	0,964	0,968	0,980	0,993	0,957	0,974	0,909	0,913	0,950	
Obs	0,919	0,887	0,895	0,868	0,844	0,957	0,914	0,954	0,935	0,843	0,910	0,930	0,905	A880 – Vacaria/RS
MBL _{Calib. mensal}	0,940	0,954	0,953	0,948	0,915	0,974	0,965	0,964	0,972	0,915	0,949	0,964	0,950	
MBL _{Calib. anual}	0,902	0,918	0,921	0,918	0,862	0,964	0,938	0,961	0,957	0,858	0,899	0,944	0,919	
Obs	0,905	0,859	0,914	0,882	0,841	0,926	0,910	0,956	0,872	0,876	0,831	0,901	0,890	A868 – Itajaí/SC
MBL _{Calib. mensal}	0,910	0,904	0,934	0,954	0,933	0,951	0,956	0,976	0,947	0,954	0,939	0,960	0,943	
MBL _{Calib. anual}	0,898	0,894	0,914	0,923	0,888	0,943	0,945	0,969	0,917	0,927	0,885	0,937	0,919	

FONTE: A autora (2025).

TABELA 11 – MODELO BARTLETT-LEWIS – ERROS MÉDIOS MENSIS E ERROS ANUAIS NA REPRODUÇÃO DA PROPORÇÃO DE HORAS SECAS – ESTAÇÕES A871, A880 E A868

Descrição	Erro Médio Mensal			Erro Anual			Estação
	MAE	MAPE	MSE	MAE	MAPE	RMSE	
MBL _{Calib. mensal}	0,018	1,9%	0,00	0,019	0,006	0,6%	A871 – Japira/PR
MBL _{Calib. anual}	0,013	1,4%	0,00	0,015	0,005	0,5%	
MBL _{Calib. mensal}	0,045	5,1%	0,00	0,046	0,045	5,0%	A880 – Vacaria/RS
MBL _{Calib. anual}	0,021	2,3%	0,00	0,023	0,014	1,6%	
MBL _{Calib. mensal}	0,054	6,1%	0,00	0,054	0,053	6,0%	A868 – Itajaí/SC
MBL _{Calib. anual}	0,032	3,7%	0,00	0,034	0,029	3,3%	

FONTE: A autora (2025).

Na estação A871 (Japira/PR), o modelo Bartlett-Lewis Modificado apresentou bom desempenho na reprodução da proporção de horas secas, tanto no $MBL_{Calib. \text{ mensal}}$ quanto no $MBL_{Calib. \text{ anual}}$, com valores simulados muito próximos aos observados. Em termos quantitativos, os erros mensais para escala mensal (FIGURA 27) foram baixos em ambas as configurações, com leve vantagem para o $MBL_{Calib. \text{ anual}}$ (MAE = 0,013; MAPE = 1,4%) em relação ao $MBL_{Calib. \text{ mensal}}$ (MAE = 0,018; MAPE = 1,9%). Em escala anual (FIGURA 28), os erros foram especialmente baixos, não ultrapassando 0,6% em nenhuma das abordagens.

FIGURA 27 – MBL – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A871 (JAPIRA/PR)





FIGURA 28 – MBL – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A871 (JAPIRA/PR)



Para a estação A880 (Vacaria/RS), o MBL apresentou resultados distintos entre as duas configurações. O MBL_{Calib. mensal} superestimou sistematicamente a proporção de horas secas, já o MBL_{Calib. anual} mostrou-se mais equilibrado, apresentando valores mais próximos ao observado em diferentes meses, ainda que com algumas discrepâncias, tanto para escala mensal quanto para anual (FIGURA 29 e FIGURA 30, respectivamente).

FIGURA 29 – MBL – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A880 (VACARIA/RS)


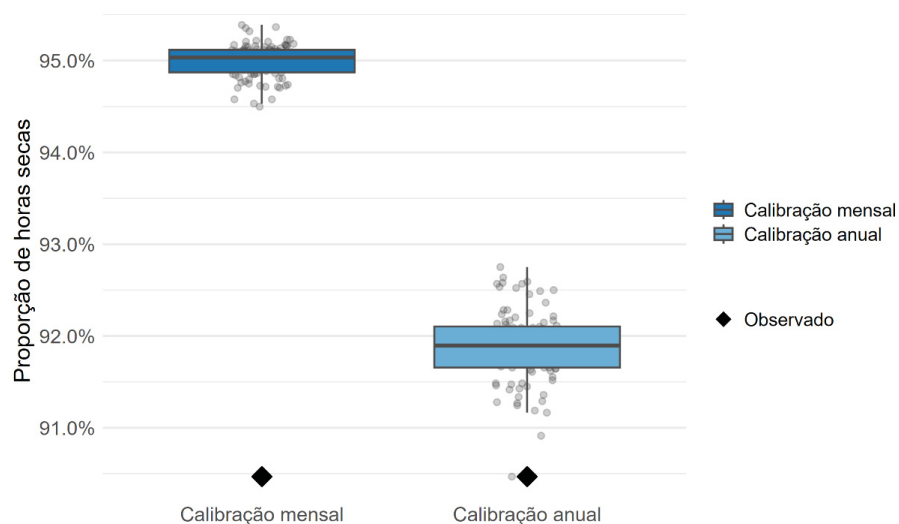


FIGURA 30 – MBL – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A880 (VACARIA/RS)



A análise quantitativa reforça esse contraste. Em escala mensal, o $MBL_{Calib. \text{ anual}}$ apresentou desempenho nitidamente superior, com erro médio absoluto (MAE) de 0,021 e erro percentual (MAPE) de 2,3%, contra 0,045 e 5,1% no $MBL_{Calib. \text{ mensal}}$. Em escala anual, a vantagem do $MBL_{Calib. \text{ anual}}$ foi ainda mais evidente, com erro praticamente desprezível (MAE = 0,014; MAPE = 1,6%), enquanto o $BL_{Calib. \text{ mensal}}$ manteve uma superestimação mais acentuada (MAE = 0,045; MAPE = 5,0%). Mesmo assim, considerando a magnitude reduzida dos erros obtidos e a boa aproximação em relação à série observada, ambos os resultados podem ser considerados bastante satisfatórios, demonstrando que o modelo foi capaz de representar adequadamente a intermitência da chuva horária nesta estação.

Na estação A868 (Itajaí/SC), o modelo de Bartlett-Lewis Modificado, em ambas as configurações, tendeu a superestimar a proporção de horas secas, ainda que em diferentes magnitudes. O $MBL_{Calib. \text{ mensal}}$ apresentou valores sistematicamente mais elevados que o observado, já o $MBL_{Calib. \text{ anual}}$ mostrou desempenho mais equilibrado, aproximando-se melhor do padrão observado, ainda que também com superestimações pontuais, para ambas as escalas (FIGURA 31 e FIGURA 32).

Os indicadores de erro confirmam essa diferença. Em escala mensal, o $MBL_{Calib. \text{ anual}}$ apresentou desempenho superior, com MAE = 0,032 e MAPE = 3,7%, contra 0,054 e 6,1% no $MBL_{Calib. \text{ mensal}}$. Em escala anual, a vantagem do $MBL_{Calib. \text{ anual}}$ foi novamente evidente, com MAE = 0,029 e MAPE = 3,3%, frente a 0,053 e 6,0% no $MBL_{Calib. \text{ mensal}}$.

FIGURA 31 – MBL – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)


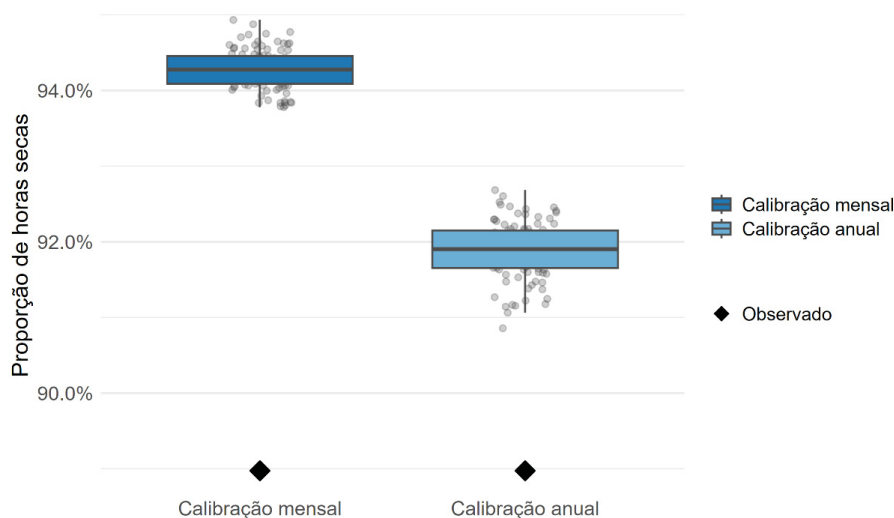


FIGURA 32 – MBL – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC)



A análise da proporção de horas secas evidenciou que, diferentemente da variância, o modelo de Bartlett-Lewis apresentou desempenho bastante satisfatório em todas as estações.

Na estação A871 (Japira/PR), tanto o $MBL_{Calib. \text{ mensal}}$ quanto o $MBL_{Calib. \text{ anual}}$ representaram bem a métrica, com resultados consistentes em ambas as formas de calibração. No geral, apresentou erros baixos em escala mensal ($MAE \leq 0,018$; $MAPE \leq 1,9\%$) e praticamente desprezíveis em escala anual ($MAE \leq 0,006$). A proximidade entre observado e simulado indica que o modelo consegue preservar adequadamente a intermitência da precipitação nessa estação, não apresentando limitações relevantes para essa métrica.

Na estação A880 (Vacaria/RS), observou-se maior contraste entre as configurações. O $MBL_{Calib. \text{ mensal}}$ resultou em uma superestimação sistemática da proporção de horas, enquanto o $MBL_{Calib. \text{ anual}}$ apresentou desempenho mais equilibrado, com erros substancialmente menores. Em escala anual, o $MBL_{Calib. \text{ anual}}$ se destacou com $MAE = 0,014$ e $MAPE = 1,6\%$, frente a $0,045$ e $5,0\%$ no $MBL_{Calib. \text{ mensal}}$.

Na estação A868 (Itajaí/SC), ambos os esquemas de calibração reproduziram de forma satisfatória a intermitência, mas novamente o $MBL_{Calib. \text{ anual}}$ mostrou resultados mais consistentes, com erros mensais ($MAE = 0,032$; $MAPE = 3,7\%$) e

anuais (MAE = 0,029; MAPE = 3,3%) inferiores aos do $MBL_{Calib. \text{ mensal}}$ (MAE = 0,053; MAPE = 6,0%).

De modo geral, os resultados indicam que o Bartlett-Lewis é capaz de representar de forma adequada a proporção de horas secas, independentemente da estação. Contudo, há uma tendência clara de o $MBL_{Calib. \text{ anual}}$ apresentar desempenho superior ao $MBL_{Calib. \text{ mensal}}$, principalmente em Vacaria e Itajaí, onde este último levou a uma superestimação sistemática da métrica. Assim, ao contrário do que foi observado para a variância, a intermitência mostrou-se uma característica mais bem capturada pelo modelo quando adotada a calibração anual. Apesar de os erros associados à métrica serem relativamente baixos, observa-se que o modelo, em todas as configurações, tende a superestimar a proporção de horas secas, o que indica uma tendência do modelo em ampliar a duração dos períodos secos e, conseqüentemente, reduzir a frequência de ocorrência de horas com chuva.

4.1.2.3 Autocorrelação

Na TABELA 12, encontram-se os resultados mensais e anuais observados da autocorrelação (lag-1), bem como a mediana das 100 simulações geradas em cada configuração, abrangendo as três estações avaliadas (A871, A880 e A868). Por sua vez, a TABELA 13 consolida os erros médios calculados em escala mensal – obtidos pela média dos erros individuais de cada mês – quanto os erros anuais, estes determinados por meio da comparação direta entre os valores anuais observados e as 100 simulações correspondentes para cada configuração.

TABELA 12 – MODELO BARTLETT-LEWIS – AUTOCORRELAÇÃO – ESTAÇÕES A871, A880 E A868

Descrição	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Anual	Estação
Obs	0,226	0,364	0,197	0,176	0,533	0,367	0,640	0,043	0,215	0,143	0,313	0,425	0,300	A871 – Japira/PR
MBL _{Calib. mensal}	0,788	0,692	0,765	0,425	0,614	0,767	0,661	0,304	0,535	0,519	0,835	0,803	0,727	
MBL _{Calib. anual}	0,815	0,762	0,748	0,602	0,701	0,850	0,751	0,264	0,647	0,471	0,864	0,813	0,784	
Obs	0,178	0,296	0,233	0,441	0,646	0,379	0,392	0,673	0,637	0,436	0,209	0,393	0,363	A880 – Vacaria/RS
MBL _{Calib. mensal}	0,590	0,505	0,548	0,498	0,691	0,460	0,541	0,506	0,575	0,614	0,663	0,556	0,573	
MBL _{Calib. anual}	0,781	0,749	0,765	0,756	0,853	0,750	0,803	0,776	0,748	0,786	0,846	0,746	0,786	
Obs	0,573	0,370	0,293	0,589	0,351	0,788	0,140	0,321	0,453	0,164	0,549	0,289	0,431	A868 – Itajaí/SC
MBL _{Calib. mensal}	0,229	0,716	0,697	0,611	0,601	0,745	0,450	0,297	0,649	0,400	0,540	0,535	0,501	
MBL _{Calib. anual}	0,776	0,783	0,758	0,783	0,780	0,830	0,698	0,413	0,835	0,628	0,750	0,751	0,755	

FONTE: A autora (2025).

TABELA 13 – MODELO BARTLETT-LEWIS – ERROS MÉDIOS MENSAIS E ERROS ANUAIS NA REPRODUÇÃO DA AUTOCORRELAÇÃO – ESTAÇÕES A871, A880 E A868

Descrição	Erro Médio Mensal			Erro Anual			Estação
	MAE	MAPE	MSE	MAE	MAPE	MSE	
MBL _{Calib. mensal}	0,344	182%	0,15	0,425	142%	0,181	A871 – Japira/PR
MBL _{Calib. anual}	0,387	197%	0,18	0,482	160%	0,232	
MBL _{Calib. mensal}	0,199	72,2%	0,06	0,209	57,5%	0,044	A880 – Vacaria/RS
MBL _{Calib. anual}	0,366	127%	0,16	0,422	116%	0,178	
MBL _{Calib. mensal}	0,213	74,7%	0,06	0,072	16,8%	0,007	A868 – Itajaí/SC
MBL _{Calib. anual}	0,325	121%	0,13	0,324	75,3%	0,105	

FONTE: A autora (2025).

Na estação A871, o MBL, apresentou uma superestimação sistemática da autocorrelação em ambas as configurações. Tanto o $MBL_{Calib. \text{ mensal}}$ quanto o $MBL_{Calib. \text{ anual}}$ produziram valores muito mais altos do que os observados em praticamente todos os meses (FIGURA 33). Por exemplo, em agosto, o observado foi de 0,043, enquanto o $MBL_{Calib. \text{ mensal}}$ estimou 0,304 e o $MBL_{Calib. \text{ anual}}$ 0,264; em novembro, a diferença foi ainda mais acentuada, com 0,313 observado contra 0,835 ($MBL_{Calib. \text{ mensal}}$) e 0,864 ($MBL_{Calib. \text{ anual}}$). Isso mostra que o modelo gerou séries mais persistentes do que a realidade local, reduzindo a aleatoriedade típica da precipitação horária na região. Em escala anual, também pode ser verificada essa mesma tendência de superestimação da variável (FIGURA 34).

A análise dos erros evidencia esse desajuste. Em escala mensal, o $MBL_{Calib. \text{ mensal}}$ apresentou erros ligeiramente menores ($MAE = 0,344$; $RMSE = 0,356$) do que o $MBL_{Calib. \text{ anual}}$ ($MAE = 0,387$; $RMSE = 0,398$), embora ambos com $MAPE$ extremamente elevados (182% e 197%, respectivamente), confirmando a magnitude das distorções. Em escala anual, os resultados seguiram a mesma tendência, com melhor desempenho relativo do $MBL_{Calib. \text{ mensal}}$ ($MAE = 0,425$) frente ao $MBL_{Calib. \text{ anual}}$ ($MAE = 0,482$), mas ainda com erros muito altos ($MAPE$ superiores a 140%).

FIGURA 33 – MBL – AUTOCORRELAÇÃO MENSAL – ESTAÇÃO A871 (JAPIRA/PR)





FIGURA 34 – MBL – AUTOCORRELAÇÃO ANUAL – ESTAÇÃO A871 (JAPIRA/PR)



Na estação A880, os valores observados de autocorrelação lag-1 variaram de 0,178 em janeiro a 0,673 em agosto, com média anual de 0,363. Esse comportamento indica que a persistência da precipitação horária é sazonal: mais baixa no verão (chuvas convectivas curtas e isoladas) e mais alta no inverno (eventos mais contínuos e duradouros).

O modelo apresentou desempenho distinto entre as configurações. O $MBL_{Calib. \text{ mensal}}$ acompanhou parcialmente a sazonalidade, mas de forma sistematicamente superestimada. Em meses de baixa persistência, como janeiro (0,178 observado), os valores simulados foram substancialmente maiores (0,590), enquanto em meses de alta persistência, como agosto (0,673 observado), os valores se mantiveram mais próximos (0,506). Apesar das diferenças, o $MBL_{Calib. \text{ mensal}}$ conseguiu manter a variação ao longo do ano, ainda que com magnitude inflada. O $MBL_{Calib. \text{ anual}}$, por outro lado, apresentou superestimações ainda mais acentuadas, com valores muito elevados em todos os meses (sempre acima de 0,74) e pouca variação sazonal. Isso resultou em séries com persistência artificialmente elevada e menos sensíveis à dinâmica climática local.

Os erros reforçam essa leitura. Em escala mensal (FIGURA 35), o $MBL_{Calib. \text{ mensal}}$ apresentou desempenho claramente superior (MAE = 0,199; RMSE = 0,215) em relação ao $MBL_{Calib. \text{ anual}}$ (MAE = 0,366; RMSE = 0,370). Em escala anual (FIGURA 36), a diferença se manteve: MAE = 0,209 no $MBL_{Calib. \text{ mensal}}$ contra 0,422 no $MBL_{Calib. \text{ anual}}$.

anual, com erros relativos muito elevados em ambas as configurações (MAPE de 57,5% e 116%, respectivamente).

FIGURA 35 – MBL – AUTOCORRELAÇÃO MENSAL – ESTAÇÃO A880 (VACARIA/RS)





FIGURA 36 – MBL – AUTOCORRELAÇÃO ANUAL – ESTAÇÃO A880 (VACARIA/RS)



Para a estação A868, o modelo apresentou desempenhos distintos nas duas configurações. Em escala mensal (FIGURA 37), o $MBL_{Calib. \text{ mensal}}$ mostrou resultados heterogêneos: em alguns meses aproximou-se do observado, como em novembro (0,540 simulado contra 0,549 observado), mas em outros apresentou superestimações significativas, como em março (0,697 contra 0,293). Ainda assim,

conseguiu refletir parte da variabilidade sazonal, ainda que com magnitudes infladas. O $MBL_{Calib. \text{ anual}}$, por sua vez, resultou em superestimação generalizada e persistente, com valores sempre elevados e pouca sensibilidade às oscilações mensais. Assim, gerou séries excessivamente persistentes e pouco representativas do comportamento real da estação. Situação que também pode ser observada em escala anual (FIGURA 38).

FIGURA 37 – MBL – AUTOCORRELAÇÃO MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)





FIGURA 38 – MBL – AUTOCORRELAÇÃO ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC)



Os erros confirmam esse contraste. Em escala mensal, o $MBL_{Calib. \text{ mensal}}$ foi mais adequado ($MAE = 0,213$; $RMSE = 0,228$) em relação ao $MBL_{Calib. \text{ anual}}$ ($MAE = 0,325$; $RMSE = 0,331$), ainda que ambos apresentem erros relativos elevados ($MAPE$ de 74,7% e 121%). Em escala anual, o $MBL_{Calib. \text{ mensal}}$ mostrou desempenho expressivo ($MAE = 0,072$; $MAPE = 16,8\%$), enquanto o $MBL_{Calib. \text{ anual}}$ manteve superestimações fortes, com $MAE = 0,324$ e $MAPE = 75,3\%$.

De modo geral, a análise da autocorrelação lag-1 evidenciou uma limitação sistemática do modelo de Bartlett-Lewis Modificado em representar a persistência da precipitação horária nas três estações avaliadas. Em todas elas, verificou-se tendência consistente de superestimação, resultando em séries mais persistentes do que as observadas, o que reduz a aleatoriedade característica das chuvas em escala horária.

Entre as configurações testadas, a calibração mensal apresentou desempenho relativamente superior à calibração anual, pois conseguiu, em certa medida, refletir a variabilidade sazonal. Isso foi particularmente evidente nas estações A880 e A868, nas quais o $MBL_{Calib. \text{ mensal}}$ acompanhou a variação intra-anual da persistência, ainda que com magnitudes infladas. Já a calibração anual mostrou-se mais rígida, com valores invariavelmente elevados e pouca sensibilidade às oscilações mensais.

Os erros quantitativos reforçaram essa diferença, com MAE e $RMSE$ consistentemente menores para a calibração mensal. No entanto, os valores de $MAPE$ se mostraram muito elevados, frequentemente acima de 100%. É importante destacar, contudo, que a interpretação desses erros deve ser feita com cautela: como a autocorrelação varia em uma escala limitada, pequenas diferenças absolutas podem se traduzir em grandes erros relativos. Assim, embora os indicadores confirmem a tendência de superestimação, parte da magnitude dos erros está associada à própria natureza da métrica.

Em síntese, conclui-se que o MBL, mesmo em sua calibração mensal, apresenta limitações relevantes na reprodução da dependência temporal da precipitação horária no Sul do Brasil. A superestimação sistemática da autocorrelação compromete a simulação realista da aleatoriedade e da sazonalidade das chuvas, restringindo a aplicabilidade do modelo em análises que demandem a preservação fiel da estrutura temporal dos eventos.

4.1.2.4 Conclusão geral da análise das três métricas

A aplicação do modelo de Bartlett-Lewis Modificado nas três estações analisadas permitiu identificar padrões consistentes de desempenho, que variaram de acordo com a métrica considerada.

No caso da variância horária, o modelo apresentou limitação estrutural importante, marcada pela subestimação sistemática dos meses de maior variabilidade e pela tendência a suavizar o comportamento pluviométrico. Essa limitação foi observada em todas as estações, mas de forma mais evidente em Japira, onde os picos sazonais não foram adequadamente representados. Em Vacaria, o desempenho foi relativamente melhor, com o $MBL_{Calib. \text{ mensal}}$ aproximando-se do valor anual observado, enquanto o $MBL_{Calib. \text{ anual}}$ mostrou-se claramente insuficiente. De modo geral, o $MBL_{Calib. \text{ mensal}}$ foi superior, ainda que sem conseguir reproduzir a magnitude dos extremos mensais.

Quanto à proporção de horas secas, o modelo mostrou desempenho satisfatório em todas as estações, com valores simulados muito próximos dos observados. Nessa métrica, o $MBL_{Calib. \text{ anual}}$ apresentou resultados mais consistentes, porém em ambas as configurações os erros médios observados foram baixos, reforçando que a intermitência da precipitação foi adequadamente representada pelo modelo. Ainda assim, verificou-se superestimação sistemática da métrica, evidenciando a tendência do modelo em aumentar a duração dos períodos secos.

Em relação à autocorrelação lag-1, o modelo de Bartlett-Lewis Modificado apresentou os maiores desafios. Em todas as estações, verificou-se uma superestimação sistemática da persistência horária, com valores simulados muito acima dos observados. O $MBL_{Calib. \text{ mensal}}$, apesar de também superestimar, conseguiu preservar parte da variabilidade sazonal, enquanto o $MBL_{Calib. \text{ anual}}$ resultou em séries artificialmente persistentes, com valores excessivamente elevados e pouco sensíveis às flutuações mensais.

Em síntese, o modelo de Bartlett-Lewis Modificado apresentou desempenhos contrastantes entre as métricas. Enquanto a intermitência (proporção de horas secas) foi bem representada – sobretudo no $MBL_{Calib. \text{ anual}}$ –, a variância horária e a autocorrelação lag-1 evidenciaram limitações importantes, com destaque para a suavização dos extremos e a superestimação da persistência. O $MBL_{Calib. \text{ mensal}}$ mostrou-se geralmente mais eficiente para variância e autocorrelação, enquanto o

MBL_{Calib. anual} se destacou na proporção de horas secas. Esses resultados reforçam a necessidade de cautela na aplicação do modelo, pois seu desempenho é dependente da métrica analisada e da forma de calibração adotada.

4.1.3 Horário de Pico Diário

Os resultados obtidos para determinação do horário de pico diário, conforme procedimento descrito no item 3.5.3, são apresentados na TABELA 14.

TABELA 14 – MODELO BARTLETT-LEWIS – PADRÃO HORÁRIO DE OCORRÊNCIA DO PICO DIÁRIO – ESTAÇÕES A871, A880 E A868


Descrição	00 - 05h	06 - 11h	12 - 17h	18 - 23h	Estação
Observado	21,7%	19,1%	19,1%	40,0%	A871 – Japira/PR
MBL _{Calib. mensal}	21,8%	27,2%	25,6%	25,4%	
MBL _{Calib. anual}	22,2%	27,4%	26,7%	23,7%	
Observado	20,3%	27,5%	19,8%	32,4%	A880 – Vacaria/RS
MBL _{Calib. mensal}	23,2%	25,2%	24,5%	27,1%	
MBL _{Calib. anual}	23,0%	28,3%	26,6%	22,1%	
Observado	32,6%	31,6%	10,7%	25,1%	A868 – Itajai/SC
MBL _{Calib. mensal}	25,0%	24,0%	24,0%	27,0%	
MBL _{Calib. anual}	22,4%	26,2%	25,6%	25,8%	

Para a estação A871 (Japira/PR), na série observada, a distribuição dos horários de pico mostrou um padrão fortemente concentrado no período noturno (18-23h), que respondeu por 40% dos máximos diários. Os demais blocos apresentaram proporções relativamente próximas, variando entre 19,1% (manhã e tarde) e 21,7% (madrugada). Esse resultado indica que, em Japira, há uma clara tendência de ocorrência dos maiores volumes de precipitação no final do dia.

Nas séries simuladas, o MBL não conseguiu reproduzir esse padrão de concentração, conforme observado na FIGURA 39. Tanto no MBL_{Calib. mensal} quanto no MBL_{Calib. anual}, os resultados apresentaram uma redistribuição mais uniforme entre os blocos, com redução significativa da importância relativa do período noturno (25,4% e 23,7%, respectivamente). Em contrapartida, houve superestimação dos blocos da manhã (06-11h) e da tarde (12-17h), que chegaram a representar cerca de 27% cada nas simulações, frente a apenas 19,1% no observado.

Assim, em Japira, o modelo de Bartlett-Lewis Modificado resultou em uma perda do padrão preferencial de ocorrência dos picos no período noturno, produzindo

distribuições mais homogêneas e deslocando parte da frequência para o início e meio do dia. Entre as duas configurações, o MBL_{Calib. mensal} apresentou ligeiramente maior proximidade ao observado, ainda que com discrepâncias relevantes.




Na estação A880 (Vacaria/RS), a série observada apresentou predominância do período noturno (18-23h), que concentrou 32,4% dos picos diários de precipitação, seguido pelo período da manhã (06-11h, 27,5%). A madrugada (20,3%) e a tarde (19,8%) tiveram participação menos expressiva, reforçando um padrão em que os máximos tendem a ocorrer preferencialmente no final do dia e início da manhã.

Nas simulações, o MBL não conseguiu preservar essa concentração noturna, conforme apresentado na FIGURA 40. O MBL_{Calib. mensal} redistribuiu a frequência de forma mais homogênea entre os blocos, reduzindo a importância relativa do período 18-23h (27,1%) e ampliando as participações da madrugada (23,2%) e da tarde (24,5%). Já o MBL_{Calib. anual} apresentou desempenho ainda mais discrepante, subestimando fortemente o bloco noturno (22,1% contra 32,4% observado) e elevando o peso da manhã (28,3%) e da tarde (26,6%).

Em termos gerais, o MBL_{Calib. mensal} manteve um padrão mais equilibrado e relativamente mais próximo do observado, ainda que com perda da predominância noturna. O MBL_{Calib. anual}, por outro lado, mostrou distorções mais acentuadas,

reforçando a tendência de gerar distribuições artificiais mais uniformes e menos representativas do regime real da estação.




Na estação A868 (Itajaí/SC), o padrão observado mostrou predominância da madrugada (00-05h, 32,6%) e da manhã (06-11h, 31,6%), com menor representatividade no período noturno (25,1%) e baixa frequência na tarde (10,7%). Esse resultado indica uma distribuição intradiária relativamente bem definida, com maior concentração dos máximos entre a madrugada e a manhã.

As simulações do Bartlett-Lewis Modificado, contudo, não conseguiram reproduzir esse padrão concentrado. Tanto o MBL_{Calib. mensal} quanto o MBL_{Calib. anual} resultaram em uma redistribuição mais homogênea entre os blocos, reduzindo a importância relativa da madrugada e da manhã e inflando a frequência da tarde, que chegou a 24–26% nas simulações contra apenas 10,7% no observado. A noite também foi superestimada, embora em menor grau (FIGURA 41).

Conclui-se, portanto, que ambas as configurações resultaram em distorções acentuadas, com perda quase completa da diferença entre os blocos e uma distribuição excessivamente nivelada.

FIGURA 41 – MBL – HORÁRIO DE PICO – ESTAÇÃO A868 (ITAJAÍ/SC)



A análise do horário de pico diário evidenciou que o modelo Bartlett-Lewis Modificado apresentou limitações consistentes em todas as estações, caracterizadas principalmente pela tendência de suavizar os padrões observados e redistribuir a frequência de ocorrência entre os blocos horários.

Na estação A871 (Japira/PR), o padrão observado mostrou forte concentração no período noturno (40%), mas o modelo não conseguiu reproduzir essa predominância. Tanto o MBL_{Calib. mensal} quanto o MBL_{Calib. anual} reduziram a importância da noite para cerca de 25%, ao mesmo tempo em que superestimaram os períodos da manhã e da tarde. O MBL_{Calib. mensal} foi ligeiramente mais próximo, mas ainda distante da realidade observada.

Na estação A880 (Vacaria/RS), o observado indicou predominância do período noturno (32,4%) e secundariamente da manhã (27,5%). O MBL_{Calib. mensal} suavizou esse padrão, distribuindo de forma mais homogênea entre os blocos, enquanto o MBL_{Calib. anual} apresentou discrepâncias mais acentuadas, subestimando fortemente o noturno (22,1%) e inflando a manhã e à tarde.

Na estação A868 (Itajaí/SC), o padrão observado apresentou concentração bem definida na madrugada (32,6%) e manhã (31,6%), com baixa representatividade da tarde (10,7%). O MBL, porém, não preservou esse contraste: tanto o MBL_{Calib. mensal}

quanto o $MBL_{Calib. \text{ anual}}$ redistribuíram a frequência, reduzindo a importância dos blocos da madrugada e manhã e superestimando a tarde.

De forma geral, os resultados indicam que o Bartlett-Lewis Modificado, independentemente da configuração, não foi capaz de reproduzir adequadamente os padrões observados de horário de pico diário, apresentando distribuições excessivamente uniformizadas e perda das concentrações características de cada estação. O $MBL_{Calib. \text{ mensal}}$ mostrou desempenho relativamente superior ao $MBL_{Calib. \text{ anual}}$, mas ambos demonstraram limitações importantes, sobretudo na representação de regimes com concentrações marcadas em determinados blocos horários.

4.1.4 Chuva Horária Máxima Diária

Os valores observados e as medianas das 100 simulações para cada estatística, discriminados por estação e configuração, estão apresentados na TABELA 15. As curvas de permanência resultantes encontram-se na FIGURA 42, FIGURA 43 e FIGURA 44, que contemplam as duas configurações do modelo em cada estação avaliada.

TABELA 15 – MODELO BARTLETT-LEWIS – ESTATÍSTICAS DA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÕES A871, A880 E A868

Descrição	Méd.	Md.	D. Padrão	Quantil 90%	Quantil 95%	Quantil 99%	Máx.	Estação
Observado	5,82	2,60	8,25	15,0	19,6	40,4	54,4	A871 – Japira/PR
$MBL_{Calib. \text{ mensal}}$	3,53	2,54	3,24	8,1	9,7	12,5	14,4	
$MBL_{Calib. \text{ anual}}$	2,82	2,21	2,43	6,1	7,4	9,5	11,1	
Observado	4,33	2,10	5,83	10,7	15,9	28,6	30,2	A880 – Vacaria/RS
$MBL_{Calib. \text{ mensal}}$	4,44	2,50	4,94	11,4	14,2	18,7	22,2	
$MBL_{Calib. \text{ anual}}$	2,46	1,69	2,40	5,8	7,0	9,1	10,8	
Observado	3,10	1,00	4,95	9,0	12,8	21,1	31,8	A868 – Itajaí/SC
$MBL_{Calib. \text{ mensal}}$	3,41	1,39	4,53	9,4	12,1	17,9	28,7	
$MBL_{Calib. \text{ anual}}$	2,14	1,19	2,31	5,5	6,7	9,1	11,2	


Na estação A871 (Japira/PR), os valores observados de máximas horárias diárias apresentaram média de 5,82 mm, com desvio padrão elevado (8,25 mm) e valores extremos expressivos, incluindo um máximo de 54,4 mm. Os quantis superiores também foram altos (quantil 95% = 19,6 mm; quantil 99% = 40,4 mm),

refletindo a ocorrência de eventos intensos de curta duração característicos dessa localidade.

O modelo de Bartlett-Lewis Modificado, entretanto, mostrou desempenho limitado na reprodução desses extremos. No $MBL_{Calib. \text{ mensal}}$, as estatísticas descritivas apresentaram valores sistematicamente inferiores ao observado: média de 3,53 mm, quantil 95% de 9,7 mm e máximo de apenas 14,4 mm. Embora a mediana (2,54 mm) tenha ficado próxima da observada (2,60 mm), a amplitude dos valores foi muito reduzida, com forte subestimação dos quantis mais altos. O $MBL_{Calib. \text{ anual}}$ reforçou essa tendência de subestimação, apresentando valores ainda menores: média de 2,82 mm, quantil 95% de 7,4 mm e máximo de 11,1 mm, confirmando a dificuldade da calibração única em representar a variabilidade extrema.

As curvas de permanência ilustram claramente esse comportamento (FIGURA 42): tanto no $MBL_{Calib. \text{ mensal}}$ quanto no $MBL_{Calib. \text{ anual}}$, a curva simulada ficou consistentemente abaixo da observada em toda a faixa de permanência, com maior divergência nos eventos mais raros (baixa permanência). O $MBL_{Calib. \text{ mensal}}$ aproximou-se um pouco mais da distribuição empírica, sobretudo nos valores medianos, mas nenhuma das duas configurações foi capaz de representar adequadamente os eventos mais intensos.


FIGURA 42 – MBL – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A871 (JAPIRA/PR)



Na estação A880, a série observada apresentou média de 4,33 mm, desvio padrão de 5,83 mm e valor máximo de 30,2 mm. Os quantis superiores também foram expressivos (quantil 95% = 15,9 mm; quantil 99% = 28,6 mm), indicando a ocorrência de eventos intensos de curta duração.

O desempenho do MBL variou de forma marcante entre as duas configurações. O MBL_{Calib. mensal} apresentou boa aderência às estatísticas observadas, reproduzindo adequadamente a média (4,44 mm contra 4,33 mm) e os quantis superiores, ainda que com subestimação moderada dos valores extremos (quantil 99% = 18,7 mm e máximo de 22,2 mm frente a 28,6 mm e 30,2 mm observados). Já o MBL_{Calib. anual} resultou em forte subestimação em todos os indicadores, com média reduzida (2,46 mm), quantil 95% de apenas 7,0 mm e máximo de 10,8 mm, valores muito inferiores aos registrados.

FIGURA 43 – MBL – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A880 (VACARIA/RS)



As curvas de permanência reforçam esse contraste (FIGURA 43). O MBL_{Calib. mensal} manteve boa proximidade da curva observada em grande parte da distribuição, especialmente nas chuvas mais frequentes (permanência acima de 25%). Apesar de ainda subestimar os eventos mais raros, conseguiu representar de forma razoável a tendência central e a dispersão dos extremos. O MBL_{Calib. anual}, por outro lado, apresentou curva sistematicamente abaixo da observada em toda a faixa de permanência, com divergência crescente nas permanências mais baixas,


evidenciando sua limitação estrutural em reproduzir a intensidade dos eventos máximos.

Na estação A868, a série observada apresentou média de 3,10 mm e desvio padrão de 4,95 mm, com máximos diários atingindo 31,8 mm e quantis elevados (quantil 95% = 12,8 mm; quantil 99% = 21,1 mm). Esse padrão indica a presença de eventos intensos, ainda que relativamente menos frequentes.

O MBL_{Calib. mensal} mostrou desempenho razoável, reproduzindo adequadamente a média (3,41 mm contra 3,10 mm) e valores próximos aos quantis superiores, ainda que com subestimação dos extremos mais raros (quantil 99% = 17,9 mm e máximo de 28,7 mm). Em termos centrais, a mediana (1,39 mm) foi ligeiramente superior à observada (1,00 mm), mas dentro de uma faixa aceitável.

Já o MBL_{Calib. anual} apresentou forte subestimação em toda a distribuição, com média de 2,14 mm, quantil 95% de apenas 6,7 mm e máximo de 11,2 mm, muito aquém dos 31,8 mm observados. Esse viés negativo reduziu significativamente a representatividade do modelo para eventos extremos.

FIGURA 44 – MBL – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A868 (ITAJAÍ/SC)



As curvas de permanência reforçam esse contraste (FIGURA 44): o MBL_{Calib. mensal} mostrou boa aderência à curva observada em grande parte da distribuição, especialmente nas chuvas mais frequentes (permanências médias e altas), embora ainda subestime os maiores eventos. O MBL_{Calib. anual}, por outro lado, apresentou curva

sistematicamente abaixo da observada, com divergência marcante nas permanências mais baixas, evidenciando baixa capacidade de representar as intensidades extremas.

A análise das chuvas máximas horárias diárias mostrou que o modelo Bartlett-Lewis apresentou limitações consistentes na representação dos extremos, ainda que com diferenças relevantes entre as estações e configurações.

Na estação A871 (Japira/PR), o modelo conseguiu reproduzir adequadamente os valores centrais da distribuição (mediana próxima ao observado), mas subestimou fortemente os quantis superiores e o máximo absoluto. Tanto o $MBL_{Calib. \text{ mensal}}$ quanto o $MBL_{Calib. \text{ anual}}$ resultaram em curvas de permanência abaixo da observada, com destaque para o $MBL_{Calib. \text{ mensal}}$, que foi relativamente mais próximo, embora ainda insuficiente para capturar os eventos mais raros.

Na estação A880 (Vacaria/RS), o desempenho foi mais favorável ao $MBL_{Calib. \text{ mensal}}$. Essa configuração conseguiu representar bem a média (4,44 mm contra 4,33 mm) e parte dos quantis superiores (quantil 95% = 14,2 mm contra 15,9 mm), embora ainda com subestimação do máximo (22,2 mm contra 30,2 mm). O $MBL_{Calib. \text{ anual}}$, por sua vez, resultou em forte subestimação em toda a distribuição, com máximos muito inferiores ao observado, revelando baixa representatividade para os extremos nesta localidade.

Na estação A868 (Itajaí/SC), o $MBL_{Calib. \text{ mensal}}$ também se mostrou mais adequado, aproximando-se dos valores médios e dos quantis superiores, ainda que com subestimação dos eventos mais raros (quantil 99% = 17,9 mm contra 21,1 mm observado). O $MBL_{Calib. \text{ anual}}$, novamente, subestimou toda a distribuição, com valores bastante reduzidos (máximo de 11,2 mm contra 31,8 mm observado).

De forma geral, os resultados indicam que o modelo de Bartlett-Lewis Modificado não conseguiu reproduzir adequadamente a magnitude dos eventos extremos, subestimando de forma recorrente as chuvas máximas diárias em todas as estações. O $MBL_{Calib. \text{ mensal}}$ apresentou desempenho consistentemente superior ao $MBL_{Calib. \text{ anual}}$, conseguindo preservar melhor a média e os quantis intermediários, mas ainda com limitações na representação dos extremos mais raros. O $MBL_{Calib. \text{ anual}}$ mostrou desempenho insatisfatório, com curvas de permanência sistematicamente abaixo da observada e incapacidade de capturar a intensidade real dos eventos máximos.

4.1.5 Conclusões Gerais Modelo Bartlett-Lewis Modificado

A aplicação do modelo Bartlett-Lewis Modificado nas três estações analisadas evidenciou um desempenho heterogêneo entre as métricas, com alguns avanços na representação da precipitação horária, mas também limitações estruturais importantes.

No caso da variância horária, o modelo apresentou desempenho insatisfatório, marcado pela suavização dos valores observados. Japira, mês de maior variabilidade, foi sistematicamente subestimada, enquanto em Vacaria o $MBL_{Calib. \text{ mensal}}$ conseguiu aproximar-se do valor anual observado, embora ainda com discrepâncias nos extremos mensais. De forma geral, o $MBL_{Calib. \text{ mensal}}$ mostrou-se superior ao $MBL_{Calib. \text{ anual}}$, preservando melhor a sazonalidade, mas sem reproduzir adequadamente a magnitude dos picos.

A proporção de horas secas foi a métrica de melhor desempenho do Bartlett-Lewis Modificado. Em todas as estações, os valores simulados se aproximaram bastante dos observados, com erros baixos tanto em escala mensal quanto anual. Neste caso, o $MBL_{Calib. \text{ anual}}$ destacou-se como a configuração mais precisa, sobretudo em Vacaria e Itajaí. Entretanto, mesmo com bons resultados, destaca-se que de modo geral o modelo tendeu a superestimar a proporção de horas secas.

A autocorrelação lag-1 representou o maior desafio. Em todas as estações, o modelo resultou em uma superestimação sistemática da persistência horária, com valores simulados muito acima dos observados. O $MBL_{Calib. \text{ mensal}}$ foi relativamente mais adequado, por preservar parte da variabilidade sazonal, mas ainda apresentou erros elevados. O $MBL_{Calib. \text{ anual}}$, por sua vez, produziu séries excessivamente persistentes e pouco representativas da realidade, evidenciando uma limitação estrutural do modelo nessa métrica.

Na análise do horário de pico diário, o modelo de Bartlett-Lewis Modificado também apresentou dificuldades. Em Japira, a forte concentração noturna observada foi redistribuída de forma quase uniforme nas simulações. Em Vacaria, a predominância noturna foi subestimada, enquanto em Itajaí o modelo não conseguiu reproduzir a concentração matinal e da madrugada, inflando artificialmente o período da tarde. Em todos os casos, o resultado foi uma suavização dos padrões intradiários

observados, com o $MBL_{Calib. \text{ mensal}}$ novamente apresentando desempenho relativamente melhor que o $MBL_{Calib. \text{ anual}}$.

Por fim, na avaliação das chuvas máximas horárias diárias, o MBL mostrou-se incapaz de reproduzir a magnitude dos eventos extremos. Em todas as estações, houve subestimação dos valores máximos e dos quantis superiores, ainda que o $MBL_{Calib. \text{ mensal}}$ tenha apresentado maior proximidade da distribuição observada, especialmente em Vacaria e Itajaí. O $MBL_{Calib. \text{ anual}}$, em contrapartida, apresentou desempenho insatisfatório, com valores muito reduzidos e curvas de permanência sistematicamente abaixo da observada.

Em síntese, os resultados indicam que o modelo de Bartlet-Lewis Modificado apresenta desempenho contrastante entre métricas. Enquanto a intermitência da precipitação (proporção de horas secas) foi representada de forma satisfatória – sobretudo pelo $MBL_{Calib. \text{ anual}}$ –, a variância, a autocorrelação, o horário de pico e as chuvas máximas diárias revelaram limitações estruturais do modelo. O $MBL_{Calib. \text{ mensal}}$ mostrou-se globalmente mais adequado, preservando em maior medida a sazonalidade e os padrões locais, mas ainda sem conseguir representar de forma realista os padrões observados.

4.2 MÉTODO DOS FRAGMENTOS

4.2.1 Estatísticas de Validação Padrão

4.2.1.1 Variância

Na TABELA 16, apresentam-se os valores mensais observados da variância, bem como a mediana das 100 séries simuladas em cada configuração, para as três estações analisadas (A871, A880 e A868), considerando as seis combinações dos parâmetros l e k . De modo geral, observa-se que a variância mensal é melhor representada nos meses em que os valores observados foram mais baixos. Esse comportamento sugere que o modelo apresenta maior capacidade de replicar padrões de chuva menos complexos ou menos intensos, enquanto encontra dificuldades em capturar adequadamente a variabilidade de meses com eventos mais expressivos.

Complementarmente, a TABELA 17 exhibe os erros médios mensais –obtidos a partir da média dos erros individuais calculados para cada mês – e os erros anuais,

estes estimados diretamente pela comparação entre as 100 simulações anuais geradas e os valores anuais observados.

TABELA 16 – MÉTODO DOS FRAGMENTOS – VARIÂNCIA – ESTAÇÕES A871, A880 E A868

Descrição	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Anual	Estação
Obs	7,201	1,587	0,779	0,391	0,343	0,808	0,167	0,031	0,516	0,123	5,164	2,328	1,628	A871 – Japira/PR
MOF _{L15,K5}	3,277	1,844	0,565	0,244	0,459	0,765	0,293	0,014	0,380	0,086	5,267	4,214	1,536	
MOF _{L15,K10}	3,635	1,946	0,598	0,257	0,485	0,845	0,320	0,014	0,455	0,087	5,633	3,977	1,586	
MOF _{L15,K15}	4,014	1,944	0,626	0,256	0,524	0,905	0,307	0,014	0,435	0,086	6,382	4,115	1,703	
MOF _{L30,K5}	3,467	1,589	0,558	0,256	0,355	1,115	0,288	0,013	0,280	0,080	4,710	3,948	1,459	
MOF _{L30,K10}	4,624	1,619	0,549	0,301	0,376	0,886	0,287	0,013	0,325	0,081	4,682	3,616	1,509	
MOF _{L30,K15}	4,938	1,773	0,574	0,320	0,398	1,066	0,288	0,013	0,372	0,080	4,875	3,816	1,565	
Obs	2,944	0,864	1,853	0,585	2,765	0,227	0,734	0,366	0,282	2,313	3,577	0,920	1,469	A880 – Vacaria/RS
MOF _{L15,K5}	2,804	1,235	1,694	1,430	2,305	0,373	0,761	0,629	0,391	2,251	2,529	1,020	1,508	
MOF _{L15,K10}	2,709	1,398	1,694	1,365	2,385	0,368	0,766	0,607	0,392	2,555	2,988	0,949	1,587	
MOF _{L15,K15}	2,690	1,506	1,683	1,402	2,429	0,440	0,799	0,624	0,487	2,752	3,019	0,999	1,660	
MOF _{L30,K5}	2,182	1,183	1,324	1,163	2,050	0,251	0,742	0,417	0,478	2,048	2,457	0,880	1,301	
MOF _{L30,K10}	2,258	1,222	1,537	1,107	2,081	0,283	0,808	0,541	0,518	2,314	2,591	0,925	1,395	
MOF _{L30,K15}	2,091	1,280	1,461	1,093	2,192	0,310	0,817	0,556	0,484	2,291	2,657	0,972	1,430	
Obs	4,217	3,637	1,301	0,705	1,239	0,268	0,558	0,065	0,700	0,849	0,934	0,777	1,266	A868 – Itajai/SC
MOF _{L15,K5}	5,976	7,838	1,325	1,008	1,196	0,395	0,304	0,097	1,309	0,492	1,693	1,439	1,905	
MOF _{L15,K10}	5,930	8,192	1,266	1,114	1,353	0,392	0,391	0,098	1,267	0,542	1,728	1,183	2,118	
MOF _{L15,K15}	5,977	8,170	1,407	1,182	1,431	0,400	0,465	0,104	1,319	0,525	1,817	1,128	2,033	
MOF _{L30,K5}	5,775	8,272	1,266	0,992	1,224	0,394	0,331	0,056	0,805	0,406	1,710	0,837	1,873	
MOF _{L30,K10}	5,653	7,812	1,329	1,107	1,260	0,394	0,339	0,072	0,848	0,465	1,673	0,867	1,859	
MOF _{L30,K15}	5,772	7,759	1,291	1,106	1,266	0,403	0,449	0,083	1,119	0,478	1,647	0,796	1,852	


FONTE: A autora (2025).

TABELA 17 – MÉTODO DOS FRAGMENTOS – ERROS MÉDIOS MENSALIS E ERROS ANUAIS NA REPRODUÇÃO DA VARIÂNCIA – ESTAÇÕES A871, A880 E A868

Descrição	Erro Médio Mensal			Erro Anual			Estação	
	MAE	MAPE	MSE	RMSE	MAE	MAPE		MSE
MOFL15,K5	0,621	40,1%	1,574	0,720	0,160	9,8%	0,035	0,188
MOFL15,K10	0,630	44,5%	1,516	0,739	0,146	9,0%	0,033	0,183
MOFL15,K15	0,644	47,0%	1,477	0,763	0,191	11,7%	0,056	0,237
MOFL30,K5	0,593	41,3%	1,417	0,681	0,188	11,5%	0,051	0,226
MOFL30,K10	0,555	39,1%	1,259	0,663	0,195	12,0%	0,059	0,243
MOFL30,K15	0,549	39,8%	1,172	0,665	0,192	11,8%	0,056	0,236
MOFL15,K5	0,420	49,2%	0,314	0,502	0,084	5,7%	0,011	0,105
MOFL15,K10	0,451	50,5%	0,383	0,562	0,161	11,0%	0,046	0,213
MOFL15,K15	0,506	58,5%	0,469	0,625	0,207	14,1%	0,061	0,247
MOFL30,K5	0,435	38,0%	0,332	0,488	0,163	11,1%	0,032	0,179
MOFL30,K10	0,438	43,7%	0,329	0,518	0,099	6,7%	0,014	0,119
MOFL30,K15	0,450	46,0%	0,346	0,538	0,099	6,8%	0,016	0,125
MOFL15,K5	0,834	56,1%	2,567	0,965	0,672	53,1%	0,489	0,699
MOFL15,K10	0,949	62,4%	3,483	1,120	0,798	63,0%	0,698	0,835
MOFL15,K15	1,030	68,9%	4,361	1,254	0,898	70,9%	0,902	0,950
MOFL30,K5	0,809	55,1%	2,374	0,913	0,611	48,2%	0,399	0,632
MOFL30,K10	0,794	56,5%	2,317	0,930	0,608	48,1%	0,407	0,638
MOFL30,K15	0,788	56,0%	2,245	0,926	0,617	48,8%	0,419	0,647

A FIGURA 45 apresenta a distribuição mensal da variância horária simulada e observada para a estação A871, evidenciando diferenças relevantes entre as configurações de parâmetros. Verifica-se que, embora os valores simulados se aproximem da observação em alguns meses, há uma tendência considerável à subestimativa no mês de janeiro e à superestimativa em dezembro. Além disso, os valores de MAE situaram-se entre 0,549 e 0,644, enquanto o MAPE variou de aproximadamente 39% a 47%, indicando que a variância simulada apresenta desvios expressivos em relação ao observado. Observou-se que, para l de 15 dias, o aumento de k implicou no agravamento dos erros, com destaque para a configuração $MOF_{L15,K15}$, que apresentou os maiores valores de MAPE (47,0%) e MAE (0,644). Em contraste, para l de 30 dias, verificou-se tendência oposta: o incremento de k resultou em redução dos erros, culminando na configuração $MOF_{L30,K15}$ como a mais estável, com o menor valor de MAE (0,549). De modo geral, o desempenho obtido com l de 30 dias mostrou-se mais consistente, sugerindo que a utilização de uma janela temporal mais ampla favorece a preservação da variabilidade mensal da precipitação horária simulada.


FIGURA 45 – MOF – VARIÂNCIA MENSAL – ESTAÇÃO A871 (JAPIRA/PR)



Por outro lado, ao se considerar a variância horária em escala anual (FIGURA 46), os erros de variância foram relativamente baixos, com MAE entre 0,146 e 0,195 e MAPE variando de 9% a 12%; e com melhor desempenho das simulações associadas à configuração com janela l de 15. A configuração $MOF_{L15,K10}$ destacou-

se apresentando o melhor desempenho global, com os menores erros (MAE = 0,146; MAPE = 9,0%; MSE = 0,033; RMSE = 0,183). De forma geral, os resultados indicam que, na escala anual, o modelo conseguiu preservar a variabilidade da precipitação horária com boa aproximação, sem diferenças acentuadas entre as configurações testadas.

FIGURA 46 – MOF – VARIÂNCIA ANUAL – ESTAÇÃO A871 (JAPIRA/PR)



Na estação A880 (Vacaria/RS), os erros associados à variância mensal mostraram-se mais elevados do que os verificados em Japira, especialmente em termos de MAPE, que alcançou valores entre 38,0% e 58,5%. Tanto para l de 15 dias como para de 30 dias, o desempenho piorou progressivamente com o aumento de k , sendo a configuração $\text{MOF}_{L15,K15}$ a de menor aderência (MAE = 0,506; MAPE = 58,5%). Entre todas as configurações, os melhores desempenhos ocorreram com $\text{MOF}_{L30,K5}$, que apresentou o menor MAPE (38,0%), e $\text{MOF}_{L15,K5}$ que apresentou menor MAE (0,420). Em síntese, os resultados de Vacaria evidenciam maior dificuldade do modelo em reproduzir a variabilidade mensal (FIGURA 47), destacando-se que o aumento de k foi prejudicial e l de 30 dias garantiu maior estabilidade dos erros, ainda que sem ganhos expressivos de ajuste.

Na escala anual (FIGURA 48), os erros de variância em Vacaria apresentaram valores baixos, com MAE variando de 0,084 a 0,207 e MAPE entre 5,7% e 14,1%. O melhor ajuste foi obtido na configuração $\text{MOF}_{L15,K5}$, que apresentou os menores erros globais (MAE = 0,084; MAPE = 5,7%; RMSE = 0,105). Assim como na escala mensal,

o desempenho se deteriorou com o aumento de k para l de 15 dias, entretanto, melhorou para l de 30 dias, com as configurações $MOF_{L30,K10}$ e $MOF_{L30,K15}$ também se destacando com baixos erros relativos ($MAPE \approx 6,7\%$). De forma geral, os resultados anuais em Vacaria indicam boa capacidade de preservação da variabilidade, com destaque para o melhor ajuste absoluto em $MOF_{L15,K5}$.

FIGURA 47 – MOF – VARIÂNCIA MENSAL – ESTAÇÃO A880 (VACARIA/RS)






FIGURA 48 – MOF – VARIÂNCIA ANUAL – ESTAÇÃO A880 (VACARIA/RS)



Por fim, a estação A868 (Itajaí/SC), situada no litoral de Santa Catarina, os erros de variância mensal foram os mais elevados entre as três estações analisadas, com MAE variando de 0,788 a 1,030 e MAPE entre 55,1% e 68,9%. Particularmente

nos meses de janeiro e fevereiro, as variâncias simuladas superaram substancialmente as observadas, indicando uma tendência do modelo em superestimar a dispersão intradiária nessas condições, conforme ilustrado na FIGURA 49. Para l de 15 dias, observou-se claro agravamento dos erros com o aumento de k , culminando em $\text{MOF}_{L15,K15}$, que apresentou o pior desempenho ($\text{MAE} = 1,030$; $\text{MAPE} = 68,9\%$; $\text{RMSE} = 1,254$). Em contrapartida, para l de 30 dias, os resultados mostraram maior estabilidade, com erros próximos entre si (MAE em torno de 0,79-0,81 e RMSE entre 0,913 e 0,926). Isso indica que, embora o modelo consiga reduzir os erros absolutos com uma janela mais ampla, ele ainda apresenta limitações significativas em reproduzir a variabilidade mensal observada em Itajaí.


FIGURA 49 – MOF – VARIÂNCIA MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)



A análise da variância anual (FIGURA 50) reflete essa mesma dificuldade, com os erros em Itajaí mantendo-se elevados em comparação às demais estações, mostrando a maior dificuldade do modelo em reproduzir a variabilidade da precipitação horária nesse local. O MAE variou entre 0,608 e 0,898, enquanto o MAPE apresentou valores expressivos, de 48,1% a 70,9%, evidenciando desvios significativos em relação ao observado. Para l de 15 dias, houve tendência de crescimento dos erros com o aumento de k , atingindo o pior desempenho em $\text{MOF}_{L15,K15}$ ($\text{MAE} = 0,898$; $\text{MAPE} = 70,9\%$; $\text{RMSE} = 0,950$). Já para l de 30 dias, os resultados foram mais estáveis, com destaque para $\text{MOF}_{L30,K10}$ como a melhor configuração ($\text{MAE} = 0,608$ e $\text{MAPE} = 48,1$), embora ainda com discrepâncias

consideráveis. De forma geral, os resultados anuais confirmam que, em Itajaí, mesmo a ampliação da janela para 30 dias não foi suficiente para reduzir os erros a níveis compatíveis com os encontrados nas demais estações, reforçando a maior complexidade dessa localidade quanto à preservação da variância da precipitação simulada.

FIGURA 50 – MOF – VARIÂNCIA ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC)



A avaliação da variância evidenciou diferenças marcantes entre as estações analisadas.

Em Japira, os resultados foram consistentes, com erros moderados na escala mensal (MAPE entre 39% e 47%) e bom desempenho na escala anual, em que os desvios permaneceram baixos (MAPE de 9% a 12%), destacando-se a configuração $MOF_{L15,K10}$.

Em Vacaria, verificou-se maior dificuldade na escala mensal, especialmente para l de 15 dias, em que o aumento de k ampliou os erros até um MAPE de 58,5%. Entretanto, na escala anual, os resultados foram notavelmente melhores, com valores reduzidos de erro (MAPE entre 5,7% e 14,1%), e desempenho superior em $MOF_{L15,K5}$, indicando que o modelo conseguiu preservar satisfatoriamente a variabilidade global da precipitação horária.

Por outro lado, em Itajaí observou-se a maior fragilidade do método, com erros expressivos tanto na escala mensal (MAPE de 55% a 69%) quanto na anual (48% a 71%), ainda que com maior estabilidade para l de 30 dias. De forma geral, constatou-

se que o aumento de k foi prejudicial em janelas de 15 dias em todas as estações para a análise mensal, enquanto l de 30 dias trouxe maior estabilidade também em escala mensal.

4.2.1.2 Proporção de Horas Secas

Na TABELA 18, são apresentados os valores mensais e anuais observados da proporção de horas secas, bem como a mediana das 100 séries simuladas em cada configuração, para as três estações analisadas (A871, A880 e A868), considerando as seis combinações dos parâmetros l e k . Já a TABELA 19, por sua vez, reúne os erros médios mensais – obtidos a partir da média dos erros individuais calculados para cada mês – e os erros anuais, estes estimados diretamente pela comparação entre as 100 simulações anuais geradas e os valores anuais observados.

TABELA 18 – MÉTODO DOS FRAGMENTOS – PROPORÇÃO DE HORAS SECAS – ESTAÇÕES A871, A880 E A868

Descrição	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Anual	Estação
Obs	0,935	0,917	0,958	0,951	0,950	0,953	0,953	0,993	0,933	0,970	0,921	0,903	0,945	A871 – Japira/PR
MOF _{L15,K5}	0,923	0,906	0,942	0,957	0,954	0,961	0,968	0,991	0,921	0,968	0,911	0,937	0,945	
MOF _{L15,K10}	0,923	0,910	0,947	0,957	0,956	0,963	0,972	0,991	0,929	0,966	0,917	0,938	0,948	
MOF _{L15,K15}	0,929	0,911	0,949	0,956	0,956	0,965	0,972	0,992	0,924	0,966	0,920	0,936	0,949	
MOF _{L30,K5}	0,917	0,902	0,939	0,958	0,946	0,958	0,970	0,988	0,910	0,969	0,904	0,930	0,941	
MOF _{L30,K10}	0,921	0,903	0,941	0,961	0,948	0,959	0,969	0,988	0,919	0,969	0,908	0,930	0,943	
MOF _{L30,K15}	0,923	0,909	0,944	0,961	0,950	0,961	0,970	0,989	0,923	0,968	0,913	0,932	0,945	
Obs	0,919	0,887	0,895	0,868	0,844	0,957	0,914	0,954	0,935	0,843	0,910	0,930	0,905	A880 – Vacaria/RS
MOF _{L15,K5}	0,918	0,917	0,919	0,904	0,802	0,961	0,913	0,961	0,942	0,845	0,913	0,953	0,912	
MOF _{L15,K10}	0,917	0,922	0,921	0,907	0,805	0,963	0,913	0,962	0,944	0,853	0,921	0,954	0,914	
MOF _{L15,K15}	0,919	0,926	0,924	0,908	0,811	0,964	0,913	0,962	0,947	0,856	0,922	0,956	0,917	
MOF _{L30,K5}	0,894	0,893	0,905	0,896	0,792	0,957	0,917	0,956	0,943	0,829	0,903	0,948	0,903	
MOF _{L30,K10}	0,897	0,900	0,915	0,900	0,798	0,960	0,921	0,958	0,944	0,837	0,909	0,950	0,907	
MOF _{L30,K15}	0,898	0,907	0,919	0,901	0,798	0,962	0,921	0,958	0,946	0,837	0,911	0,954	0,909	
Obs	0,905	0,859	0,914	0,882	0,841	0,926	0,910	0,956	0,872	0,876	0,831	0,901	0,890	A868 – Itajaí/SC
MOF _{L15,K5}	0,903	0,897	0,901	0,919	0,835	0,931	0,917	0,966	0,894	0,892	0,838	0,935	0,903	
MOF _{L15,K10}	0,902	0,897	0,906	0,926	0,842	0,933	0,923	0,968	0,900	0,899	0,846	0,933	0,909	
MOF _{L15,K15}	0,905	0,903	0,906	0,928	0,852	0,938	0,930	0,970	0,904	0,899	0,847	0,935	0,906	
MOF _{L30,K5}	0,887	0,893	0,902	0,916	0,835	0,921	0,918	0,960	0,874	0,880	0,831	0,938	0,897	
MOF _{L30,K10}	0,888	0,896	0,903	0,919	0,839	0,924	0,923	0,962	0,879	0,887	0,835	0,932	0,899	
MOF _{L30,K15}	0,896	0,893	0,903	0,921	0,843	0,926	0,929	0,965	0,888	0,887	0,835	0,929	0,901	


FONTE: A autora (2025).

TABELA 19 – MÉTODO DOS FRAGMENTOS – ERROS MÉDIOS MENSALIS E ERROS ANUAIS NA REPRODUÇÃO DA PROPORÇÃO DE HORAS SECAS
– ESTAÇÕES A871, A880 E A868

Descrição	Erro Médio Mensal			Erro Anual			Estação	
	MAE	MAPE	MSE	RMSE	MAE	MAPE		MSE
MOF _{L15,K5}	0,013	1,3%	0,000	0,014	0,002	0,20%	0,000	0,002
MOF _{L15,K10}	0,013	1,3%	0,000	0,015	0,003	0,32%	0,000	0,004
MOF _{L15,K15}	0,012	1,3%	0,000	0,015	0,004	0,37%	0,000	0,004
MOF _{L30,K5}	0,014	1,5%	0,000	0,016	0,005	0,48%	0,000	0,005
MOF _{L30,K10}	0,013	1,4%	0,000	0,016	0,003	0,30%	0,000	0,004
MOF _{L30,K15}	0,012	1,3%	0,000	0,015	0,002	0,22%	0,000	0,003
MOF _{L15,K5}	0,018	2,0%	0,001	0,020	0,007	0,79%	0,000	0,008
MOF _{L15,K10}	0,020	2,2%	0,001	0,022	0,010	1,11%	0,000	0,011
MOF _{L15,K15}	0,021	2,3%	0,001	0,023	0,012	1,34%	0,000	0,013
MOF _{L30,K5}	0,017	1,9%	0,001	0,019	0,003	0,33%	0,000	0,004
MOF _{L30,K10}	0,018	2,0%	0,001	0,021	0,003	0,38%	0,000	0,004
MOF _{L30,K15}	0,020	2,2%	0,001	0,022	0,005	0,51%	0,000	0,006
MOF _{L15,K5}	0,019	2,2%	0,001	0,021	0,013	1,42%	0,000	0,013
MOF _{L15,K10}	0,021	2,4%	0,001	0,024	0,016	1,84%	0,000	0,017
MOF _{L15,K15}	0,023	2,6%	0,001	0,026	0,020	2,22%	0,000	0,020
MOF _{L30,K5}	0,017	1,9%	0,000	0,020	0,007	0,75%	0,000	0,008
MOF _{L30,K10}	0,018	2,0%	0,001	0,021	0,009	1,05%	0,000	0,010
MOF _{L30,K15}	0,018	2,1%	0,001	0,021	0,012	1,31%	0,000	0,012

Para a estação A871 (Japira/PR), localizada no interior do Paraná, os resultados para a proporção de horas secas em escala mensal mostraram excelente aderência entre as séries simuladas e observadas, se destacando como os mais consistentes entre as três estações (FIGURA 51). Os erros foram muito baixos em todas as configurações, com MAE entre 0,012 e 0,014 e MAPE em torno de apenas 1,3% a 1,5%, indicando elevada capacidade do modelo em preservar a intermitência da chuva. Os valores de MSE e RMSE foram praticamente nulos, reforçando a consistência dos resultados. Entre as configurações, observou-se homogeneidade de desempenho, sem diferenças significativas entre os valores de l e k (FIGURA 51). Os melhores resultados numéricos foram obtidos em $\text{MOF}_{L15,K15}$ e $\text{MOF}_{L30,K15}$ (MAE = 0,012; MAPE = 1,33%), ainda que as demais configurações tenham apresentado desempenhos praticamente equivalentes, indicando alta capacidade do modelo em representar a intermitência mensal da chuva horária nesta localidade.


FIGURA 51 – MOF – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A871 (JAPIRA/PR)



Em escala anual (FIGURA 52), o desempenho é ainda mais expressivo, todas as configurações resultaram em erros absolutos médios inferiores a 0,01 e MAPE inferiores a 0,5%, o que demonstra boa capacidade do método em reproduzir a proporção global de horas seca. Todas as configurações apresentaram desempenho excelente, sem variações relevantes entre k e l , ainda que o melhor ajuste numérico tenha ocorrido em $\text{MOF}_{L15,K5}$ (MAE = 0,002; MAPE = 0,20%) e $\text{MOF}_{L30,K15}$ (MAE = 0,002; MAPE = 0,22%). Em síntese, a análise anual confirma a robustez do MOF na

preservação da intermitência, mostrando que, em Japira, o modelo consegue reproduzir de forma excelente a proporção de horas secas, independentemente da configuração adotada.

FIGURA 52 – MOF – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A871 (JAPIRA/PR)



Na estação A880 (Vacaria/RS), os resultados para a proporção de horas secas na escala mensal demonstram desempenho igualmente satisfatório, apresentando desvios muito baixos, confirmando a elevada aderência entre as séries simuladas e observadas (FIGURA 53). Os erros absolutos permaneceram reduzidos, com MAE entre 0,017 e 0,021, enquanto o MAPE variou de apenas 1,9% a 2,3%, valores que indicam um desempenho bastante consistente do modelo. O aumento de k , tanto em l de 15 dias quanto em l de 30 dias, resultou em pequeno incremento dos erros, mas sem comprometer o ajuste. Entre as configurações, os melhores resultados foram obtidos com $MOF_{L30,K5}$ (MAE = 0,017; MAPE = 1,94%), embora as diferenças entre as demais combinações sejam marginais.

Na escala anual, os resultados foram ainda mais consistentes, com erros praticamente nulos em todas as configurações. Os valores de MAE variaram de 0,003 a 0,012, enquanto o MAPE permaneceu abaixo de 1,5%, confirmando a alta precisão do modelo em reproduzir a proporção global de horas secas. Entre as configurações, o melhor desempenho foi obtido com $MOF_{L30,K5}$ e $MOF_{L30,K10}$, ambas com MAE = 0,003 e MAPE inferior a 0,4%. As configurações com l de 15 dias apresentaram erros ligeiramente superiores, mas ainda assim extremamente baixos. De modo geral, a

análise anual em Vacaria evidencia que o MOF manteve de forma notável a intermitência da chuva, independentemente dos parâmetros utilizados, reforçando a robustez da métrica e a confiabilidade do modelo nessa estação (FIGURA 54).

FIGURA 53 – MOF – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A880 (VACARIA/RS)






FIGURA 54 – MOF – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A880 (VACARIA/RS)



Em contrapartida, a estação A868 (Itajaí/SC) apresentou os maiores desvios entre observado e simulado, tanto na análise mensal quanto anual, porém também apresentando excelente desempenho. A FIGURA 55 evidencia uma leve tendência de superestimativa da proporção de horas secas, especialmente nos meses de fevereiro, abril e dezembro, porém do mesmo modo o MAE variou entre 0,017 e 0,023, e o MAPE


manteve-se muito baixo, entre 1,95% e 2,64%, valores que indicam uma preservação satisfatória. Assim como observado nas demais estações, o aumento de k em l de 15 dias acarretou em um pequeno acréscimo dos erros, sendo $\text{MOF}_{L15,K15}$ a configuração menos ajustada ($\text{MAE} = 0,023$; $\text{MAPE} = 2,64\%$). Por outro lado, o melhor desempenho ocorreu em $\text{MOF}_{L30,K5}$, com os menores valores de MAE (0,017) e MAPE (1,95%). De modo geral, os resultados mensais em Itajaí confirmam que a proporção de horas secas é uma métrica pouco sensível aos parâmetros de l e k , apresentando elevada robustez e consistência entre as diferentes configurações.

FIGURA 55 – MOF – PROPORÇÃO DE HORAS SECAS MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)



A análise anual (FIGURA 56) confirma a maior dificuldade com essa estação, porém mesmo assim, apresentado resultados extremamente satisfatórios, com erros bastante reduzidos em todas as configurações. O MAE variou entre 0,007 e 0,020, enquanto o MAPE oscilou de apenas 0,75% a 2,22%, confirmando o bom desempenho do modelo nessa métrica. O melhor ajuste ocorreu em $\text{MOF}_{L30,K5}$ ($\text{MAE} = 0,007$; $\text{MAPE} = 0,75\%$), enquanto os maiores erros foram observados em $\text{MOF}_{L15,K15}$, ainda assim com valores baixos ($\text{MAPE} = 2,22\%$). Em resumo, mesmo em Itajaí – onde a variância apresentou maiores discrepâncias – a métrica de intermitência mostrou-se robusta, com resultados consistentes em todas as escalas temporais.

FIGURA 56 – MOF – PROPORÇÃO DE HORAS SECAS ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC)



A análise da proporção de horas secas revelou desempenho altamente satisfatório do Método dos Fragmentos nas três estações avaliadas. Em Japira, os erros foram praticamente nulos, tanto na escala mensal (MAPE \approx 1,3%-1,5%) quanto na anual (MAPE inferior a 0,5%), demonstrando a elevada precisão do modelo em preservar a intermitência horária. Em Vacaria, o comportamento foi semelhante, com valores de MAPE variando entre 1,9% e 2,3% na escala mensal e inferiores a 1,5% na anual, confirmando a consistência dos resultados e a baixa sensibilidade aos parâmetros de l e k . Em Itajaí, apesar das maiores dificuldades observadas na variância, a métrica de horas secas manteve ótimo desempenho, com MAPE de 2% na escala mensal e inferior a 2,3% na anual.

De forma geral, os resultados evidenciam que a intermitência da chuva foi preservada de maneira quase integral, independentemente da estação ou da configuração de parâmetros. A baixa magnitude dos erros e a estabilidade entre diferentes combinações de l e k reforçam a robustez do MOF para essa métrica, evidenciando que a proporção de horas secas constitui uma propriedade estatística facilmente preservada pelo modelo, mesmo em contextos de maior variabilidade pluviométrica, como em Itajaí.

4.2.1.3 Autocorrelação Lag-1

Na TABELA 20, apresentam-se os valores mensais e anual da autocorrelação lag-1 observada, bem como mediana das 100 séries simuladas em cada configuração,

para as três estações analisadas (A871, A880 e A868), considerando as seis combinações dos parâmetros l e k . Complementarmente, a TABELA 21 exhibe os erros médios mensais – obtidos a partir da média dos erros individuais calculados para cada mês – e os erros anuais, estes estimados diretamente pela comparação entre as 100 simulações anuais geradas e os valores anuais observados.

TABELA 20 – MÉTODO DOS FRAGMENTOS – AUTOCORRELAÇÃO LAG-1 – ESTAÇÕES A871, A880 E A868

Descrição	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Anual	Estação
Obs	0,226	0,364	0,197	0,176	0,533	0,367	0,640	0,043	0,215	0,143	0,313	0,425	0,300	A871 – Japira/PR
MOF _{L15,K5}	0,233	0,326	0,241	0,251	0,373	0,474	0,340	0,172	0,352	0,361	0,250	0,230	0,259	
MOF _{L15,K10}	0,210	0,291	0,265	0,203	0,314	0,469	0,293	0,172	0,302	0,338	0,231	0,251	0,253	
MOF _{L15,K15}	0,187	0,282	0,248	0,230	0,294	0,392	0,321	0,172	0,304	0,276	0,184	0,198	0,226	
MOF _{L30,K5}	0,200	0,322	0,299	0,340	0,355	0,349	0,409	0,276	0,444	0,405	0,354	0,234	0,284	
MOF _{L30,K10}	0,172	0,291	0,318	0,263	0,341	0,418	0,354	0,275	0,401	0,349	0,344	0,242	0,276	
MOF _{L30,K15}	0,172	0,285	0,328	0,238	0,325	0,347	0,376	0,219	0,318	0,361	0,329	0,225	0,259	
Obs	0,178	0,296	0,233	0,441	0,646	0,379	0,392	0,673	0,637	0,436	0,209	0,393	0,363	
MOF _{L15,K5}	0,223	0,361	0,349	0,288	0,393	0,336	0,397	0,391	0,458	0,334	0,398	0,178	0,313	
MOF _{L15,K10}	0,209	0,289	0,321	0,296	0,406	0,339	0,359	0,393	0,454	0,294	0,339	0,227	0,297	
MOF _{L15,K15}	0,217	0,253	0,273	0,283	0,406	0,208	0,351	0,385	0,284	0,289	0,376	0,196	0,269	
MOF _{L30,K5}	0,218	0,266	0,327	0,328	0,444	0,488	0,520	0,487	0,337	0,415	0,475	0,198	0,361	
MOF _{L30,K10}	0,219	0,272	0,317	0,338	0,442	0,305	0,434	0,472	0,326	0,366	0,459	0,175	0,339	
MOF _{L30,K15}	0,208	0,267	0,312	0,342	0,452	0,237	0,468	0,474	0,303	0,369	0,434	0,180	0,335	
Obs	0,573	0,370	0,293	0,589	0,351	0,788	0,140	0,321	0,453	0,164	0,549	0,289	0,431	A868 – Itajaí/SC
MOF _{L15,K5}	0,111	0,280	0,358	0,412	0,468	0,387	0,498	0,116	0,293	0,312	0,515	0,146	0,274	
MOF _{L15,K10}	0,090	0,258	0,340	0,328	0,429	0,420	0,452	0,110	0,325	0,275	0,453	0,137	0,232	
MOF _{L15,K15}	0,080	0,242	0,267	0,329	0,402	0,410	0,387	0,095	0,354	0,286	0,432	0,136	0,245	
MOF _{L30,K5}	0,115	0,321	0,372	0,363	0,383	0,395	0,440	0,256	0,438	0,425	0,554	0,165	0,306	
MOF _{L30,K10}	0,179	0,303	0,365	0,420	0,402	0,415	0,449	0,156	0,475	0,349	0,464	0,163	0,291	
MOF _{L30,K15}	0,123	0,305	0,356	0,340	0,417	0,427	0,363	0,116	0,408	0,320	0,446	0,164	0,278	


FONTE: A autora (2025).

TABELA 21 – MÉTODO DOS FRAGMENTOS – ERROS MÉDIOS MENSALIS E ERROS ANUAIS NA REPRODUÇÃO DA AUTOCORRELAÇÃO LAG-1 – ESTAÇÕES A871, A880 E A868

Descrição	Erro Médio Mensal			Erro Anual			Estação	
	MAE	MAPE	MSE	RMSE	MAE	MAPE		MSE
MOF _{L15,K5}	0,152	77,7%	0,036	0,179	0,050	16,7%	0,004	0,060
MOF _{L15,K10}	0,160	79,7%	0,042	0,191	0,058	19,2%	0,005	0,068
MOF _{L15,K15}	0,162	75,8%	0,043	0,193	0,076	25,5%	0,008	0,089
MOF _{L30,K5}	0,171	110,1%	0,043	0,193	0,029	9,8%	0,001	0,036
MOF _{L30,K10}	0,166	107,2%	0,042	0,193	0,042	13,9%	0,003	0,051
MOF _{L30,K15}	0,162	99,7%	0,040	0,191	0,054	18,1%	0,004	0,066
MOF _{L15,K5}	0,181	47,3%	0,050	0,207	0,054	15,0%	0,004	0,063
MOF _{L15,K10}	0,174	44,4%	0,047	0,202	0,068	18,7%	0,006	0,078
MOF _{L15,K15}	0,187	46,9%	0,053	0,214	0,086	23,8%	0,009	0,097
MOF _{L30,K5}	0,155	41,9%	0,038	0,177	0,024	6,5%	0,001	0,031
MOF _{L30,K10}	0,166	44,4%	0,043	0,191	0,035	9,6%	0,002	0,043
MOF _{L30,K15}	0,164	43,1%	0,043	0,190	0,040	11,1%	0,002	0,049
MOF _{L15,K5}	0,199	63,0%	0,062	0,228	0,155	36,0%	0,027	0,164
MOF _{L15,K10}	0,202	60,3%	0,063	0,231	0,181	42,1%	0,036	0,191
MOF _{L15,K15}	0,205	58,7%	0,065	0,236	0,197	45,8%	0,043	0,208
MOF _{L30,K5}	0,188	59,9%	0,060	0,218	0,125	28,9%	0,018	0,134
MOF _{L30,K10}	0,194	60,0%	0,059	0,224	0,135	31,3%	0,021	0,144
MOF _{L30,K15}	0,196	57,5%	0,061	0,226	0,147	34,1%	0,024	0,156

Na estação de Japira, os resultados para a autocorrelação de primeira ordem (lag-1) em escala mensal (FIGURA 57), evidenciaram erros consideráveis quando comparados às métricas anteriores. O MAE situou-se entre 0,152 e 0,171, enquanto os valores de MAPE foram elevados, variando de aproximadamente 75,8% até 110%, o que indica grande dificuldade do modelo em reproduzir com precisão a dependência temporal da chuva entre horas consecutivas. Para l de 15 dias, os erros apresentaram relativa estabilidade, com o menor MAE em $\text{MOF}_{L15,K5}$ (0,152). No caso de l de 30 dias, a performance mostrou-se ainda mais crítica, com percentuais de erro superiores a 100% em k entre 5 e 10, sugerindo que a ampliação da janela não trouxe benefícios, mas sim intensificou os desvios relativos.


FIGURA 57 – MOF – AUTOCORRELAÇÃO LAG-1 MENSAL – ESTAÇÃO A871 (JAPIRA/PR)



Na escala anual (FIGURA 58), os resultados para a autocorrelação de primeira ordem em Japira foram substancialmente melhores que os obtidos na escala mensal, refletindo maior capacidade do modelo em preservar a dependência temporal quando considerada de forma agregada. Os valores de MAE variaram de 0,029 a 0,076, enquanto o MAPE oscilou entre 9,8% e 25,5%, significativamente inferiores aos desvios superiores a 75% observados no mensal. As configurações com l de 30 dias apresentaram os menores erros relativos, em especial $\text{MOF}_{L30,K5}$, que registrou o melhor desempenho (MAE = 0,029; MAPE = 9,77%; RMSE = 0,036). Em síntese, os resultados de Japira indicam que a preservação da dependência temporal (lag-1) constitui um desafio significativo para o MOF, com erros elevados na escala mensal e

pouca sensibilidade positiva às diferentes combinações de parâmetros. Entretanto, na escala anual observou-se expressiva redução dos desvios, sobretudo com a adoção de janelas mais amplas (l de 30 dias), evidenciando que a agregação temporal favorece a reprodução da estrutura de autocorrelação.

FIGURA 58 – MOF – AUTOCORRELAÇÃO LAG-1 ANUAL – ESTAÇÃO A871 (JAPIRA/PR)



Na estação de Vacaria (A880), os erros da autocorrelação de primeira ordem em escala mensal foram expressivos, embora melhores em relação aos das demais estações. O MAE variou de 0,155 a 0,187, enquanto o MAPE oscilou entre 41,9% e 47,3%, indicando dificuldades do modelo em preservar a dependência temporal hora a hora. Comparando as configurações, observou-se desempenho superior para l 30 dias, com destaque para $\text{MOF}_{L30,K5}$, que apresentou os menores erros (MAE = 0,155; MAPE = 41,9%; RMSE = 0,177).

Na escala anual, os resultados indicaram expressiva redução dos erros em comparação à escala mensal (FIGURA 59), reforçando que a agregação temporal favorece a preservação da dependência horária. O MAE variou de 0,024 a 0,086, enquanto o MAPE oscilou entre 6,5% e 23,8%, valores bem inferiores aos desvios superiores a 40% observados no mensal. As configurações com l de 30 dias apresentaram desempenho notavelmente superior, em especial $\text{MOF}_{L30,K5}$ (MAE = 0,024; MAPE = 6,5%; RMSE = 0,031), que se destacou como a melhor configuração. Dessa forma, em Vacaria, a preservação do lag-1 mostrou-se limitada na escala mensal, mas menos crítica do que em Japira.

Na escala anual, houve redução significativa dos desvios, especialmente com a adoção de janelas mais amplas (l de 30 dias), o que conferiu maior estabilidade e melhor reprodução da autocorrelação (FIGURA 60).

FIGURA 59 – MOF – AUTOCORRELAÇÃO LAG-1 MENSAL – ESTAÇÃO A880 (VACARIA/RS)






FIGURA 60 – MOF – AUTOCORRELAÇÃO LAG-1 ANUAL – ESTAÇÃO A880 (VACARIA/RS)



Na estação de Itajaí, os resultados para o lag-1 em escala mensal (FIGURA 61) evidenciaram erros elevados, com MAE variando entre 0,188 e 0,205 e MAPE entre 57,5% e 63,0%. Apesar de expressivos, esses valores foram menos críticos que em Japira, onde os desvios chegaram a ultrapassar 100%. As diferenças entre as configurações foram pequenas, sem indicação clara de ganhos com o aumento de l


ou com a variação de k . O desempenho ligeiramente superior foi observado em $\text{MOF}_{L30,K5}$ ($\text{MAE} = 0,188$; $\text{MAPE} = 59,9\%$; $\text{RMSE} = 0,218$), ainda que sem avanços relevantes em relação às demais combinações.

FIGURA 61 – MOF – AUTOCORRELAÇÃO LAG-1 MENSAL – ESTAÇÃO A868 (ITAJAÍ/SC)



Na escala anual (FIGURA 62), os resultados de Itajaí apresentaram redução dos erros em comparação à escala mensal, mas ainda permaneceram mais elevados que os verificados em Japira e Vacaria. O MAE variou de 0,125 a 0,197, enquanto o MAPE oscilou entre 28,9% e 45,8%, valores que, embora menores que os desvios mensais (58%-63%), ainda indicam limitações relevantes na preservação da autocorrelação. As configurações com l de 30 dias se destacaram positivamente, sobretudo $\text{MOF}_{L30,K5}$ ($\text{MAE} = 0,125$; $\text{MAPE} = 28,9\%$; $\text{RMSE} = 0,134$), que apresentou os menores erros. Em Itajaí, a preservação do lag-1 mostrou-se um desafio para o MOF, com erros elevados tanto na escala mensal quanto na anual. Apesar da redução dos desvios na agregação anual, os resultados permaneceram superiores aos das demais estações, evidenciando a variabilidade da resposta do modelo entre diferentes contextos regionais.

FIGURA 62 – MOF – AUTOCORRELAÇÃO LAG-1 ANUAL – ESTAÇÃO A868 (ITAJAÍ/SC)



A análise do lag-1 evidenciou as maiores limitações do MOF entre as métricas avaliadas, refletindo a dificuldade em preservar a dependência temporal entre horas consecutivas. Em Japira, os erros foram particularmente críticos na escala mensal, com MAPE superior a 100% em algumas configurações, embora na escala anual houvesse expressiva redução dos desvios, sobretudo em janelas mais amplas (l de 30 dias). Em Vacaria, os erros mensais foram elevados, mas menos severos do que em Japira (MAPE em torno de 42%-47%), com melhora significativa na escala anual, onde se destacaram os melhores resultados entre as três estações (MAPE mínimo de 6,5% em $\text{MOF}_{L30,K5}$). Em Itajaí, a preservação da autocorrelação também se mostrou desafiadora, dado que os desvios mensais oscilaram entre 58% e 63%, e embora a agregação anual tenha reduzido os erros (MAPE mínimo de 28,9% em $\text{MOF}_{L30,K5}$), os valores permaneceram mais elevados em comparação às demais localidades.

De forma geral, conclui-se que a reprodução da estrutura de autocorrelação horária constitui um ponto sensível do MOF, com desempenho mais frágil em Japira e Itajaí, e resultados mais consistentes em Vacaria quando considerada a escala anual, com o modelo geralmente subestimando os resultados. A análise conjunta reforça a importância de avaliar o modelo em múltiplas escalas temporais, evidenciando que a agregação anual contribui para atenuar os desvios, ainda que não elimine por completo as limitações na preservação da dependência temporal.

4.2.1.4 Conclusão geral da análise das três métricas

A análise das configurações de parâmetros evidenciou que não houve um padrão único capaz de assegurar o melhor desempenho do MOF em todas as métricas e estações. Em alguns casos, como na variância mensal de Japira e no lag-1 anual de Vacaria e Itajaí, as janelas mais amplas (l de 30 dias) proporcionaram ajustes superiores, reduzindo os erros e conferindo maior estabilidade. Em outros contextos, no entanto, especialmente na variância anual de Japira e Vacaria, as combinações com l de 15 dias apresentaram desempenho mais consistente. Além disso, observou-se que o parâmetro k não apresentou tendência clara: em certas situações o aumento de k contribuiu para a melhoria, enquanto em outras resultou em maior discrepância em relação ao observado.

De forma geral, a avaliação sugere que a resposta do modelo à variação de parâmetros depende fortemente da métrica considerada e das características locais de cada estação. Essa heterogeneidade reforça a importância de analisar múltiplas configurações, uma vez que o desempenho não pode ser atribuído de forma generalizada a um único conjunto de parâmetros. Além disso, é importante destacar que a distinção entre os erros médios mensais – calculados a partir da média dos doze erros mensais – e os erros anuais – obtidos diretamente pela comparação entre as séries anuais simuladas e observadas – revelou-se fundamental para compreender as nuances do desempenho do modelo em diferentes escalas temporais. Essa análise reforça a relevância de se adotar múltiplas métricas e múltiplas escalas de avaliação como estratégia essencial para uma validação robusta de modelos estocásticos aplicados à desagregação temporal da chuva.

4.2.2 Horário de Pico Diário

A TABELA 22 apresenta os resultados referentes à determinação do horário de pico diário, obtidos segundo procedimento descrito no item 3.5.3.


TABELA 22 – MÉTODO DOS FRAGMENTOS – PADRÃO HORÁRIO DE OCORRÊNCIA DO PICO DIÁRIO – ESTAÇÕES A871, A880 E A868

Descrição	00 - 05h	06 - 11h	12 - 17h	18 - 23h	Estação
Observado	21,7%	19,1%	19,1%	40,0%	A871 – Japira/PR
MOF _{L15,K5}	27,1%	22,1%	15,3%	35,4%	
MOF _{L15,K10}	28,7%	21,9%	14,8%	34,6%	
MOF _{L15,K15}	28,3%	21,0%	15,6%	35,2%	
MOF _{L30,K5}	26,8%	20,9%	15,9%	36,4%	
MOF _{L30,K10}	26,5%	20,9%	16,6%	36,1%	
MOF _{L30,K15}	26,6%	20,6%	16,4%	36,4%	
Observado	20,3%	27,5%	19,8%	32,4%	A880 – Vacaria/RS
MOF _{L15,K5}	21,2%	27,5%	20,7%	30,6%	
MOF _{L15,K10}	21,0%	27,2%	20,5%	31,3%	
MOF _{L15,K15}	20,9%	27,8%	20,7%	30,5%	
MOF _{L30,K5}	22,5%	28,3%	18,9%	30,3%	
MOF _{L30,K10}	21,9%	27,7%	18,9%	31,4%	
MOF _{L30,K15}	21,5%	27,8%	19,1%	31,6%	
Observado	32,6%	31,6%	10,7%	25,1%	A868 – Itajai/SC
MOF _{L15,K5}	27,5%	38,3%	15,5%	18,7%	
MOF _{L15,K10}	27,7%	37,5%	15,5%	19,3%	
MOF _{L15,K15}	26,4%	37,1%	15,5%	21,0%	
MOF _{L30,K5}	29,4%	35,9%	17,4%	17,4%	
MOF _{L30,K10}	28,7%	36,6%	16,7%	18,0%	
MOF _{L30,K15}	28,3%	36,7%	16,7%	18,3%	

Na estação A871 (Japira/PR), a distribuição observada dos horários de pico diário revelou uma predominância no período noturno (18-23h), que concentrou 40,0% dos máximos diários de precipitação. Os demais blocos apresentaram valores mais equilibrados, variando entre 19,1% (manhã e tarde) e 21,7% (madrugada), conforme pode ser também observado na FIGURA 63.

Nas séries desagregadas, entretanto, o Método dos Fragmentos apresentou sub-representação do período noturno, com valores entre 34,6% e 36,4%, inferiores ao observado. Em contrapartida, verificou-se superestimação da madrugada (00-05h), que chegou a atingir 28,7% nas simulações frente a 21,7% no observado. Ou seja, parte da frequência que deveria estar concentrada no período noturno foi redistribuída para a madrugada. Os blocos da manhã (06–11h) e da tarde (12–17h) também apresentaram diferenças, ainda que menos expressivas. Ambos oscilaram entre 14,8% e 22,1% nas simulações, frente a 19,1% no observado. Isso sugere que o modelo, além de suavizar o predomínio noturno, introduziu uma leve dispersão para os demais intervalos. Ainda é válido comentar, que todas as configurações apresentaram mesmas tendências, nenhuma se sobressaindo.

Assim, embora o modelo tenha mantido a predominância noturna, não conseguiu reproduzir satisfatoriamente a intensidade relativa observada para Japira, redistribuindo parte dessa frequência para a madrugada. Esse resultado evidencia uma possível limitação do método em captar padrões mais marcantes de concentração intradiária, ainda que a tendência global (predomínio noturno) tenha sido preservada.




Na estação A880 (Vacaria/RS), a distribuição observada dos horários de pico diário apresentou predominância no período noturno (18-23h), com 32,4% dos máximos diários de precipitação (FIGURA 64). O segundo maior percentual ocorreu no bloco da manhã (06-11h), com 27,5%, seguido pelos períodos da madrugada (00-05h: 20,3%) e da tarde (12-17h: 19,8%). Essa configuração demonstra que, para a localidade, os picos diários tendem a ocorrer tanto no final do dia quanto no período da manhã.

Dessa vez, o MOF evidenciou elevada capacidade de reproduzir o padrão observado, apresentando resultados consistentes e próximos aos dados reais em todas as configurações analisadas. As diferenças entre observado e simulado foram inferiores a 2,2 pontos percentuais por bloco horário, indicando boa consistência. A

predominância do período noturno (18-23h) foi corretamente preservada, com valores entre 30,3% e 31,6% nas simulações, muito próximos ao valor observado (32,4%). De modo semelhante, o bloco da manhã (06-11h) também apresentou excelente correspondência, variando entre 27,2% e 28,3% nas simulações, frente aos 27,5% observados. As discrepâncias mais notáveis ocorreram nos blocos de madrugada (00-05h) e tarde (12-17h), em que as simulações tenderam a superestimar levemente o primeiro e a subestimar o segundo. Ainda assim, tais diferenças permanecem pequenas e não comprometem a representação geral do padrão.


Dessa forma, conclui-se que o Método dos Fragmentos apresentou desempenho robusto na estação A880, sendo capaz de manter o equilíbrio entre os blocos horários e reproduzir de forma fiel a predominância do período noturno e a relevância do período matutino. A consistência dos resultados, observada em todas as configurações testadas, evidencia que a metodologia não distorceu a distribuição intradiária dos picos de precipitação e reforça sua aplicabilidade para a caracterização desse comportamento em tal localidade.



Na estação A868 (Itajaí/SC), a distribuição observada dos horários de pico diário apresentou maior concentração na madrugada (00-05h), com 32,6%, seguida

de perto pelo período da manhã (06-11h), com 31,6%. O período noturno (18-23h) respondeu por 25,1% dos casos, enquanto a tarde (12-17h) foi responsável por apenas 10,7% dos máximos diários.

Nas séries desagregadas para Itajaí, o Método dos Fragmentos apresentou maior divergência em relação ao observado do que nas demais estações analisadas (FIGURA 65). De modo geral, houve uma superestimação sistemática do bloco da manhã (06-11h), com proporções variando entre 35,9% e 38,3% nas simulações, frente aos 31,6% observados. Ao mesmo tempo, o modelo subestimou consistentemente o período noturno (18-23h), que variou entre 17,4% e 21,0% nas simulações, em contraste com os 25,1% registrados na série observada. Outro ponto de discrepância relevante ocorreu na tarde (12-17h), onde as simulações atribuíram proporções significativamente maiores (15,5% a 17,4%) em comparação ao valor observado (10,7%). A representação do período da madrugada (00-05h) também não se apresentou satisfatória, subestimando consideravelmente o horário de maior quantidade de picos observados.



Essas diferenças sugerem que, para a estação de Itajaí, o método não conseguiu reproduzir adequadamente o padrão observado de distribuição dos picos

diários. A principal limitação esteve associada à transferência de proporção entre blocos, com excesso de frequência atribuída às manhãs e às tardes em detrimento do período noturno e da madrugada, que se mostraram menos representados do que nos dados reais. Apesar disso, ressalta-se que o processo de desagregação preservou, em linhas gerais, a predominância dos períodos da madrugada e manhã, os quais juntos concentraram a maior parte dos picos diários tanto na série observada quanto nas simulações. Assim, embora apresente limitações para captar a distribuição intradiária específica de Itajaí, o método manteve a tendência geral de ocorrência concentrada no início do dia, ainda que com deslocamentos nas proporções relativas entre os blocos horários.

A análise conjunta das três estações avaliadas evidencia diferenças relevantes no desempenho do Método dos Fragmentos quanto à representação da distribuição intradiária dos picos de precipitação entre as estações analisadas. Em Vacaria (A880), o modelo reproduziu de forma bastante fiel a distribuição dos picos, preservando a predominância noturna e matutina com discrepâncias inferiores a 2 p.p. Em Japira (A871), embora a predominância noturna tenha sido mantida, o modelo subestimou sua magnitude e transferiu parte da frequência para a madrugada, o que caracteriza uma possível limitação frente ao padrão observado. Em Itajaí (A868), as discrepâncias foram ainda mais acentuadas, com superestimação sistemática do período matutino e da tarde e sub-representação do noturno.

De forma geral, os resultados indicam que o MOF é capaz de preservar tendências gerais de ocorrência dos máximos diários, mas apresenta restrições para reproduzir a intensidade relativa dos padrões intradiários, em diferentes climas.

4.2.3 Chuva Horária Máxima Diária


A TABELA 23 apresenta, para cada estação e configuração avaliada, os valores observados juntamente com a mediana das 100 simulações para cada estatística. A FIGURA 66, FIGURA 67 e FIGURA 68 ilustram as curvas de permanência para cada estação analisada, contemplando todas as seis configurações do modelo.

TABELA 23 – MÉTODO DOS FRAGMENTOS – ESTATÍSTICAS DA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÕES A871, A880 E A868

Descrição	Méd.	Md.	D. Padrão	Quantil 90%	Quantil 95%	Quantil 99%	Máx.	Estação
Observado	5,38	2,60	8,25	15,0	19,6	40,4	54,4	A871 – Japira/PR
MOF _{L15,K5}	5,68	2,60	7,96	15,2	21,8	34,5	44,8	
MOF _{L15,K10}	5,77	2,60	7,90	15,6	22,6	34,2	43,4	
MOF _{L15,K15}	5,96	2,60	8,43	16,0	23,6	36,6	45,3	
MOF _{L30,K5}	5,54	2,53	7,76	14,2	21,1	34,7	43,6	
MOF _{L30,K10}	5,56	2,60	7,87	14,3	20,5	33,5	50,4	
MOF _{L30,K15}	5,69	2,58	8,03	14,7	21,6	34,9	48,7	
Observado	4,33	2,10	5,83	10,7	15,9	28,6	30,2	A880 – Vacaria/RS
MOF _{L15,K5}	4,48	1,99	5,82	12,8	16,7	24,0	29,7	
MOF _{L15,K10}	4,57	2,02	6,02	13,1	16,9	25,3	34,7	
MOF _{L15,K15}	4,69	1,97	6,26	13,2	17,4	26,4	35,9	
MOF _{L30,K5}	4,08	1,70	5,11	10,9	14,7	21,3	25,9	
MOF _{L30,K10}	4,26	1,86	5,47	11,4	15,6	22,2	28,5	
MOF _{L30,K15}	4,33	1,89	5,53	11,6	15,8	22,4	29,4	
Observado	3,10	1,00	4,95	9,0	12,8	21,1	31,8	A868 – Itajaí/SC
MOF _{L15,K5}	3,65	1,00	6,82	9,6	14,8	36,1	47,0	
MOF _{L15,K10}	3,75	1,00	7,14	10,1	15,6	40,5	48,6	
MOF _{L15,K15}	3,81	1,00	7,36	10,0	16,3	39,6	48,6	
MOF _{L30,K5}	3,53	1,00	6,74	9,0	14,8	38,5	46,4	
MOF _{L30,K10}	3,59	1,00	6,78	9,3	14,9	33,5	47,0	
MOF _{L30,K15}	3,59	1,00	6,66	9,2	15,3	34,3	48,6	

Para a estação A871 (Japira/PR), de forma geral, nota-se que todas as combinações de parâmetros l e k foram capazes de reproduzir satisfatoriamente as medidas de tendência central da precipitação horária máxima diária. Tanto as médias quanto as medianas simuladas mantiveram-se muito próximas às do registro observado, com diferenças pouco expressivas. Este comportamento evidencia a robustez do MOF em preservar a magnitude típica dos máximos diários, garantindo que os valores mais representativos da distribuição não fossem distorcidos pelo processo de desagregação. Em relação à dispersão, expressa pelo desvio-padrão, observa-se que os valores simulados oscilaram entre 7,76 e 8,43 mm, enquanto o observado foi de 8,25 mm. Essa proximidade indica que o modelo não apresentou tendência marcante de superestimar ou subestimar a variabilidade da série, o que é relevante para assegurar consistência estatística na simulação da irregularidade dos máximos horários ao longo do tempo.

FIGURA 66 – MOF – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A871 (JAPIRA/PR)



Por outro lado, uma análise mais detalhada dos quantis superiores revela diferenças um pouco mais relevantes entre as configurações. O quantil 90% observado (15,0 mm) foi reproduzido de maneira mais superestimada pelas configurações l 15 (15,2 a 16,0 mm), enquanto as configurações com janela de 30 dias tenderam a subestimá-lo (14,2 a 14,7 mm). O mesmo padrão se verifica para o quantil 95%, em que há uma tendência da janela de 15 dias apresentar valores superiores em relação à janela de 30. No quantil 99%, que reflete eventos extremos de maior magnitude, todas as medianas das séries subestimaram em relação ao observado (40,4 mm). Em relação ao valor máximo absoluto, enquanto a série observada atingiu 54,4 mm, nenhuma configuração foi capaz de reproduzir uma mediana integralmente esse extremo. Ressalta-se que a análise foi realizada a partir da mediana das 100 simulações, o que garante uma representação estável da

tendência central, mas tende a atenuar os valores extremos. Assim, a menor correspondência nos máximos absolutos não significa incapacidade do modelo em gerar tais eventos, mas reflete a opção metodológica de reduzir a influência de outliers. Ainda assim, observa-se na FIGURA 66 que valores mais elevados encontram-se representados dentro da faixa interquartil (P25-P75), evidenciando que o modelo é capaz de reproduzir a variabilidade dos máximos horários, mesmo que suavizados pela síntese adotada.

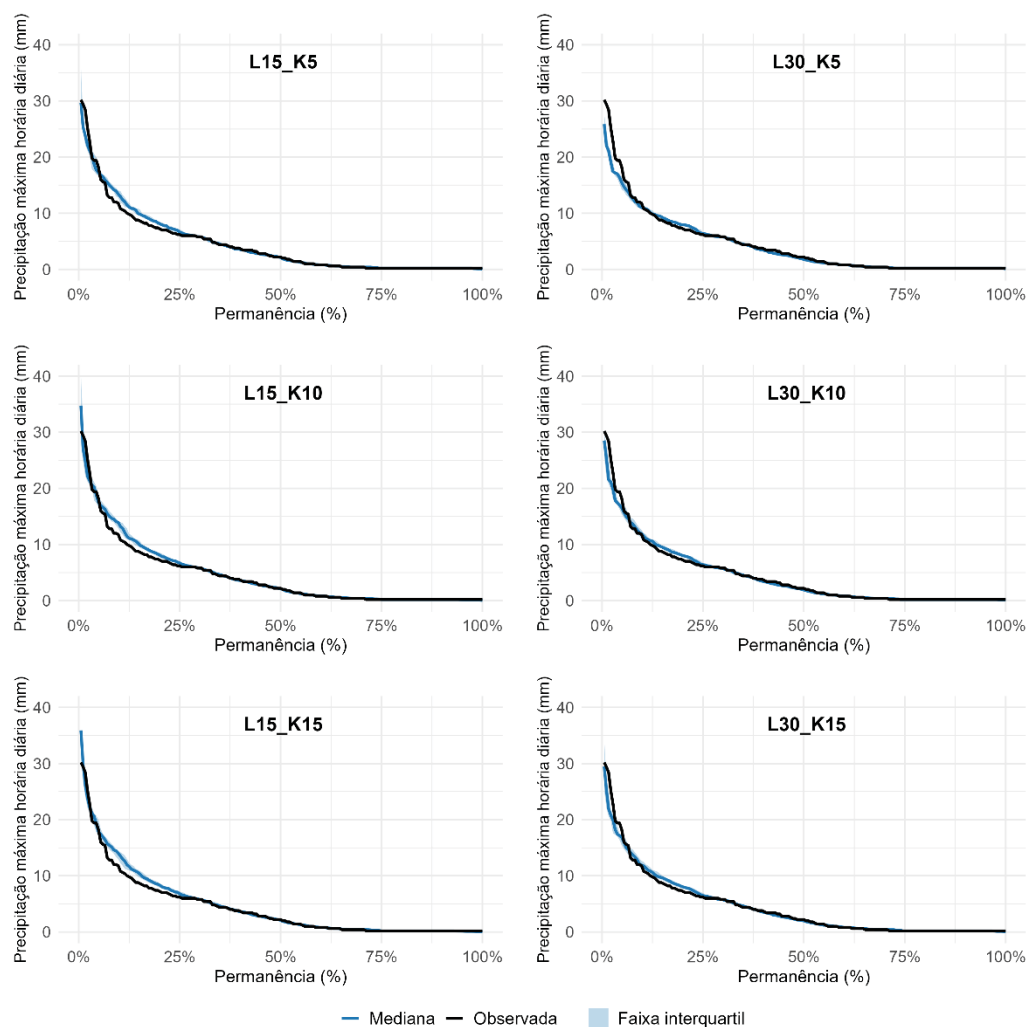
Na estação de Vacaria (A880), os resultados mostram novamente uma boa correspondência entre as estatísticas observadas e as simuladas pelo MOF. A média observada (4,33 mm) foi bem reproduzida em todas as configurações, com valores próximos variando entre 4,08 e 4,69 mm, o que indica que o modelo manteve adequadamente o volume médio das chuvas máximas horárias diárias. A mediana simulada apresentou leve subestimação em relação ao observado (2,10 mm), com valores variando de 1,70 a 2,02 mm. A variabilidade, representada pelo desvio padrão, também foi bem reproduzida. O valor observado (5,83 mm) aparece entre as faixas das simulações (5,11 a 6,26 mm), indicando que o modelo preserva de forma geral a dispersão dos máximos horários.

No que se refere aos quantis superiores, observa-se que os quantis 90%, 95% e 99% foram razoavelmente representados, com pequenas diferenças em relação ao observado. Em particular, de maneira geral, os quantis mais altos tenderam a apresentar valores ligeiramente superiores nas configurações l de 15, e um pouco mais inferiores em l de 30, sugerindo que janelas menores reagem de forma mais acentuada a eventos extremos, enquanto janelas maiores tendem a suavizar essa resposta.

Os máximos absolutos observados (30,2 mm) foram bem aproximados em várias configurações, chegando a 35,9 mm na configuração $\text{MOF}_{L15,K15}$. Mais uma vez, a utilização da mediana como medida de tendência central nas simulações atenua os extremos, de forma que os picos individuais podem aparecer reduzidos quando comparados diretamente ao observado. Ainda assim, como mostram as curvas de permanência (FIGURA 67), observa-se que as simulações reproduzem satisfatoriamente a distribuição dos máximos, com valores mais elevados claramente representados dentro da faixa interquartil (P25-P75), o que reforça a consistência do modelo na geração de eventos intensos. Em síntese, para a estação Vacaria, o MOF

apresentou desempenho sólido em todas as configurações, preservando tanto a média quanto a dispersão dos máximos horários. Pequenas diferenças nos quantis superiores indicam que a escolha de parâmetros influencia a representação dos extremos: l de 15 favorece maior aderência a picos elevados, enquanto l de 30 tende a suavizar a resposta. Assim como em Japira, os resultados reforçam a robustez do método, mesmo quando sintetizado pela mediana das execuções.

FIGURA 67 – MOF – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A880 (VACARIA/RS)




Na estação A868 (Itajaí/SC), os resultados revelam um desempenho inferior do MOF em relação à representação das chuvas máximas horárias diárias, sobretudo nos valores extremos. A média simulada apresenta-se consistentemente superior à

observada (3,6 – 3,8 mm contra 3,1 mm), e o desvio-padrão é também mais elevado, indicando uma maior dispersão dos valores gerados pelo modelo.

A discrepância é mais evidente nos quantis superiores: enquanto o valor observado no quantil 95% é de 12,8 mm, as simulações alcançam entre 14,8 e 16,3 mm. No quantil 99%, essa diferença é ainda mais acentuada, chegando a quase o dobro (21,1 mm observado contra até 40,5 mm simulado). O mesmo padrão se repete para o valor máximo, em que os experimentos do MOF registram picos próximos a 48 mm, bem acima do máximo observado de 31,8 mm.

FIGURA 68 – MOF – PERMANÊNCIA PRECIPITAÇÃO MÁXIMA HORÁRIA DIÁRIA – ESTAÇÃO A868 (ITAJAÍ/SC)



Esses resultados sugerem que, embora o modelo consiga reproduzir adequadamente a mediana das distribuições – que coincide com o valor observado

de 1,0 mm –, ele tende a superestimar a intensidade das chuvas extremas nessa localidade. Essa superestimação pode estar relacionada à própria variabilidade pluviométrica característica da região de Itajaí.

A análise das curvas de permanência (FIGURA 68) reforça essa interpretação: observa-se que, na faixa interquartil, a aderência entre séries simuladas e observadas é satisfatória. No entanto, nas permanências mais baixas – justamente onde se concentram os maiores extremos – as curvas simuladas tendem a se afastar da observada, evidenciando a dificuldade do modelo em limitar a magnitude dos picos máximos.

De forma geral, o Método dos Fragmentos apresentou desempenho satisfatório na reprodução das chuvas máximas horárias diárias, mantendo boa aderência às distribuições observadas, sobretudo na faixa interquartil. A mediana foi bem preservada em todas as estações, indicando que o modelo representa adequadamente a estrutura central da distribuição. Contudo, a análise dos quantis superiores evidenciou diferenças marcantes entre locais: enquanto algumas estações apresentaram boa aproximação, em outras o modelo superestimou significativamente os extremos. Esse comportamento foi particularmente notável em Itajaí (A868), onde os valores simulados do quantil 95%, quantil 99% e máximos absolutos superaram de forma consistente os observados. Essa tendência sugere que, embora o MOF consiga capturar o padrão geral das distribuições, ainda apresenta limitações na representação das chuvas mais intensas, possivelmente relacionadas às características locais de variabilidade pluviométrica. Assim, o método mostra robustez na preservação das propriedades centrais, mas deve ser aplicado com cautela em estudos voltados especificamente para análise de extremos.

4.2.4 Conclusões Gerais Método dos Fragmentos

A avaliação integrada das métricas aplicadas ao Método dos Fragmentos evidencia tanto a robustez quanto as limitações do modelo. As métricas de validação padrão mostraram que a variância horária foi razoavelmente preservada em Japira e Vacaria, mas apresentou discrepâncias mais elevadas em Itajaí; a proporção de horas secas destacou-se como a métrica mais robusta, com erros praticamente nulos em todas as estações; e a autocorrelação de primeira ordem (lag-1), de modo geral,

constituiu o ponto mais sensível, com erros elevados na escala mensal, mas significativa melhora na escala anual, sobretudo em Vacaria. As métricas complementares reforçaram esse diagnóstico: o horário de pico diário mostrou que o MOF manteve as tendências gerais observadas, ainda que com redistribuições entre blocos horários, e as chuvas máximas horárias diárias evidenciaram boa correspondência para Japira e Vacaria, mas superestimação dos extremos em Itajaí.

No que se refere às configurações de parâmetros, observou-se que não houve um padrão único de melhor desempenho. Em algumas situações, como na variância mensal de Japira ou no lag-1 anual de Vacaria, janelas mais amplas (l de 30 dias) proporcionaram ganhos relevantes; em outras, como na variância anual de Vacaria, combinações com l de 15 dias mostraram-se mais consistentes. Já o parâmetro k não apresentou tendência clara: em certas análises o aumento de k trouxe ganhos, enquanto em outras acentuou discrepâncias. De modo geral, as janelas de 30 dias mostraram maior estabilidade, mas não garantiram superioridade absoluta em todas as métricas e estações.

Esses achados reforçam a importância de considerar múltiplas métricas, múltiplas escalas temporais e múltiplas configurações de parâmetros na validação de modelos estocásticos aplicados à desagregação temporal da chuva. A heterogeneidade dos resultados entre estações e métricas evidencia que a performance do MOF é sensível ao contexto regional e ao aspecto estatístico avaliado, demandando análises abrangentes para uma avaliação mais realista de sua aplicabilidade.

4.3 COMPARAÇÕES ENTRE MODELOS

A avaliação conjunta das métricas analisadas permitiu identificar diferenças marcantes entre o desempenho do Modelo Bartlett-Lewis Modificado (MBL) e do Método dos Fragmentos (MOF), revelando pontos fortes e limitações de cada abordagem.

No que se refere à variância horária, o MOF apresentou desempenho consistentemente superior, conseguindo reproduzir de forma fiel tanto a magnitude quanto a sazonalidade da variabilidade intradiária nas três estações. O MBL, em contrapartida, mostrou uma tendência estrutural de suavização, reduzindo a variância

e subestimando os meses de maior variabilidade. Mesmo em Vacaria (A880) e Itajaí (A868), onde o $MBL_{Calib. \text{ mensal}}$ aproximou-se do valor anual observado, os extremos mensais ainda foram mal representados, confirmando sua dificuldade em capturar adequadamente a amplitude da variabilidade.

Na proporção de horas secas, o MOF também apresentou resultados mais próximos dos medidos, preservando adequadamente a intermitência da precipitação. O MBL, embora tenha produzido erros médios baixos, mostrou superestimação sistemática em Vacaria e Itajaí, gerando séries artificialmente mais secas do que as observadas, comportamento também reportado por Pui *et al.* (2012). Assim, mesmo nessa métrica, o MOF demonstrou maior aderência ao padrão real.

Em relação à autocorrelação lag-1, nenhuma das abordagens conseguiu representar plenamente os valores observados. Ainda assim, o MOF apresentou desempenho superior ao MBL, reproduzindo parcialmente a dependência temporal entre valores consecutivos. Adicionalmente, observou-se uma tendência do MOF em subestimar tal métrica, o que vai ao encontro aos resultados dos estudos apresentados por Poschlod *et al.* (2018) e Li *et al.* (2018). O MBL, por outro lado, apresentou uma superestimação sistemática da persistência, resultando em séries excessivamente contínuas e pouco realistas.

Na análise do horário de pico diário, o MOF mostrou maior proximidade ao observado, ainda que com pequenas distorções na redistribuição entre blocos horários. O MBL, por outro lado, apresentou suavização acentuada, reduzindo a concentração de picos nos intervalos dominantes e redistribuindo-os de forma quase uniforme ao longo do dia. Em Japira, por exemplo, a forte concentração de picos em horários noturnos foi praticamente perdida nas simulações do MBL. Pode-se concluir que o modelo gerou chuvas estocasticamente a qualquer horário do dia seguindo o processo de Poisson, resultando em uma incompatibilidade entre as chuvas observadas e desagregadas durante as horas do dia, assim como também reportado por Engida e Esteves (2011). Assim, o MOF mostrou-se mais adequado para preservar padrões intradiários, enquanto o MBL falhou em representar concentrações características de cada localidade.

Por fim, nas chuvas máximas horárias diárias, ambas as abordagens apresentaram limitações, mas em magnitudes diferentes. O MOF conseguiu preservar melhor a magnitude dos eventos extremos, embora com variações entre estações. O

MBL, em contrapartida, apresentou subestimação sistemática dos extremos, especialmente na calibração anual, com máximos e quantis superiores muito abaixo dos observados. Os resultados obtidos pela calibração mensal mostram-se relativamente mais próximos, mas ainda insuficientes para capturar a intensidade real dos maiores eventos.

De forma geral, os resultados evidenciam que o MOF apresentou desempenho mais consistente e robusto – resultado também evidenciado por Pui *et al.* (2012). Representando de modo satisfatório, dado o pequeno histórico de anos utilizado, a variância, a intermitência, a autocorrelação, os padrões intradiários e os extremos de chuva. O MBL mostrou fragilidades estruturais importantes, com tendência à suavização da variabilidade, superestimação da persistência e subestimação de extremos, além de vantagem apenas pontual na simplicidade de sua representação da intermitência.

A FIGURA 69, resume as principais diferenças observadas entre o desempenho do Método dos Fragmentos (MOF) e do Modelo Bartlett-Lewis Modificado (MBL), com base nas métricas avaliadas nas três estações.

FIGURA 69 – RESUMO DAS PRINCIPAIS DIFERENÇAS ENTRE O MBL E MOF

	MBL	MOF
Variância horária	Suaviza a variância e subestima picos mensais	Reproduz bem a variabilidade e sazonalidade
Proporção de horas secas	Intermitência próxima à observada mas com tendência à superestimação	Mantém intermitência próxima à observada
Autocorrelação lag-1	Superestima a persistência	Representa parcialmente a dependência temporal
Horário de pico diário	Suaviza e perde os padrões	Preserva o padrão intradiário com pequenas distorções
Chuvas máximas horárias	Subestima os máximos, sobretudo na calibração anual	Reproduz melhor a magnitude dos extremos
Síntese geral	Maior simplificação, com potencial mediante calibração aprimorada	Desempenho mais consistente e robusto nas métricas avaliadas

É importante destacar, entretanto, que os resultados aqui obtidos não invalidam o potencial do Modelo Bartlett-Lewis Modificado. Considera-se que uma calibração mais robusta, explorando diferentes parametrizações e estratégias de ajuste, poderia trazer ganhos de desempenho, sobretudo na representação da variabilidade e dos extremos. Cabe ressaltar, ainda, que a climatologia do Sul do Brasil, caracterizada por alta variabilidade pluviométrica e pela ocorrência frequente de eventos intensos, impõe desafios adicionais à previsibilidade das séries e dificulta a representação estatística de seus padrões. Nesse sentido, as limitações observadas não decorrem apenas do modelo em si, mas também da complexidade inerente ao regime climático regional. Estudos anteriores corroboram essa relação entre o desempenho do modelo e as condições climáticas locais. Estudos como o de Pui *et al.* (2012) demonstraram que o Randomized Bartlett-Lewis apresenta bom desempenho em regiões de clima temperado e menor variabilidade sazonal, como Sydney. Em contrapartida, Engida e Esteves (2011), ao aplicarem o modelo na Bacia Superior do Nilo Azul, na Etiópia, identificaram desempenho insatisfatório na representação do padrão intradiário da chuva, atribuindo as discrepâncias à predominância de chuvas convectivas e à alta variabilidade temporal.

Ainda assim, nas condições avaliadas, o Método dos Fragmentos mostrou-se mais adequado para a desagregação temporal da precipitação horária, por reproduzir com maior fidelidade a variabilidade, a dependência temporal e os padrões intradiários observados.

4.4 LIMITAÇÕES E IMPLICAÇÕES

Os resultados obtidos também refletem limitações associadas à base de dados e às condições de calibração adotadas. As simulações foram realizadas a partir de séries históricas de apenas sete anos, o que restringe a representatividade da variabilidade interanual e pode influenciar o desempenho dos modelos. Em períodos dominados por anos secos ou chuvosos, por exemplo, as estatísticas de entrada e calibração podem não refletir adequadamente o comportamento pluviométrico de longo prazo.

No caso do Método dos Fragmentos (MOF), o tamanho reduzido da amostra limita a diversidade de fragmentos disponíveis, tornando o processo de desagregação

mais sensível à composição da base histórica. Já no Modelo Bartlett-Lewis Modificado (MBL), a calibração com séries curtas tende a gerar parâmetros instáveis, especialmente os relacionados à frequência e duração dos eventos. Em ambos os modelos, a qualidade dos dados horários é outro fator relevante: mesmo após os procedimentos de consistência, falhas pontuais e lacunas podem afetar a validação e a comparação dos resultados.

Quanto à localização, as estações de Vacaria (RS), Itajaí (SC) e Japira (PR) estão distribuídas em diferentes contextos geográficos da Região Sul – serra, litoral e interior –, mas apresentam médias anuais semelhantes. Possíveis influências de fatores locais, como altitude e proximidade do oceano, não foram objeto de análise detalhada e são aqui apenas reconhecidas como condicionantes potenciais. Dessa forma, os resultados devem ser interpretados com cautela quanto à representatividade regional e às limitações impostas pelo tamanho amostral e pela qualidade dos dados disponíveis.

5 DISCUSSÃO

A análise comparativa entre o Modelo Bartlett-Lewis Modificado (MBL) e o Método dos Fragmentos (MOF) permitiu identificar padrões consistentes de desempenho que refletem tanto diferenças conceituais entre os modelos quanto a influência das características pluviométricas locais. Ao confrontar esses resultados com a literatura recente, observa-se que as tendências identificadas neste estudo são compatíveis com achados reportados em distintas regiões do mundo.

De modo geral, o MOF apresentou desempenho mais robusto, reproduzindo adequadamente variância, intermitência, dependência temporal e padrões intradiários. Esse comportamento é coerente com Poschlod *et al.* (2018), que verificaram boa capacidade do método em representar variabilidade e extremos horários quando comparado a abordagens dinâmicas de alta resolução. Manikanta *et al.* (2023) também mostraram que abordagens baseadas em fragmentos mantêm desempenho estável em diferentes contextos climáticos, em contraste com o Bartlett-Lewis, cujo ajuste se mostrou mais sensível. Resultados complementares foram apresentados por Li *et al.* (2018), que demonstraram que variações do MOF baseadas em reamostragem aumentam sua estabilidade e capacidade de preservar propriedades estatísticas, especialmente em cenários de dados limitados.

Ademais, o MBL mostrou desempenho inferior em aspectos-chave, sobretudo quanto à representação da variabilidade temporal e da magnitude dos extremos, comportamento também relatado em estudos prévios. Pui *et al.* (2012) observaram bom desempenho do modelo apenas em clima temperado, enquanto Engida e Esteves (2011) relataram inadequações em região tropical convectiva, mesmo após redistribuições estocásticas via função Beta. De forma semelhante, Kossieris *et al.* (2018) verificaram que versões sub-horárias do Bartlett-Lewis ainda apresentam dificuldades na representação de extremos e períodos secos, mesmo após ajustes pós-processamento. Além disso, Kaczmarska *et al.* (2015) destacam que o desempenho do Bartlett-Lewis depende fortemente da parametrização adotada, evidenciando que calibrações tradicionais podem não representar adequadamente a variabilidade temporal, ao passo que abordagens não estacionárias via local GMM (*Generalized Method of Moments*), por exemplo, podem aprimorar o ajuste dos momentos estatísticos.

Os resultados obtidos neste trabalho se alinham a essas evidências: o MBL apresentou melhor desempenho em estações de comportamento mais regular, porém enfrentou dificuldades em meses de maior variabilidade e na reprodução de picos concentrados em horários específicos. A autocorrelação lag-1 reforçou essa limitação, com superestimação da persistência pelo MBL e desempenho mais realista do MOF, ainda que com leve subestimação. Quanto aos extremos, o MOF preservou melhor a magnitude dos maiores eventos, comportamento compatível com Manikanta *et al.* (2023) e também observado em ambiente tropical urbano por Lu e Qin (2014). Já o Bartlett-Lewis manteve tendência sistemática à subestimação dos máximos, em linha com Pui *et al.* (2012) e Kossieris *et al.* (2018).

De modo geral, os resultados reforçam que o MOF constitui uma alternativa prática e consistente para a desagregação de chuvas diárias em escala horária, sobretudo em cenários de alta variabilidade ou limitação de dados subdiários. O desempenho inferior do MBL não invalida seu uso, mas evidencia a necessidade de parametrizações mais sensíveis ao regime local. Assim, este estudo confirma tendências apontadas na literatura e amplia o entendimento sobre a aplicabilidade desses modelos em diferentes regiões sujeitas a variabilidade temporal da precipitação e restrições de dados.

6 CONCLUSÕES

O presente estudo teve como objetivo avaliar a aplicabilidade de dois métodos de desagregação temporal de precipitação diária em escalas horárias, o Método dos Fragmentos (MOF) e o modelo estocástico Bartlett-Lewis Modificado (MBL), no contexto da região Sul do Brasil. A análise foi conduzida a partir de dados pluviométricos de estações automáticas do INMET, buscando caracterizar o desempenho de cada modelo frente a diferentes métricas hidrológicas e verificar sua capacidade de representar padrões de variabilidade intradiária, extremos e dependência temporal.

Como etapa inicial, foi realizado o mapeamento da rede de postos disponíveis e a avaliação da qualidade das séries pluviométricas em escala subdiária. Essa análise evidenciou a reduzida cobertura espacial e temporal de dados horários consistentes na região Sul do Brasil, revelando uma das maiores limitações para estudos hidrológicos nacionais. A escassez de informações em alta resolução justifica a relevância de se testar e comparar métodos de desagregação, que permitem gerar séries horárias a partir de registros diários, muito mais amplamente disponíveis. Assim, a investigação realizada contribui também para compreender o papel desses modelos como ferramentas de preenchimento dessa lacuna observacional.

Os resultados demonstraram que ambos os métodos foram capazes de gerar séries desagregadas coerentes com os dados observados, ainda que apresentando algumas limitações. O Método dos Fragmentos mostrou-se mais consistente na preservação da variabilidade intradiária, refletida em métricas como a variância horária e a proporção de horas secas, além de incorporar de forma implícita os regimes sazonais a partir da base histórica utilizada. Em geral, o modelo MOF superou o desempenho do MBL, o que não é totalmente inesperado, uma vez que sua lógica de funcionamento opera com base na reamostragem das frações de chuva observadas em escala subdiária. Dessa forma, é natural que produza estatísticas mais próximas daquelas verificadas nos dados medidos. Entretanto, essa mesma característica também impõe uma restrição, pois sua aplicação depende da disponibilidade de séries subdiárias contínuas, limitando sua utilização em regiões com cobertura pluviométrica insuficiente.

Por outro lado, o Modelo Bartlett-Lewis Modificado, embora fundamentado em uma formulação estocástica mais abrangente e teoricamente capaz de gerar séries independentes de registros históricos, apresentou limitações importantes. A calibração mensal se mostrou mais estável do que a calibração anual, sugerindo que ajustes sazonais mais robustos poderiam melhorar o desempenho do modelo.

Um aspecto central a ser destacado é a extensão reduzida da base histórica utilizada. Considerando-se que apenas oito anos de dados foram efetivamente empregados para compor a série subsidiária de referência – dos quais um foi reservado para comparação e apenas sete para a calibração e aplicação dos métodos –, a amostra disponível não foi suficiente para capturar plenamente a variabilidade climática regional. Essa limitação se refletiu nos erros mais significativos observados nas estatísticas avaliadas, indicando que os resultados não permitem uma validação definitiva da capacidade dos modelos. Ainda assim, a análise possibilitou identificar tendências claras: o MOF demonstrou maior aderência às distribuições observadas em diferentes métricas, enquanto o MBL apresentou desempenho mais instável, mas com potencial de aprimoramento mediante calibrações mais refinadas.

Em síntese, verificou-se que os objetivos estabelecidos foram alcançados: foi possível avaliar a disponibilidade e qualidade das séries horárias observadas e analisar a qualidade da desagregação promovida pelos dois modelos, destacando as vantagens e limitações de cada abordagem. O estudo contribui, assim, para ampliar o entendimento sobre a aplicabilidade desses métodos no contexto nacional, oferecendo subsídios para estudos hidrológicos que demandem séries de precipitação em alta resolução temporal, como modelagem de cheias, drenagem urbana e análise de disponibilidade hídrica.

Recomenda-se que estudos futuros considerem a avaliação do desempenho dos modelos em cenários críticos, como os observados em 2015, de modo a testar sua robustez sob diferentes condições hidrológicas. Sugere-se também que calibrações mais detalhadas sejam conduzidas para o Bartlett-Lewis Modificado, explorando alternativas sazonais e metodologias mais robustas de ajuste paramétrico. Ademais, a incorporação de um número maior de estações pluviométricas e de séries históricas mais extensas permitiria não apenas ampliar a base estatística, mas também identificar em quais condições climáticas cada modelo apresenta melhor desempenho. Esse avanço possibilitaria estabelecer recomendações mais precisas

de aplicabilidade, considerando as diferentes realidades hidrológicas. Essas frentes de investigação abrem caminhos para o aperfeiçoamento das técnicas de desagregação, contribuindo para a gestão mais eficiente dos recursos hídricos.

REFERÊNCIAS

- AGUILAR, M. G.; COSTA, V. A. F. A regional similarity-based approach for sub-daily rainfall nonparametric generation. **RBRH: Revista Brasileira de Recursos Hídricos**, v. 25, e5, 2020.
- ALLEN, R. G. et al. **Crop evapotranspiration – Guidelines for computing crop water requirements**. Rome: FAO, 1998. (FAO Irrigation and Drainage Paper, 56).
- BACK, A. J.; DORFMAN, R.; CLARKE, R. Modelagem da precipitação horária por meio do modelo de pulsos retangulares de Bartlett-Lewis Modificado. **RBRH: Revista Brasileira de Recursos Hídricos**, v. 4, n. 1, p. 5-17, 1999.
- BERNE, A. et al. Temporal and spatial resolution of rainfall measurements required for urban hydrology. **Journal of Hydrology**, v. 299, p. 166-179, 2004.
- BISWAS, P.; SAHA, U. Disaggregation of rainfall from daily to 1-hour scale through integrated MMRC-copula modelling. **Journal of Hydrology**, v. 647, 132338, 2025.
- BLENKINSOP, S. et al. The INTENSE Project: using observations and models to understand the past, present and future of sub-daily rainfall extremes. **Advances in Science and Research**, v. 15, p. 117-126, 2018.
- BOSA, D. A.; SIQUYEIRA, M. V. M.; KLINGELFUS, A. T. Aplicação do SMAP com previsão numérica de precipitação para otimização da operação da PCH Tamboril. **Brazilian Journal of Animal and Environmental Research**, v. 7, p. 283-295, 2024.
- CAPPELLI, F. et al. Sub-daily rainfall simulation using multifractal canonical disaggregation: a parsimonious calibration strategy based on intensity-duration-frequency curves. **Stochastic Environmental Research and Risk Assessment**, v. 39, p. 1-19, 2025.
- CAVALCANTE, A. L.; SILANS, A. M. B. P. Modelo estocástico de desagregação da chuva diária em eventos sub-diários para a região litorânea do Nordeste. **RBRH: Revista Brasileira de Recursos Hídricos**, v. 17, n.3, p. 39-48, 2012.
- CONNOLLY, R. D.; SCHIRMER, J.; DUNN, P. A Daily Rainfall Disaggregation Model. **Agricultural and Forest Meteorology**, v. 92, p. 105-117, 1998.
- CERÓN, W. L. et al. Spatio-temporal análisis of droughts in Cali, Colombia and their primary relationships with the El Niño-Southern Oscillation (ENSO) between 1971 and 2011. **Atmosfera**, v. 33, p. 51-69, 2019.
- CHOW, V.T., MAIDMENT, D.R., MAYS, L.W. **Applied hydrology**. New York: McGraw-Hill, 1988.
- COLLISCHONN, W; DORNELLES, F. **Hidrologia para engenharia e ciências ambientais**. 2ª edição revisada e ampliada. Porto Alegre: Associação Brasileira de

Recursos Hídricos, 2015. 336 p. (Coleção ABRH; 12). Disponível em: <<https://www.abrhidro.org.br/SGCv3/publicacao.php?PUB=5>>.

COSTA, V. **Estimação indireta de quantis de enchentes extremas a partir de modelos chuva-vazão com emprego conjunto de um gerador estocástico de precipitação diária, análise bayesiana e distribuições limitadas superiormente.** Tese de doutorado, Programa de Pós Graduação em Saneamento, Meio Ambiente e Recursos Hídricos da UFMG, Belo Horizonte, 2015.

CRUCIANI, D.E. **A drenagem na agricultura.** São Paulo: Ed. Nobel, 1986. 337p.

DE MICHELE, C.; SALVADORI, G. A generalized Pareto intensity duration model of storm rainfall exploiting 2-copulas. **Journal of Geophysical Research**, v. 108, D2 4067, 2003.

DEPINÉ, H. et al. Preenchimento de Falhas de Dados Horários de Precipitação Utilizando Redes Neurais Artificiais. **RBRH: Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 19, n. 1, p. 51-63, 2014.

ENGIDA, A.N; ESTEVES M. Characterization and disaggregation of daily rainfall in the Upper Blue Nile Basin in Ethiopia. **Hydrological Sciences Journal**, v. 333, p. 226-234, 2011.

FREITAS, E. S. et al. Análise da correlação da precipitação entre pluviógrafos em diferentes escalas temporais. **XXIV Simpósio Brasileiro de Recursos Hídricos**, v. XXIV, nov. 2021.

GARCEZ, L. N.; ALVAREZ, E. V. **Hidrologia.** 2. ed. São Paulo: Edgard Blücher, 1988.

GRIMM, A. M. **Clima da Região Sul do Brasil.** In: CAVALCANTI, I. F. A.; FERREIRA, N. J.; JUSTI DA SILVA, M. G. A.; SILVA DIAS, M. A. F.(org). Tempo e Clima no Brasil, São Paulo: Oficina de Textos, 2009. p.135-147

HERSHENHORN, J.; WOOLHISER D. A. Disaggregation of daily rainfall. **Journal of Hydrology**, v. 95, p. 299-322, 1987.

HINGRAY, B.; BEN HAHA, M. Statistical performances of various deterministic and stochastic models for rainfall series disaggregation. **Atmospheric Research**, v. 77, p. 152-175, 2005.

IPCC – INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **Climate Change 2021: The Physical Science Basis.** Cambridge: Cambridge University Press, 2021.

HUFF, F.A. Time distribution of rainfall in heavy storms. **Water Resource Research**, v. 3, n. 4, p. 1007-1019, 1967.

JIN, L. et al. Coupling the remote sensing data-enhanced SWAT model with the bidirectional long short-term memory model to improve daily streamflow simulations. **Journal of Hydrology**, v. 634, 131117, 2024.

JOSEPH, J. F.; FALCON, H. E.; SHARIF, H. O. Hydrologic trends and correlations in South Texas river basins: 1950–2009. **Journal of Hydrologic Engineering**, v. 18, n. 12, p. 1653-1662, 2013.

KACZMARSKA, J.; ISHAM, V.; ONOF, C. Point process models for fine-resolution rainfall. **Hydrological Sciences Journal**, v. 59, p. 1972-1991, 2014.

KACZMARSKA, J.; ISHAM, V.; NORTHROP, P. Local generalised method of moments: an application to point process-based rainfall models. **Environmetrics**, v. 26, n. 4, p. 312-325, 2015.

KEIFER, C. J.; CHU, H. H. Synthetic storm pattern for drainage design. **Journal of the Hydraulics Division**, v. 83, p. 1-25, 1957.

KIDD, C. et al. So, how much of the Earth's surface is covered by rain gauges? **American Meteorological Society**, v. 98, n. 1, p. 69-78, 2017.

KLEMES, V. Conceptualization and scale in hydrology. **Journal of Hydrology**, v. 65, p. 1-23, 1983.

KOSSIERIS, P. et al. A rainfall disaggregation scheme for sub-hourly time scales: Coupling a Bartlett-Lewis based model with adjusting procedures. **Journal of Hydrology**, v. 556, p. 980-992, 2018.

KOUTSOYIANNIS, D.; ONOF, C. Rainfall disaggregation using adjusting procedures on a Poisson cluster model. **Journal of Hydrology**, v. 246, p. 109-122, 2001.

LALL, U.; SHARMA, A. A nearest neighbor bootstrap for resampling hydrological time series. **Water Resources Research**, v.32, p. 679-693, 1996.

LI, X. et al. Three resampling approaches based on method of fragments for daily-to-subdaily precipitation disaggregation. **International Journal of Climatology**, v. 38, p. 1119-1138, 2018.

LICZNAR, P.; LOMOTOWSKI, J.; RUPP, D. E.; Random cascade driven rainfall disaggregation for urban hydrology: an evaluation of six models and a new generator. **Atmospheric Research**, v. 99, p. 563-578, 2011.

LU, Y.; QIN, X. Multisite rainfall downscaling and disaggregation in a tropical urban area. **Journal of Hydrology**, v. 509, p. 55–65, 2014.

MAIDMENT, D. R. (Ed.). **Handbook of Hydrology**. New York: McGraw-Hill, 1993.

MANIKANTA, V.; GANGULY, T.; UMAMAHESH, N. V. A multi criteria decision making based nonparametric method of fragments to disaggregate daily precipitation. **Journal of Hydrology**, v. 617, 128994, 2023.

MARTINI, L. C. P. Changes in rainfall patterns in southern Brazil over 1961-2000 period detected by rain gauge data. **International Journal of Climatology**, v. 42 p. 9101-9114, 2022.

MEHROTRA, R. et al. Continuous rainfall simulation: 2. A regionalized daily rainfall generation approach. **Water Resources Research**, v. 48, W01536, 2012

MEIRA, M. A. et al. Quality control procedures for sub-hourly rainfall data: An investigation in different spatio-temporal scales in Brazil. **Journal of Hydrology**, v. 613, 128358, 2022.

MELATI, M.D. Regressões simples e robusta na regionalização da vazão Q95 na Bacia Hidrográfica do Taquari-Antas. **Ciência e Natura**, v. 38, p. 722-739, 2016.

MELLO, C. R., SILVA, A. M., BESKOW, S. **Hidrologia de superfície: Princípios e Aplicações**. 2.ed. Lavras: UFLA, 2022.

MOLNAR, P.; BURLANDO, P. Preservation of rainfall properties in stochastic disaggregation by a simple random cascade model. **Atmospheric Research**, v. 77, p. 137-151, 2005.

OLSSON, J. Evaluation of a scaling cascade model for temporal rainfall disaggregation. **Hydrology and Earth System Sciences**, v. 2, p. 19-30, 1998.

ONOF, C. et al. Rainfall modelling using Poisson-cluster processes: a review of developments. **Stochastic Environmental Research and Risk Assessment**, v. 14, p.384–411, 2000.

PENG, A. et al. The application of ensemble precipitation forecasts to reservoir operation. **Water Supply**, v. 19, n.2, p.588-595, 2019.

PEREIRA, G. et al. Avaliação dos dados de precipitação estimados pelo satélite TRMM para o Brasil. **RBRH: Revista Brasileira de Recursos Hídricos**, v. 18, n. 3, p. 139-148, 2013.

PHAM, M. T. et al. Stochastic simulation of precipitation-consistent daily reference evapotranspiration using vine copulas. **Stochastic Environmental Research and Risk Assessment**, v. 30, p. 2197-2214, 2016

PINHEIRO, A.; GRACIANO, R. L. G.; SEVERO, D. L. Tendência das séries temporais de precipitação da região sul do Brasil. **Revista Brasileira de Meteorologia**, v. 28, n.3, p.281-290, 2013.

POSCHLOD, B. et al. Comparison and evaluation os statistical rainfall disaggregation and high-resolution dynamical downscaling over complex terrain. **Journal of Hydrology**, v. 19, p. 1973-1982, 2018.

PUI, A. et al. A comparison of alternatives for daily to sub-daily rainfall disaggregation. **Journal of Hydrology**, v. 470,-471, p. 138-157, 2012.

- SALVIANO, M.F.; GROppo, J.D.; PELLEGRINO, G.Q. Análise de tendências em dados de Precipitação e Temperatura no Brasil. **Revista Brasileira de Meteorologia**, v. 31, n. 1, p. 64-73, 2016.
- SANTOS, I. et al. **Hidrometria Aplicada**. Curitiba: CEHPAR – Centro de hidráulica e Hidrologia Prof. Parigot de Souza, 2001. p. 372.
- SCHEEVEL, C. R. et al. **Precipitation thresholds for landslide occurrence near Seattle, Mukilteo, and Everett, Washington**. Reston: U.S. Geological Survey, 2017. (Open-File Report, 2017-1039).
- SHARMA, A.; MEHROTRA R. **Rainfall generation, in Rainfall: State of Science**. American Geophysical Union, p. 215-246, 2010.
- SILVA, J. R. S. et al. Variabilidade da precipitação e relação com a produtividade de mandioca (*Manihot Esculenta*) na Cidade de Cruzeiro do Sul, Acre. **Research Society and Development**, v.11, n.8, 2022.
- SINGH, V. P. **Elementary Hydrology**. Englewood Cliffs: Prentice Hall, 1992.
- SOUSA, A. M. L. et al. Variabilidade espaço-temporal da precipitação na Amazônia durante eventos Enos. **Revista Brasileira de Geografia Física**, v.8, n.1, p.13-24, 2015.
- SVANIDZE, G. G. **Mathematical Modeling of Hydrologic Series**. Water Resources Publications, Fort Collins, Colo, 1980.
- TUCCI, C. E. M. **Hidrologia Ciência e Aplicação**. 2. Ed. Porto Alegre: Editora da UFRGS/ABRH, 1997.
- RAMOS, F. et al. **Engenharia hidrológica**. Rio de Janeiro: ABRH/UFRJ, 1989.
- RODRÍGUEZ-ITURBE, I.; COX, D. F. R. S.; ISHAM, V. Some models for rainfall based on stochastic point processes. **Proceedings of the Royal Society A**, v. 410, p. 269-288, 1987.
- RODRÍGUEZ-ITURBE, I.; COX, D. F. R. S.; ISHAM, V. A point process model for rainfall: further developments. **Proceedings of the Royal Society A**, v. 417, p. 283-298, 1988.
- VILLELA, S. M; MATTOS, A. **Hidrologia Aplicada**. São Paulo: McGraw-Hill do Brasil, 1975.
- WANG, Y.; HE, B.; TAKASE, K. Effects of temporal resolution on hydrological model parameters and its impact on prediction of river discharge. **Hydrological Sciences Journal**, v. 54, p. 886-898, 2009.
- WARD, R. C. **Principles of Hydrology**. England: McGraw-Hill, 1967.

WARD, H. C. et al. Impact of temporal resolution of precipitation forcing data on modelled urban-atmosphere exchanges and surface conditions. **International Journal of Climatology**, v. 38, p. 649-662, 2018.

WESTRA, S. et al. Continuous rainfall simulation: 1. A regionalized subdaily disaggregation approach. **Water Resources Research**, v. 48, W01535, 2012.

WREGE, M. S. et al. Atlas climático da região Sul do Brasil: estados do Paraná, Santa Catarina e Rio Grande do Sul. 2. ed. Brasília, DF: **Embrapa**, 2012.

ZANARDO, S. et al. Intra-annual rainfall variability control on interannual variability of catchment water balance: A stochastic analysis. **Water Resources Research**, v.48, E00J16, 2012