

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS NATURAIS E EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA

Cleiton Tibulo

**MODELOS ESTATÍSTICOS EMPREGADOS PARA A PREVISÃO
SAZONAL DA PRECIPITAÇÃO NAS REGIÕES SUL, SUDESTE E
CENTRO OESTE DO BRASIL**

Santa Maria, RS
2021

Cleiton Tibulo

**MODELOS ESTATÍSTICOS EMPREGADOS PARA A PREVISÃO
SAZONAL DA PRECIPITAÇÃO NAS REGIÕES SUL, SUDESTE E
CENTRO OESTE DO BRASIL**

Tese de Doutorado apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Meteorologia, Área de Concentração em Climatologia, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Doutor em Meteorologia**.

Orientadora: Profa. Dra. Simone Erotildes Teleginski Ferraz

Santa Maria, RS
2021

Tibulo, Cleiton

Modelos estatísticos empregados para a previsão sazonal da precipitação nas regiões Sul, Sudeste e Centro Oeste do Brasil / Cleiton Tibulo.- 2021.

247 p.; 30 cm

Orientadora: Simone Erotildes Teleginski Ferraz
Tese (doutorado) - Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, Programa de Pós-Graduação em Meteorologia, RS, 2021

1. Precipitação 2. Previsão Sazonal 3. Modelos Estatísticos I. Ferraz, Simone Erotildes Teleginski II. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, CLEITON TIBULO, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Tese) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

Cleiton Tibulo

**MODELOS ESTATÍSTICOS EMPREGADOS PARA A
PREVISÃO SAZONAL DA PRECIPITAÇÃO NAS REGIÕES SUL,
SUDESTE E CENTRO-OESTE DO BRASIL**

Tese de Doutorado apresentada ao
Curso de Doutorado do Programa de
Pós-Graduação em Meteorologia,
Área de Concentração em
Climatologia, da Universidade
Federal de Santa Maria (UFSM, RS),
como requisito parcial para obtenção
do grau de **Doutor em
Meteorologia.**

Aprovado em 06 de maio de 2021:



Simone Erotildes Teleginski Ferraz, Dra. (UFSM)
(Presidente/Orientadora)



Nathalie Tissot Boiaski, Dra. (UFSM)



Diogo Alessandro Arsego, Dr. (CPTEC)



Luciane Flores Jacobi, Dra. (UFSM)



Adriano Mendonça Souza, Dr. (UFSM)

Santa Maria, RS
2021

DEDICATÓRIA

Dedico essa tese a meu falecido pai Ivar Tibulo, o qual perdi durante a realização desta pesquisa. Homem honrado, com muito conhecimento de mundo, de ótima relação com as pessoas, nunca desistiu de seus ideais e seus propósitos, sempre colocava o interesse coletivo ou das outras pessoas a frente dos seus. Para mim sempre foi um exemplo, a cada dia que passei com você pai, me tornei uma pessoa melhor, mais educada, mais paciente, mais dedicada, de maior doação ao próximo. Hoje entendo muitas coisas que você me falava, espero um dia que você me perdoe por não ter passado mais tempo com você.

A você papai dedico e compartilho esse trabalho, tenho certeza que de onde você estiver, estará sentindo orgulho por essa realização.

Obrigado por tudo que você representou, representa e representará na minha vida!

AGRADECIMENTOS

A Deus, por me dar saúde, força e disposição para trabalhar e estudar superando as dificuldades e por proporcionar esta oportunidade de cursar o mestrado.

À minha esposa, Vaneza De Carli Tibulo, pelo incentivo, auxílio e apoio que sempre me deu para prosseguir com os estudos.

À minha orientadora, professora Simone Herothildes Ferraz, pelo conhecimento, competência, incentivo, paciência, dedicação e amizade transmitida. Um especial muito obrigado!

Aos meus filhos Natieli De Carli Tibulo e Guilherme de Carli Tibulo, aos quais dedico todo o meu esforço. Que compreendam os momentos que não pude estar próximo.

Aos professores Adriano Mendonça Souza e Nathalie, pela compreensão, ajuda e colaboração prestadas ao longo desse período.

Ao meu pai, Ivar Tibulo, e minha mãe, Valdomira Tibulo, por me ensinarem a prosseguir mesmo em situações adversas, a vocês devo tudo o que tenho.

À minha família como um todo pelos incentivos proferidos.

Agradeço à Universidade Federal de Santa Maria e a todos os professores e funcionários do PPGMET/UFSM que me auxiliaram nestes quatro últimos anos.

Ao Colégio Militar de Santa Maria que forneceu ferramentas necessárias para que esta pesquisa fosse realizada.

Por fim, agradeço aos professores que se disponibilizaram a participar da banca gastando seus preciosos tempos a fim de corrigir e tornar este trabalho melhor.

Obrigado a todos!

Com os erros aprendemos coisas que jamais
aprenderíamos se as coisas dessem sempre certo.

Autor desconhecido.

RESUMO

MODELOS ESTATÍSTICOS EMPREGADOS PARA A PREVISÃO SAZONAL DA PRECIPITAÇÃO NAS REGIÕES SUL, SUDESTE E CENTRO OESTE DO BRASIL

AUTOR: Cleiton Tibulo

ORIENTADORA: Profa. Dra. Simone Erotildes Teleginski Ferraz

A presente pesquisa tem como objetivo aplicar modelos estatísticos de séries temporais para a previsão da precipitação pluviométrica sazonal em sub-regiões das regiões Sul, Sudeste e Centro-Oeste do Brasil, investigando se os modelos das classes Autoregressivos Integrados e de Médias Móveis que levam em consideração a componente sazonal (SARIMA), Autoregressivos Integrados e de Médias Móveis que consideram a componente sazonal e permitem a entrada de variáveis exógenas (SARIMAX), Alisamento Exponencial e Combinados podem ser usados como ferramenta de apoio aos modelos dinâmicos na previsão da precipitação acumulada mensal. Para realização deste estudo foram considerados os dados da série histórica correspondente à precipitação acumulada mensal, extraídos de Xavier et al., (2015) das regiões Sul, Sudeste e Centro-Oeste do Brasil, compreendidas entre as latitudes (20,625°S e 33,62°S) e longitudes (42,62°W e 57,62°W) no período de 01 de janeiro de 1980 a 31 de dezembro de 2013. Estes dados foram interpolados para 1° latitude por 1° de longitude, sendo a série um ponto central. No total foram obtidas 107 séries históricas de precipitação acumulada mensal, contendo cada série 408 observações (meses). As séries de Temperatura da Superfície do Mar (TSM) selecionadas para o mesmo período com 5° de latitude por 5° de longitude, sendo a série um ponto central, compreendida na faixa entre 60° Norte e 60° Sul pertencentes ao conjunto de dados ERSSTv5 da NOAA (Huang et al., 2017). Obteve-se 1418 séries históricas de TSM, contendo cada série 408 observações. Para ajuste dos modelos utilizou-se o software RStudio. Determinou-se a influência da TSM nas sub-regiões através da correlação de Person. Avaliou-se a qualidade das previsões pontuais por meio da média percentual absoluta dos erros. Categorizou-se as previsões mediante a técnica quantílica. Utilizou-se o teste Deibol-Mariano para verificar se há diferença estatística significativa entre as previsões dos modelos. As sub-regiões com similaridades de precipitação acumulada mensal foram definidas pela análise de agrupamento. A técnica determinou cinco sub-regiões similares: Sub-região Sul 1, Sub-região Sul 2, Sub-região Sul 3, Sub-região Sudeste/Centro 1 e Sub-região Sudeste/Centro-Oeste 2. Para a região Sul foram ajustados os modelos propostos para as previsões sazonais trimestrais: verão, outono, inverno e primavera. Os melhores resultados de previsão para as três sub-regiões Sul foram obtidos para o período de outono e primavera, seguidas do verão. No período de inverno os modelos encontraram dificuldades de ajuste e previsões, tendo em vista a alta variabilidade contida nas séries temporais para esses períodos. Nas regiões Sudeste/Centro-Oeste testou-se os modelos para os meses de novembro a março (verão estendido), que é considerado período chuvoso. Os modelos demonstraram um excelente ajuste e desempenho para ambas as regiões com erros nas previsões pontuais em torno de 14% sub-região Sudeste/Centro-Oeste 1 e 18% sub-região Sudeste/Centro-Oeste 2, não havendo diferença estatística significativa entre as previsões dos modelos testados. Há de se considerar para essas sub-regiões uma forte influência da TSM na precipitação acumulada mensal. Conclui-se que os modelos propostos de previsão de ST podem ser usados como uma ferramenta de apoio aos modelos dinâmicos para a previsão da precipitação acumulada mensal nas regiões pesquisadas, com destaque para o modelo SARIMA.

Palavras-chave: Precipitação. Previsão Sazonal. Modelos Estatísticos.

ABSTRACT

STATISTICAL MODELS EMPLOYED FOR THE SEASONAL FORECASTING OF PRECIPITATION IN THE SOUTH, SOUTHEAST AND MIDWEST OF BRAZIL.

AUTHOR: Cleiton Tibulo

ADVISOR: Profa. Dra. Simone Erotildes Teleginski Ferraz

This present research aims to apply statistical models of time series for the forecast of seasonal rainfall in sub-regions of the South, Southeast and Midwest regions of Brazil, investigating whether the models of Integrated Autoregressive classes and Moving Averages that take into account the seasonal component (SARIMA), Integrated Autoregressive and Moving Averages that considers a seasonal component and allows the entry of exogenous variables (SARIMAX), Exponential Smoothing and Combined can be used as a support tool for the dynamic models in forecasting monthly accumulation. In order to carry out the study, data from the historical series corresponding to the accumulated monthly combination, extracted from Xavier et al., (2015) from the South, Southeast and Midwest regions of Brazil, between latitudes ($20,625^{\circ}$ S and $33, 62^{\circ}$ S) and longitudes (42.62° W and 57.62° W) in the period from January 1st, 1980 to December 31st, 2013. These data were interpolated to 1° latitude by 1° longitude, being the series the central point. In total, 107 historical series of accumulated monthly graduation were defined, containing each 408 basic series (months). The Sea Surface Temperature (SST) series selected for the same period with 5° latitude by 5° longitude, being the series a central point, comprised in the range between 60° N and 60° S, belonging to the ERSSTv5 data set from NOAA (Huang et al., 2017). 1418 historical series of SST were obtained, with each series containing 408 observations. To adjust the models, RStudio software was used. The influence of SST in the sub-regions was determined through the Person correlation. The quality of point forecasts was evaluated by means of the absolute percentage of errors. The predictions were categorized using the quantile technique. The Deibol-Mariano test was used to verify if there is a statistically significant difference between the predictions of the models. The sub-regions with similarities in monthly accumulated precipitation were defined by cluster analysis. The technique determined five similar sub-regions: South Sub-region 1, South Sub-region 2, South Sub-region 3, Southeast / Center 1 and Southeast / Midwest 2. The models proposed for the quarterly seasonal forecasts are adjusted: summer, autumn, winter and spring. The best forecast results for the three South sub-regions were obtained from the autumn and spring period, followed by summer. In the winter period, the models encountered difficulties in adjusting and forecasting, in view of the high variability contained in the time series for these periods. In the Southeast / Midwest regions, models were tested for the months from November to March (extended summer), which is considered a rainy season. The models demonstrated an excellent fit and performance for both regions with errors in point forecasts of around 14% Southeast / Midwest 1 sub-region and 18% Southeast / Midwest 2 sub-region, with no statistically significant difference between the predictions of the tested models. For these sub regions, a strong influence of the SST in the accumulated monthly rainfall must be considered. It is concluded that the proposed ST forecasting models can be used as a tool to support the dynamic models for the forecast of monthly accumulated precipitation in the surveyed regions, with emphasis on the SARIMA model.

Keywords: Precipitation. Seasonal Forecast. Statistical Models.

LISTA DE FIGURAS

Figura 1 – Climatologia da precipitação no Brasil, utilizando dados em grade	42
Figura 2 – Aplicação do método de análise de agrupamentos	45
Figura 3 – Dendrograma esquemático para um grupo de 5 membros	46
Figura 4 – Etapas para o estudo de ST	51
Figura 5 – Subdivisão do modelo ARIMAX	55
Figura 6 – Dendrograma das séries históricas na região Sul	70
Figura 7 – Sub-regiões da região Sul com Similaridades nas séries históricas de precipitação mensal acumulada	72
Figura 8 – Correlação entre a TSM e precipitação acumulada mensal para SR1	74
Figura 9 – Correlação entre TSM e precipitação acumulada mensal para SR2	76
Figura 10 – Correlação entre TSM e precipitação acumulada mensal para SR3	78
Figura 11 – Classificação climatológica SR1	80
Figura 12 – Série Original da precipitação acumulada mensal da SR1, 1980 a 2013	81
Figura 13 – Decomposição da série temporal em componentes tendência, sazonalidade e aleatoriedade	82
Figura 14 – Média mensal de precipitação acumulada SR1	82
Figura 15 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP)	84
Figura 16 – Modelo SARIMA (1,0,0)(0,1,2) ₁₂ ajustado à série observada	86
Figura 17 – Modelo SARIMAX (1,0,0)(0,1,2)[1] ₁₂ ajustado à série observada (SON)	88
Figura 18 – Holt-Winters multiplicativo ajustado à variável SR1 (SON)	90
Figura 19 – Desempenho dos modelos para SR1 (SON)	92
Figura 20 – Modelo SARIMA (1,0,0)(1,1,2) ₁₂ ajustado à série observada	94
Figura 21 – Modelo SARIMAX (1,0,0)(0,1,1) [1] ₁₂ ajustado à série observada	96
Figura 22 – Holt-Winters multiplicativo ajustado à variável SR1	97
Figura 23 – Desempenho dos modelos para SR1 (JJA)	99
Figura 24 – Modelo SARIMA (1,0,0) (1,1,2) ₁₂ ajustado à série observada para SR1 (MAM)	101
Figura 25 – Modelo SARIMAX (1,0,0)(0,1,1) [1] ₁₂ ajustado à série observada SR1 (MAM)	103
Figura 26 – Holt-Winters multiplicativo ajustado à variável SR1 (MAM)	104
Figura 27 – Desempenho dos modelos SR1 (MAM)	106
Figura 28 – Modelo SARIMA (1,0,0)(1,1,2) ₁₂ ajustado à série observada SR1 (DJF)	108
Figura 29 – Modelo SARIMAX (1,0,0)(0, 1, 2)[1] ₁₂ ajustado à série observada para SR1 (DJF)	110
Figura 30 – Holt-Winters aditivo ajustado à variável SR1 (DJF)	111
Figura 31 – Desempenho dos modelos para SR1 (DJF)	113
Figura 32 – Classificação climatológica SR2	116
Figura 33 – Série Original da precipitação acumulada mensal da SR2, 1980 a 2013	118
Figura 34 – Decomposição da série temporal em componentes tendência, sazonalidade e aleatoriedade	118
Figura 35 – Média mensal de precipitação acumulada SR2	119
Figura 36 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) SR2	120
Figura 37 – Modelo SARIMA ajustado à série observada SR2 (SON)	122
Figura 38 – Modelo SARIMAX (2,0,0)(0,1,1)[1] ₁₂ ajustado à série observada SR2 (SON)	124
Figura 39 – Holt-Winters multiplicativo ajustado à variável SR2 (SON)	125
Figura 40 – Desempenho dos modelos para SR2 (SON)	127
Figura 41 – Modelo SARIMA (1,0,0) (0,1,1) ₁₂ ajustado à série observada SR2 (JJA)	129

Figura 42 – Modelo SARIMAX (2,0,0) (0,1,1) [1] ₁₂ ajustado à série observada SR2 (JJA)	131
Figura 43 – Holt-Winters multiplicativo ajustado à variável SR2 (JJA).....	133
Figura 44 – Desempenho dos modelos SR2 (JJA)	135
Figura 45 – Modelo SARIMA (2,0,0) (0,1,1) ₁₂ ajustado à série observada SR2	137
Figura 46 – Modelo SARIMAX (2,0,0) (0,1,1) [1] ₁₂ ajustado à série observada SR2	139
Figura 47 – Holt-Winters multiplicativo ajustado à variável SR2	140
Figura 48 – Desempenho dos modelos SR2 (MAM)	142
Figura 49 – Modelo SARIMA (2,0,0) (0,1,1) ₁₂ ajustado à série observada SR2	144
Figura 50 – Modelo SARIMAX (1,0,0)(0,1,1) [1] ₁₂ ajustado à série observada SR2	146
Figura 51 – Holt-Winters multiplicativo ajustado à variável SR2	148
Figura 52 – Desempenho dos modelos para SR2 (DJF).....	150
Figura 53 – Classificação climatológica SR3	153
Figura 54 – Série Original da precipitação acumulada mensal da SR3, 1980 a 2013.....	155
Figura 55 – Decomposição da série temporal em componentes tendência, sazonalidade e aleatoriedade	155
Figura 56 – Média mensal de precipitação acumulada SR3.....	156
Figura 57 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP).....	157
Figura 58 – Modelo SARIMA ajustado à série observada SR3	159
Figura 59 – Modelo SARIMAX (2,0,0) (0,1,1) [1] ₁₂ ajustado à série observada SR3	161
Figura 60 – Holt-Winters aditivo ajustado à variável SR3.....	162
Figura 61 – Desempenho dos modelos para SR3 (SON)	163
Figura 62 – Modelo SARIMA (2,0,0) (0,1,1) ₁₂ ajustado à série observada SR3	165
Figura 63 – Modelo SARIMAX (2,0,0) (0,1,1) [1] ₁₂ ajustado à série observada	167
Figura 64 – Holt-Winters multiplicativo ajustado à variável SR3	168
Figura 65 – Desempenho dos modelos para SR3 (JJA)	169
Figura 66 – Modelo SARIMA (2,0,0) (0,1,1) ₁₂ ajustado à série observada SR3	171
Figura 67 – Modelo SARIMAX (1,0, 0)(0,1,1) [1] ₁₂ ajustado à série observada SR3	173
Figura 68 – Holt-Winters multiplicativo ajustado à variável SR3	174
Figura 69 – Desempenho dos modelos para SR3 (MAM)	176
Figura 70 – Modelo SARIMA (2,0,0) (0,1,1) ₁₂ ajustado à série observada SR3	178
Figura 71 – Modelo SARIMAX (1,0,0) (0,1,1) [1] ₁₂ ajustado à série observada SR3	180
Figura 72 – Holt-Winters multiplicativo ajustado à variável SR3	181
Figura 73 – Desempenhos dos modelos para SR3 (Dez a Jan)	183
Figura 74 – Dendrograma das séries históricas na região Sudeste/Centro Oeste.....	187
Figura 75 – Sub-regiões da região Sudeste/Centro Oeste com similaridades nas séries históricas de precipitação acumulada mensal.....	189
Figura 76 – Classificação climatológica SRS1 período de verão.....	196
Figura 77 – Série Original da precipitação acumulada mensal da SRS1, 1980 a 2013.....	197
Figura 78 – Decomposição da série temporal SRS1 em componentes tendência, sazonalidade e aleatoriedade	198
Figura 79 – Médias mensais de precipitação acumulada SRS1	198
Figura 80 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) SRS1.....	200
Figura 81 – Modelo SARIMA (1,0,0) (0,1,1) ₁₂ ajustado à série observada SRS1.....	202
Figura 82 – Modelo SARIMAX (1,0,0) (0,1,1) [3] ₁₂ ajustado à série observada SRS1	204
Figura 83 – Holt-Winters multiplicativo ajustado à variável SRS1	206
Figura 84 – Desempenho dos modelos para SRS1 (Dez a Mar)	208
Figura 85 – Classificação climatológica SRS2 período de verão.....	211
Figura 86 – Série Original da precipitação acumulada mensal da SRS2, 1980 a 2013.....	212
Figura 87 – Decomposição da série temporal SRS2 em componentes tendência, sazonalidade e aleatoriedade	213

Figura 88 – Médias mensais de precipitação acumulada SRS2	214
Figura 89 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) SRS2	215
Figura 90 – Modelo SARIMA (2,0,0) (1,1,1) ₁₂ ajustado à série observada SRS2	217
Figura 91 – Modelo SARIMAX (2,0,0) (0,1,1) [2] ₁₂ ajustado à série observada SRS2.....	219
Figura 92 – Holt-Winters multiplicativo ajustado à variável SRS2.....	221
Figura 93 – Desempenho dos modelos para SRS2 (Dez a Mar).....	223

LISTA DE QUADROS

Quadro 1 – Equações de suavização exponencial sazonal de Holt-Winters Aditivo	57
Quadro 2 – Equações de suavização exponencial sazonal de Holt-Winters multiplicativo ...	58
Quadro 3 – Equações de Alisamento Exponencial Biparamétrico	58
Quadro 4 – Equações de Alisamento Exponencial Simples	59
Quadro 5 – Critérios AIC e BIC	60
Quadro 6 – Critérios de avaliação sobre a qualidade das previsões	61
Quadro 7 – Intervalos de classe para categorização da precipitação	62
Quadro 8 – Nomenclatura das séries de dados da região Sul do Brasil.....	69
Quadro 9 – Sub-regiões da região Sul com similaridades nas séries históricas de precipitação mensal acumulada	71
Quadro 10 – Classificação climatológica SR1	79
Quadro 11 – Classificação categóricas das previsões para SR1	114
Quadro 12 – Classificação climatológica SR2	116
Quadro 13 – Classificação categóricas das previsões para SR2.....	152
Quadro 14 – Classificação climatológica SR3	153
Quadro 15 – Classificação categóricas das previsões para SR3.....	185
Quadro 16 – Nomenclatura das séries de dados da região Sudeste/Centro Oeste do Brasil ..	186
Quadro 17 – Sub-regiões da região Sudeste/Centro Oeste com Similaridades nas séries históricas de precipitação acumulada mensal	188
Quadro 18 – Classificação climatológica SRS1, período de verão	195
Quadro 19 – Classificação categóricas das previsões para SRS1.....	209
Quadro 20 – Classificação climatológica SRS2, período de verão	210
Quadro 21 – Classificação categóricas das previsões para SRS2.....	224
Quadro 22 – Síntese das previsões categóricas para todas as sub-regiões em análise	225

LISTA DE TABELAS

Tabela 1 – Correlações entre a região SR1 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens.....	73
Tabela 2 – Correlações entre a região SR2 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens.....	75
Tabela 3 – Correlações entre a região SR3 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens.....	77
Tabela 4 – Medidas descritivas da precipitação acumulada mensal da SR1, 1980 a 2013 ..	81
Tabela 5 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (SON).....	85
Tabela 6 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(0,1,2) ₁₂ , para região SR1 (SON)	86
Tabela 7 – Modelos concorrentes SARIMAX e os respectivos critérios para a série SR1 (SON).....	87
Tabela 8 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,2) [1] ₁₂ , para região SR1 (SON)	88
Tabela 9 – Classificação climatológica das previsões, segundo o modelo Holt-Winters multiplicativo, para região SR1 (SON).....	89
Tabela 10 – Classificação climatológica das previsões, segundo os modelos combinados, para região SR1 (SON)	91
Tabela 11 – Comparação dos Modelos utilizando os critérios de seleção (SON).....	91
Tabela 12 – Teste Diebold e Mariano (1995) (SON)	92
Tabela 13 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (JJA).....	93
Tabela 14 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(1,1,2) ₁₂ , para região SR1 (JJA)	94
Tabela 15 – Modelos concorrentes SARIMAX e os respectivos critérios	95
Tabela 16 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,1) [1] ₁₂ , para região SR1 (JJA)	96
Tabela 17 – Classificação climatológica das previsões, segundo o modelo Holt-Winters multiplicativo, para região SR1 (JJA).....	97
Tabela 18 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR1 (JJA)	98
Tabela 19 – Comparação dos Modelos utilizando os critérios de seleção (JJA).....	98
Tabela 20 – Teste Diebold e Mariano (1995) (JJA)	99
Tabela 21 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (MAM).....	100
Tabela 22 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(1,1,2) ₁₂ , para região SR1 (MAM)	101
Tabela 23 – Modelos concorrentes SARIMAX e os respectivos critérios para SR1 (MAM)	102
Tabela 24 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,2) [1] ₁₂ , para região SR1(MAM)	103
Tabela 25 – Classificação climatológica das previsões, segundo o modelo Holt-Winters multiplicativo, para região SR1 (MAM).....	104

Tabela 26 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR1 (MAM)	105
Tabela 27 – Comparação dos Modelos utilizando os critérios de seleção (MAM)	105
Tabela 28 – Teste Diebold e Mariano (1995) (MAM).....	106
Tabela 29 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (DJF).....	107
Tabela 30 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(1,1,2) ₁₂ , para região SR1 (DJF)	108
Tabela 31 – Modelos concorrentes SARIMAX e os respectivos critérios.....	109
Tabela 32 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,2) [1] ₁₂ , para região SR1 (DJF)	109
Tabela 33 – Classificação climatológica das previsões, segundo o modelo Holt-Winters aditivo para região SR1 (DJF).....	111
Tabela 34 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR1 (DJF).....	112
Tabela 35 – Comparação dos Modelos utilizando os critérios de seleção (DJF).....	112
Tabela 36 – Teste Diebold e Mariano (1995) (DJF)	113
Tabela 37 – Desempenho dos modelos para SR1 de acordo com o critério MAPE.....	114
Tabela 38 – Medidas descritivas da precipitação acumulada mensal da SR2, 1980 a 2013	117
Tabela 39 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (SON)	121
Tabela 40 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0)(0,1,1) ₁₂ , para região SR2 (SON).....	121
Tabela 41 – Modelos concorrentes SARIMAX e os respectivos critérios para SR2 (SON)	122
Tabela 42 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0)(0,1,1) [1] ₁₂ , para região SR2 (SON).....	123
Tabela 43 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR2 (SON).....	125
Tabela 44 – Classificação climatológica das previsões, segundo os modelos combinados, para região SR2 (SON)	126
Tabela 45 – Comparação dos Modelos utilizando os critérios de seleção (SON)	126
Tabela 46 – Teste Diebold e Mariano (1995) (SON).....	127
Tabela 47 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (JJA)	128
Tabela 48 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1) ₁₂ para região SR2 (JJA).....	129
Tabela 49 – Modelos concorrentes SARIMAX e os respectivos critérios para SR2 (JJA) .	130
Tabela 50 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1] ₁₂ , para região SR2 (JJA).....	131
Tabela 51 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR2 (SON).....	132
Tabela 52 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR2 (JJA)	133
Tabela 53 – Comparação dos Modelos utilizando os critérios de seleção (JJA)	134
Tabela 54 – Teste Diebold e Mariano (1995) (JJA).....	135
Tabela 55 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (MAM)	136
Tabela 56 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1) ₁₂ , para região SR2 (MAM)	137

Tabela 57 – Modelos concorrentes SARIMAX e os respectivos critérios para a série SR2 (MAM).....	138
Tabela 58 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [1] ₁₂ , para região SR2 (MAM)	138
Tabela 59 – Classificação climatológica das previsões, segundo o modelo HWM e AES, para região SR2 (MAM)	140
Tabela 60 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR2 (MAM)	141
Tabela 61 – Comparação dos Modelos utilizando os critérios de seleção (MAM).....	141
Tabela 62 – Teste Diebold e Mariano (1995) (MAM)	142
Tabela 63 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (DJF)	143
Tabela 64 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0)(0,1,1) ₁₂ , para região SR2 (DJF)	144
Tabela 65 – Modelos concorrentes SARIMAX e os respectivos critérios SR2	145
Tabela 66 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1] ₁₂ , para região SR2 (DJF).....	146
Tabela 67 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR2 (DJF).....	147
Tabela 68 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR2 (DJF)	148
Tabela 69 – Comparação dos Modelos utilizando os critérios de seleção (DJF)	149
Tabela 70 – Teste Diebold e Mariano (1995) (DJF).....	150
Tabela 71 – Desempenho dos modelos para SR2 de acordo com o critério MAPE	151
Tabela 72 – Medidas descritivas da precipitação acumulada mensal da SR3, 1980 a 2013	154
Tabela 73 – Modelos concorrentes ARIMA e os respectivos critérios para a série SR3	157
Tabela 74 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1) ₁₂ , para região SR3 (SON)	158
Tabela 75 – Modelos concorrentes SARIMAX e os respectivos critérios para SR3 (SON)	159
Tabela 76 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [1] ₁₂ , para região SR3 (SON)	160
Tabela 77 – Classificação climatológica das previsões, segundo o modelo HW aditivo para região SR3 (SON)	161
Tabela 78 – Classificação climatológica das previsões, segundo os modelos combinados, para região SR3 (SON)	162
Tabela 79 – Comparação dos Modelos utilizando os critérios de seleção (SON).....	163
Tabela 80 – Teste Diebold e Mariano (1995) (SON)	164
Tabela 81 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR3 (JJA).....	164
Tabela 82 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1) ₁₂ para região SR3 (JJA)	165
Tabela 83 – Modelos concorrentes SARIMAX e os respectivos critérios para SR3 (JJA)..	166
Tabela 84 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [1] ₁₂ , para região SR3 (JJA)	166
Tabela 85 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo para região SR3 (SON).....	167
Tabela 86 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR3 (JJA)	168
Tabela 87 – Comparação dos Modelos utilizando os critérios de seleção (JJA).....	169
Tabela 88 – Teste Diebold e Mariano (1995) (JJA)	170

Tabela 89 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR3 (MAM)	170
Tabela 90 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1) ₁₂ , para região SR3 (MAM)	171
Tabela 91 – Modelos concorrentes SARIMAX e os respectivos critérios para SR3 (MAM)	172
Tabela 92 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1] ₁₂ , para região SR3 (MAM).....	173
Tabela 93 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR3 (MAM).....	174
Tabela 94 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR3 (MAM)	175
Tabela 95 – Comparação dos Modelos utilizando os critérios de seleção (MAM)	175
Tabela 96 – Teste Diebold e Mariano (1995) (MAM).....	176
Tabela 97 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR3 (DJF).....	177
Tabela 98 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1) ₁₂ , para região SR3 (DJF).....	178
Tabela 99 – Modelos concorrentes SARIMAX e os respectivos critérios SR3.....	179
Tabela 100 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1] ₁₂ , para região SR3 (DJF)	179
Tabela 101 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR3 (DJF)	181
Tabela 102 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR3 (DJF).....	182
Tabela 103 – Comparação dos Modelos utilizando os critérios de seleção (DJF).....	182
Tabela 104 – Teste Diebold e Mariano (1995) (DJF)	184
Tabela 105 – Desempenho dos modelos para SR3 de acordo com o critério MAPE.....	184
Tabela 106 – Correlações entre a região SRS1 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens	190
Tabela 107 – Correlações entre a região SRS2 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens	192
Tabela 108 – Medidas descritivas da precipitação acumulada mensal da SRS1, 1980 a 2013	197
Tabela 109 – Modelos concorrentes SARIMA e os respectivos critérios para a série SRS1 (NDJFM)	201
Tabela 110 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(1,1,1) ₁₂ , para região SRS1 (NDJFM)	201
Tabela 111 – Modelos concorrentes SARIMAX e os respectivos critérios para SRS1.....	203
Tabela 112 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [3] ₁₂ , para região SRS1 (DJF)	204
Tabela 113 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SRS1 (NDJFM)	205
Tabela 114 – Classificação climatológica das previsões, segundo o modelo combinado, para região SRS1 (NDJFM)	206
Tabela 115 – Comparação dos Modelos utilizando os critérios de seleção (Nov a Dez) SRS1.....	207
Tabela 116 – Teste Diebold e Mariano (1995) (NDJFM) SRS1	208

Tabela 117 – Desempenho dos modelos para SRS1 de acordo com o critério MAPE	209
Tabela 118 – Medidas descritivas da precipitação acumulada mensal da SRS2, 1980 a 2013.....	212
Tabela 119 – Modelos concorrentes SARIMA e os respectivos critérios para a série SRS2 (NDJFM).....	216
Tabela 120 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (1,1,1) ₁₂ , para região SRS2 (NDJFM).....	217
Tabela 121 – Modelos concorrentes SARIMAX e os respectivos critérios SRS2.....	218
Tabela 122 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [2] ₁₂ , para região SRS2 (NDJFM).....	219
Tabela 123 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e HWA, para região SRS2 (NDJFM).....	220
Tabela 124 – Classificação climatológica das previsões, segundo o modelo Combinado, para região SRS2 (NDJFM).....	221
Tabela 125 – Comparação dos Modelos utilizando os critérios de seleção (Nov a Dez) SRS2	222
Tabela 126 – Teste Diebold e Mariano (1995) (NDJFM) SRS2.....	223
Tabela 127 – Desempenho dos modelos para SRS2 de acordo com o critério MAPE	224

LISTA DE SIGLAS E SÍMBOLOS

AR	Modelo Autorregressivo
ARMA	Modelo Autorregressivo e de Médias Móveis
ARIMA	Modelo Autorregressivo Integrado de Médias Móveis
ARMAX	Modelo Autorregressivo e de médias móveis com entrada de variáveis exógenas
ASAS	Alta Subtropical do Atlântico Sul
AEHW	Alisamento Exponencial de Holt-Winters
AES	Alisamento exponencial simples
DM	Teste Deibod-Mariano
FAC	Função de autocorrelação
FACP	Função de Autocorrelação Parcial
GPC	Grupo de pesquisa em clima
HWM	Holt-Winters multiplicativo
HWA	Holt-Winters aditivo
INMET	Instituto Nacional de Meteorologia
MA	Modelo de Médias Móveis
SARIMA	Modelo Autorregressivo Integrado de Médias Móveis Sazonal
ε	Erro aleatório
ST	Série Temporal
SR1	Sub-região Sul 1 (Lat: -24,625 a -28,625; Log: -48,625 a -49,625)
SR2	Sub-região Sul 2 (Lat: -25,625 a -29,625; Log: -51,625 a -52,625)
SR3	Sub-região Sul 3 (Lat: -29,625 a -33,625; Log: -52,625 a -53,625)
SRS1	Sub-região Sudeste 1 (Lat: -20,625 a -23,625; Log: -42,625 a -46,625)
SRS2	Sub-região Sudeste 2 (Lat: -20,625 a -23,625; Log: -52,625 a -54,625)
TSM	Temperatura da superfície do mar
Z_t	Série temporal
Φ	Parâmetro autorregressivo
Φ	Parâmetro autorregressivo sazonal
Θ	Parâmetro de médias móveis
Θ	Parâmetro de médias móveis sazonal
p	Número de parâmetros autorregressivos
d	Número de diferenciações
q	Número de parâmetros de médias móveis
P	Número de parâmetros autorregressivos sazonais
D	Número de diferenciações sazonais
Q	Número de parâmetros de médias móveis sazonais
μ	Média de uma variável aleatória

SUMÁRIO

1	INTRODUÇÃO	33
1.1	PROBLEMÁTICA	36
1.2	OBJETIVOS	36
1.2.1	Objetivo geral	36
1.2.2	Objetivos específicos	36
1.3	JUSTIFICATIVA	37
1.4	ORGANIZAÇÃO DO TRABALHO	38
2	REFERENCIAL TEÓRICO	39
2.1	REGIMES DE PRECIPITAÇÃO NO BRASIL	39
2.2	ANÁLISE MULTIVARIADA	43
2.2.1	Análise de agrupamentos	44
2.3	SÉRIES TEMPORAIS	47
2.4	MODELOS COMBINADOS DE PREVISÃO	48
2.4.1	Modelos Box-Jenkins	49
2.4.2	Modelo ARIMAX	53
2.4.3	Alisamento Exponencial	55
2.4.3.1	<i>Alisamento Exponencial de Holt-Winters (AEHW)</i>	56
2.4.3.2	<i>Alisamento Exponencial Biparamétrico (AEB)</i>	58
2.4.3.3	<i>Alisamento Exponencial Simples (AES)</i>	59
2.5	MÉTODOS PARA SELEÇÃO DE MODELOS/MEDIDAS DE ACURÁCIA	59
2.6	CLASSES PARA CATEGORIZAÇÃO DA PRECIPITAÇÃO	61
2.7	TESTE ESTATÍSTICO DEIBOLD – MARIANO (1995)	63
3	METODOLOGIA	65
4	ANÁLISE DOS RESULTADOS	69
4.1	SUB-REGIÕES COM CARACTERÍSTICAS SIMILARES DE PRECIPITAÇÃO	69
4.2	CORRELAÇÃO ENTRE AS SUB-REGIÕES E A TSM	73
4.2.1	Análise da Sub-Região Sul 1 (SR1)	79
4.2.2	Modelos de ST para Sub-Região Sul 1	83
4.2.2.1	<i>Modelo SARIMA (SON)</i>	83
4.2.2.2	<i>Modelo SARIMAX (SON)</i>	87
4.2.2.3	<i>Alisamento Exponencial Modelo Holt-Winters (SON)</i>	88
4.2.2.4	<i>Modelos Combinados (SON)</i>	90
4.2.2.5	<i>Modelo SARIMA (JJA)</i>	93
4.2.2.6	<i>Modelo SARIMAX (JJA)</i>	94
4.2.2.7	<i>Alisamento Exponencial Modelo Holt-Winters (JJA)</i>	96
4.2.2.8	<i>Modelos Combinados (JJA)</i>	98
4.2.2.9	<i>Modelo SARIMA (MAM)</i>	100
4.2.2.10	<i>Modelo SARIMAX (MAM)</i>	102
4.2.2.11	<i>Alisamento Exponencial Modelo Holt-Winters (MAM)</i>	103
4.2.2.12	<i>Modelos Combinados (MAM)</i>	105
4.2.2.13	<i>Modelo SARIMA (DJF)</i>	107
4.2.2.14	<i>Modelo SARIMAX (DJF)</i>	108
4.2.2.15	<i>Alisamento Exponencial Modelo Holt-Winters (DJF)</i>	110
4.2.2.16	<i>Modelos Combinados (DJF)</i>	111
4.2.2.17	<i>Síntese dos principais resultados encontrados para SR1</i>	114

4.2.3	Análise da Sub-Região Sul 2 (SR2)	115
4.2.4	Modelos de Séries Temporais para Sub-Região Sul 2	119
4.2.4.1	<i>Modelo SARIMA (SON)</i>	119
4.2.4.2	<i>Modelo SARIMAX (SON)</i>	122
4.2.4.3	<i>Modelos de Alisamento Exponencial e de Holt-Winters (SON)</i>	124
4.2.4.4	<i>Modelos Combinados (SON)</i>	126
4.2.4.5	<i>Modelo SARIMA (JJA)</i>	128
4.2.4.6	<i>Modelo SARIMAX (JJA)</i>	130
4.2.4.7	<i>Alisamento Exponencial Simple e de Holt-Winters (JJA)</i>	132
4.2.4.8	<i>Modelos Combinados (JJA)</i>	133
4.2.4.9	<i>Modelo SARIMA (MAM)</i>	136
4.2.4.10	<i>Modelo SARIMAX (MAM)</i>	137
4.2.4.11	<i>Alisamento Exponencial Modelo Holt-Winters (MAM)</i>	139
4.2.4.12	<i>Modelos Combinados (MAM)</i>	141
4.2.4.13	<i>Modelo SARIMA (DJF)</i>	143
4.2.4.14	<i>Modelo SARIMAX (DJF)</i>	145
4.2.4.15	<i>Alisamento Exponencial Modelo Holt-Winters (DJF)</i>	146
4.2.4.16	<i>Modelos Combinados (DJF)</i>	148
4.2.4.17	<i>Síntese dos principais resultados encontrados para SR2</i>	151
4.2.5	Análise da Sub-Região Sul 3 (SR3)	152
4.2.6	Modelos de Séries Temporais para Sub-Região Sul 3	156
4.2.6.1	<i>Modelo SARIMA (SON)</i>	156
4.2.6.2	<i>Modelo SARIMAX (SON)</i>	159
4.2.6.3	<i>Modelos de Alisamento Exponencial e de Holt-Winters (SON)</i>	161
4.2.6.4	<i>Modelos Combinados (SON)</i>	162
4.2.6.5	<i>Modelo SARIMA (JJA)</i>	164
4.2.6.6	<i>Modelo SARIMAX (JJA)</i>	166
4.2.6.7	<i>Alisamento Exponencial Simple e de Holt-Winters (JJA)</i>	167
4.2.6.8	<i>Modelos Combinados (JJA)</i>	168
4.2.6.9	<i>Modelo SARIMA (MAM)</i>	170
4.2.6.10	<i>Modelo SARIMAX (MAM)</i>	172
4.2.6.11	<i>Alisamento Exponencial Modelo Holt-Winters (MAM)</i>	173
4.2.6.12	<i>Modelos Combinados (MAM)</i>	175
4.2.6.13	<i>Modelo SARIMA (DJF)</i>	177
4.2.6.14	<i>Modelo SARIMAX (DJF)</i>	178
4.2.6.15	<i>Alisamento Exponencial Modelo Holt-Winters (DJF)</i>	180
4.2.6.16	<i>Modelos Combinados (DJF)</i>	182
4.2.6.17	<i>Síntese dos principais resultados encontrados para SR3</i>	184
4.3	SUB-REGIÕES SUDESTE/CENTRO OESTE COM CARACTERÍSTICAS SIMILARES DE PRECIPITAÇÃO	186
4.4	CORRELAÇÃO ENTRE AS SUB-REGIÕES SRS1 E SRS2 COM A TSM	189
4.4.1	Análise da Sub-Região Sudeste/Centro Oeste 1 (SRS1)	195
4.4.2	Modelos de Séries Temporais para Sub-Região Sudeste/Centro Oeste 1	199
4.4.2.1	<i>Modelo SARIMA (NDJFM)</i>	199
4.4.2.2	<i>Modelo SARIMAX (NDJFM)</i>	202
4.4.2.3	<i>Alisamento Exponencial Modelo Holt-Winters (NDJFM) SRS1</i>	205
4.4.2.4	<i>Modelos Combinados (NDJFM)</i>	206
4.4.2.5	<i>Síntese dos principais resultados encontrados para SRS1</i>	209
4.4.3	Análise da Sub-Região Sudeste/Centro Oeste 2 (SRS2)	210
4.4.4	Modelos de Séries Temporais para Sub-Região Sudeste/Centro Oeste 2	215

4.4.4.1	<i>Modelo SARIMA (NDJFM)</i>	215
4.4.4.2	<i>Modelo SARIMAX (NDJFM)</i>	217
4.4.4.3	<i>Alisamento Exponencial Modelo Holt-Winters (NDJFM) SRS2</i>	220
4.4.4.4	<i>Modelos Combinados (NDJFM)</i>	221
4.4.4.5	<i>Síntese dos principais resultados encontrados para SRS2</i>	224
5	CONCLUSÃO	227
	REFERÊNCIAS BIBLIOGRÁFICAS	229
	APÊNDICE A – Script R (Parcial)	239

1 INTRODUÇÃO

Nos dias atuais, cada vez mais, tem crescido a preocupação com fatores climáticos extremos; tais como: secas, enchentes, temperaturas anormalmente altas/baixas, tempestades, chuvas de granizo, etc., que segundo Marengo (2006) estão associados a variações climáticas e impactam diretamente na sociedade. Além desses efeitos diretos, de acordo com Medeiros et al. (2018) a variabilidade climática acentuada tem impactado de maneira negativa na saúde humana, ocasionando o aumento da incidência de doenças infecciosas transmitidas por mosquitos.

Para Santos (2012, p. 17), “eventos extremos que podem ser o excesso ou a falta de chuva causam consequências contundentes como a falta de água, aumento de doenças, danificação de moradias, erosão do solo e apodrecimento da vegetação”. Mitterstein e Severo (2007), reforçam que a variabilidade climática tem exercido influências no desenvolvimento das civilizações. Secas e inundações devastam plantações, destroem cidades provocando prejuízos econômicos e sociais.

Há uma preocupação constante em compreender o comportamento do clima em sua extrema inconstância, ao longo do tempo e conforme os espaços, para fins de predição ou para gerar explicações sobre seu conhecimento. E tal preocupação se reverte de significância quando se refere aos seus efeitos sociais, econômicos e ambientais, no campo, na cidade e na qualidade de vida da população em geral (SANTOS, 2017, p. 1347).

Dessa forma, uma das principais variáveis meteorológicas que atraem interesse especial, devido à influência direta nos setores produtivos como: agricultura e produção de energia elétrica é a precipitação pluviométrica (ANTONINI et al., 2009; CERA; FERRAZ, 2015; OLIVEIRA, 2010; PALMIERI, 2009; QUEIROZ et al., 2013; SILVA et al., 2007). Para Gouvea et al. (2018), conhecer o comportamento da precipitação é uma ferramenta importante para o planejamento em diversos setores da economia, sendo fundamental para atenuar danos sociais. Mello e Silva (2009) reforçam que dentro do ciclo hidrológico a precipitação é uma variável fundamental, entender seu comportamento é de suma importância para estudos estratégicos do meio ambiente, geração de energia e manejo agrícola.

Para Santos (2012), a precipitação influencia na produção de alimentos, no planejamento energético, urbano e na saúde pública. O conhecimento de seu comportamento, é de grande interesse para diversos órgãos públicos e privados, servindo como uma ferramenta para auxiliar no planejamento a curto, médio e longo prazo. Já Arsego (2017) ressalta que de

todas as atividades econômicas, o setor primário é o mais dependente das condições meteorológicas, tendo como uma das principais variáveis causadoras de danos a precipitação.

Para Silva et al., (2008) e Cavalcanti et al. (2009), o conhecimento e a integração de dados meteorológicos futuros pode ajudar na organização, manejo e gestão de recursos em diversos setores da economia. Segundo Santos et al. (2017), os modelos estatísticos podem contribuir para compreensão e previsão do clima, e devem ser integrados as diversas linhas de pesquisas na meteorologia.

Estudos vêm desenvolvendo e aperfeiçoando modelos estatísticos cada vez mais sofisticados, com o intuito de melhorar o conhecimento e facilitar o planejamento e a vida do homem (BARNETT; PREISENDORFER, 1987; BARNSTON et al., 2003; MORRETIN; TOLOI 2004; WILKS, 2002). No campo da Meteorologia torna-se essencial, conhecer previamente um valor futuro de uma variável climática como, por exemplo, a pluviométrica que pode facilitar a tomada de decisões em áreas como as ligadas a setores produtivos.

Dessa forma, é de fundamental importância o uso de modelos estatísticos adequados e de fácil aplicação para se fazer previsões e produzir diagnósticos o mais próximo do real e que possam ser amplamente utilizados. Entretanto, para ajustar modelos matemáticos/estatísticos que forneçam previsões confiáveis é necessário o estudo conjunto de diversas variáveis.

De acordo com Biscaro (2007, p. 7), “o estudo do clima de um local ou região é feito com base na análise estatística dos dados observados pela meteorologia, sendo contabilizados entre outras coisas as médias, as correlações, frequências, distribuições”.

Entre os modelos estatísticos, os modelos de análise multivariada e os modelos de previsão de Séries Temporais (ST) tem ganhado destaque e espaço, principalmente devido ao incremento computacional que permite trabalhar com extensos bancos de dados. Modelos de ST vêm sendo empregados satisfatoriamente em diversas áreas e têm surgido como necessidade atual o seu emprego em variáveis climáticas, devido aos diferentes impactos causadas pelas mesmas (BROCKWELL; DAVIS, 2002; CHECHI; SANCHES, 2013; LÚCIO et al., 2010; SOUZA et al. 2009; TIBULO, 2014; XAVIER, 2001). Para Duchon e Hale (2012) a análise de ST é amplamente utilizada em estudos meteorológicos porque a grande maioria das observações de variáveis atmosféricas e terrestres são ordenadas no tempo (ou espaço).

Nos últimos dez anos, os estudos relacionados a climatologia em escala global, regional e, mesmo em escala local (microclima), tem se utilizado de diversos modelos estatísticos de previsão para se analisar o comportamento de dados envolvendo os principais elementos climáticos (CHECHI; SANCHES, 2013, p. 45).

A variável proposta a ser modelada neste trabalho é a precipitação pluviométrica acumulada mensal, para regiões brasileiras que se destacam economicamente no cenário nacional. Sendo a precipitação de suma importância para o sistema produtivo e econômico brasileiro (CAVALCANTI et al., 2009). A precipitação interfere diretamente no setor primário e no setor secundário que depende diretamente da produção de energia. Cabe ressaltar que grande parte da produção de energia elétrica é dependente do regime de chuvas, pois o sistema de produção através de hidrelétricas depende do nível de água nos rios que está associado à quantidade pluviométrica (FREITAS; SOITO, 2008).

Nesse contexto, a análise multivariada em conjunto com ST aplicadas a dados pluviométricos fornece uma ferramenta complementar na previsão numérica sazonal. Além disso, em períodos em que modelos numéricos sazonais apresentam baixa previsibilidade, pode ser uma ferramenta essencial, considerando que o regime de chuvas interfere diretamente na qualidade de vida dos habitantes de qualquer região e na área econômica determina o sucesso ou o fracasso de vários empreendimentos.

Uma importante distinção deve ser feita entre os tipos de modelos: os modelos dinâmicos de previsão usam complexas equações dinâmicas que procuram reproduzir os principais componentes do sistema terrestre, enquanto os modelos estatísticos/ estocásticos de previsão usam relações históricas entre as variáveis físicas. Ou seja, um longo período de registro é examinado para tendências, sazonalidades, ciclos, extremos, e as relações entre os produtos de previsão e preditores relevantes. Os primeiros datam seu uso a partir do meio do século passado, com a melhoria computacional e os modelos estatísticos tem sido utilizados desde o final de 1800 (TROCCOLI, 2010).

A presente pesquisa busca demonstrar a importância do ajuste de modelos estatísticos que também podem ser usados para diversas variáveis climatológicas como: radiação solar, umidade relativa do ar, temperatura mínima e máxima entre outras.

Em suma, temos como problema de pesquisa: aprimorar e ajustar modelos estatísticos de previsão de ST para a variável precipitação acumulada mensal que levem em consideração às características das séries históricas de cada região ou microrregião de forma que se consiga prever com maior eficiência a precipitação sazonal das regiões em estudo, vindo a ser uma ferramenta complementar aos modelos dinâmicos.

1.1 PROBLEMÁTICA

A problemática que orienta a presente pesquisa está voltada para identificar características e influências (relações de causa e efeito) das séries históricas de precipitação pluviométrica sazonal que possibilitem ajustar modelos de ST univariados e/ou multivariados, de acordo com as características de cada região e dados disponíveis, que possam ser largamente empregados na meteorologia para auxiliar nas previsões da precipitação pluviométrica sazonal. Sendo esses modelos um auxílio aos modelos de previsão dinâmicos quando os mesmos por algum motivo apresentem baixa previsibilidade. Para Stern e Easterling (1999) não se pode deixar a impressão que a única forma de resolução é através métodos numéricos. Métodos estatísticos também podem ser usados, quando outros métodos não estão disponíveis.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Aplicar modelos estatísticos de séries temporais para a previsão da precipitação pluviométrica sazonal em sub-regiões das regiões Sul, Sudeste e Centro Oeste do Brasil, investigando entre os modelos das classes SARIMA, SARIMAX, Alisamento Exponencial e Combinados os que melhor se ajustam e que possam ser usados como ferramenta de apoio aos modelos dinâmicos na previsão da precipitação acumulada mensal.

1.2.2 Objetivos específicos

- Abordar aplicações dos modelos propostos SARIMA, SARIMAX e da classe de Alisamento Exponencial a variável precipitação acumulada mensal;
- Determinar sub-regiões com características semelhantes de precipitação pluviométrica;
- Determinar a influência da temperatura da superfície do mar (TSM) na precipitação acumulada mensal das sub-regiões;
- Ajustar os modelos SARIMAX, introduzindo como variável exógena aTSM das regiões definidas pela Correlação de Pearson;
- Ajustar os modelos combinados de previsão (agregação de previsões);

- Comparar o desempenho das previsões dos modelos da classe SARIMA, SARIMAX, Alisamento Exponencial e modelos Combinados;
- Construir gráficos para determinar as normais climáticas de cada região ou microrregião, utilizando-se de técnicas quantílicas;
- Classificar e comparar as previsões dos modelos utilizados através das técnicas quantílicas;
- Definir se os modelos estatísticos propostos podem ser uma ferramenta complementar aos modelos dinâmicos para a previsão da precipitação acumulada mensal.

1.3 JUSTIFICATIVA

Os extremos de precipitação sejam eles secas ou inundações, tem causado inúmeros transtornos tanto na área econômica como na área social, interferindo diretamente nos sistemas produtivos de toda a sociedade, do setor primário ao terciário, causando prejuízos e prejudicando o bem-estar de todos os habitantes de qualquer região atingida.

De acordo com, Gerlitz et al. (2016) a previsão da precipitação sazonal é uma tarefa difícil e crucial no campo da climatologia, devido as consequências ecológicas, econômicas e sociais de condições climáticas como secas ou inundações. Para Vasconcelos Júnior (2014), a previsão sazonal aliada ao conhecimento do início e fim da estação chuvosa é uma poderosa ferramenta para tomada de decisões no nordeste brasileiro.

Segundo Pereira et al. (2015, p. 68) “dos fenômenos meteorológicos de importância econômica para a sociedade a precipitação é sem dúvidas um dos mais importantes”. Para Checi e Bayer (2012) “A análise de séries temporais aplicada a dados climatológicos atrai interesse especial haja vista que o clima interfere diretamente em muitas áreas, determinando o sucesso ou o fracasso de vários empreendimentos”.

Dada a alta dependência dos cultivos agrícolas às condições climáticas ao longo do período de desenvolvimento da cultura, a compreensão dos mecanismos responsáveis pela variabilidade climática e uma previsão confiável das condições meteorológicas ao longo do período de desenvolvimento torna-se fator determinante para o sucesso ou fracasso da safra agrícola (ARSEGO, 2017, p. 23).

Em muitos casos as previsões através de modelos dinâmicos não têm conseguido prever adequadamente os fenômenos a fins de se promover uma prevenção adequada e evitar os transtornos a sociedade como um todo, principalmente das classes mais humildes escassas de informações ou de acesso a notícias confiáveis. Para Gerlitz et al. (2016) e Lúcio et al. (2010),

os sistemas dinâmicos que controlam a evolução climática, têm forte componente caótica. Uma certa previsibilidade é conferida devido aos lentos processos oceânicos em escala sazonal.

Desta forma a pesquisa pretende desenvolver ajustes de modelos estatísticos de previsão de ST que ofereçam resultados de previsão para a variável precipitação pluviométrica sazonal, para regiões Sul, Sudeste e Centro Oeste do Brasil, regiões com influência significativa na economia, quando os modelos numéricos sazonais por algum motivo falharem, sejam eles por falta de informação, por deficiente representação dos processos físicos que influenciam no clima numa escala sazonal ou subsazonal, ou até mesmo pela própria divulgação de resultados, oferecendo suporte mais fidedigno para tomadas de decisões, contribuindo assim significativamente para o sistema produtivo brasileiro.

Os mesmos modelos encontrados também podem vir a auxiliar na área social, oferecendo um alerta oportuno e em tempo hábil para enchentes ou períodos prolongados de secas.

1.4 ORGANIZAÇÃO DO TRABALHO

O presente trabalho está dividido em cinco capítulos, os quais buscam o bom entendimento da proposta central, através da apresentação do trabalho desenvolvido:

No capítulo 1, aborda-se uma introdução da pesquisa, contendo a importância do trabalho, justificativa e delimitação do tema.

No capítulo 2, reúnem-se informações sobre precipitação e revisão bibliográfica sobre análise multivariada de agrupamento, ST, os modelos de previsão ARIMA, ARMAX, modelos Combinados e da classe de Alisamento Exponencial com as suas características para emprego no problema, categorização da precipitação acumulada mensal utilizando técnicas quantílicas e as técnicas de acurácia MAPE, MAD, SSE e EQM, além do teste estatístico Deibold-Mariano.

No capítulo 3, é descrita a metodologia empregada para aplicação dos modelos de análise multivariada de agrupamento, dos modelos de série temporal ARIMA, ARMAX, modelos combinados e Alisamento Exponencial, técnicas de acurácia e quantílica, emprego do teste estatístico Deibol-Mariano.

O capítulo 4 apresenta os resultados obtidos das avaliações estatísticas com emprego das técnicas de análise de agrupamentos, modelos de previsão de ST, classificação categórica e pontual das previsões da precipitação acumulada e o teste estatístico Deibod-Mariano.

Por fim, no quinto capítulo é apresentada uma conclusão geral deste trabalho.

2 REFERENCIAL TEÓRICO

A preocupação com variações climáticas tem aumentado continuamente nos últimos anos. Principalmente devido à grande influência que variáveis como a precipitação exercem sobre os setores produtivos.

Eventos extremos de precipitação, segundo Pampuch (2014), geram grande preocupação devido à sua capacidade em influenciar atividades econômicas, agrícolas, interferir na disponibilidade de água, geração de energia elétrica e afetar diretamente a sociedade.

Para Santos et al. (2017) a climatologia tem sido objeto de pesquisas e compreender o comportamento do clima e sua extrema inconstância ao longo do tempo, se reverte de significância quando se refere aos efeitos sociais, econômicos, no campo, na cidade e na qualidade de vida da população em geral. De acordo com Biscaro (2007), séries históricas de elementos climáticos observados no decorrer de vários anos, podem fornecer informações bastante confiáveis.

A habilidade de antecipar como o clima irá variar de um ano para o outro, possibilita melhor gerenciamento da agricultura, recursos hídricos e atividade pesqueira, além da possibilidade de contribuição relevante nos campos dos transportes, abastecimento, turismo e lazer. Pela incorporação das previsões climáticas nas decisões gerenciais, a humanidade se tornará melhor adaptada aos ritmos irregulares do clima (SILVA et al., 2008, p. 481).

O conhecimento e a interação de dados meteorológicos ajudam na organização, manejo e gestão de recursos sejam eles privados ou públicos. Entretanto, é sabido que cada região tem características específicas que devem ser levadas em consideração e estudadas separadamente.

A seguir serão abordados alguns aspectos relevantes ao desenvolvimento deste estudo.

2.1 REGIMES DE PRECIPITAÇÃO NO BRASIL

Gerlitz et al. (2016) descrevem que a precipitação é o resultado de uma interação complexa de fenômenos atmosféricos em diferentes condições espaciais e temporais. Condições climáticas regionais são influenciadas por padrões atmosféricos de grande escala, além de persistentes condições de contorno, como a temperatura da superfície do mar (TSM), cobertura do solo, radiação solar, etc. O fato de as condições de contorno serem frequentemente

caracterizadas por uma variabilidade de baixa frequência, como a TSM, proporciona uma previsibilidade das condições climáticas a médio prazo de muitas regiões.

Reboita et al. (2010) apresentaram um estudo sobre os diferentes regimes de precipitação da América do Sul. Os autores relatam que as terras da América do Sul por estarem em diferentes latitudes e com formas de relevos variados proporcionam a formação de diversos sistemas atmosféricos. Desta forma, os autores dividem o Brasil em quatro regiões de acordo com as similaridades das médias de precipitação mensal.

O Brasil possui diferentes regimes de precipitação, em razão de sua vasta extensão territorial, desde a região equatorial até latitudes subtropicais, e de sua complexidade topográfica. De norte a sul encontra-se uma grande variedade de climas com distintas características regionais, (MARENGO; NOBRE, 2010, p. 200).

Grimm (2009) descreve as principais características climáticas da região Sul. Ressalta-se a precipitação uniforme durante o ano, com uma transição entre os subtropicais e latitudes médias. Ao Norte domina o regime de monção característica das regiões tropicais e subtropicais, enquanto ao sul há distribuição aproximadamente uniforme, característica das latitudes médias.

Para Reboita et al. (2010) a precipitação da região Sul é bem distribuída ao longo do ano por estar associada a vários fatores: sistemas frontais, Ciclones e frentes frias, complexos convectivos de mesoescala, sistemas ciclônicos, bloqueio Atmosférico, Zona de Convergência do Atlântico Sul (ZCAS), Linhas de Instabilidade (LI), vórtices ciclônicos de altos níveis, entre outros (VCANs).

Nunes et al. (2009) retratam a precipitação da região Sudeste como irregular, apresentando variados regimes climáticos, que vão do tropical ao subtropical. A distribuição da pluviosidade é fortemente influenciada pelo relevo, atuação de frentes e continentalidade. O que proporciona a formação de sub-regiões com similaridades de precipitação. Por ser uma região de transição tropical/subtropical, a precipitação apresenta menores acúmulos anuais na porção Norte e maiores acumulados no Sul. Para Jorgetti (2008) a ZCAS, é o sistema atmosférico dominante da região sudeste e produz chuvas intensas durante o verão em uma linha com orientação noroeste-sudeste.

Para Pampuch (2014) a região sudeste apresenta um ciclo anual bem definido, estação chuvosa no verão e inverno seco. Ainda segundo a autora, o Sudeste não apresenta homogeneidade da climatologia de precipitação para toda sua área, sendo necessário encontrar sub-regiões homogêneas.

Para Reboita et al. (2010), os totais pluviométricos da região Centro-Oeste e Sudeste são máximos no verão e mínimos no inverno (características de um sistema de monção). Na Região Centro-Oeste, o setor mais ao norte sofre influência dos sistemas que atuam na Amazônia. Já a região mais ao Sul sofre influência das frentes frias e linhas de instabilidade. Para a região Sudeste os baixos acumulados pluviométricos no inverno estão associados a Alta Subtropical do Atlântico Sul (ASAS), pois nesta estação está na sua posição mais oeste, se estendendo até a região sudeste do Brasil.

Alves (2009) apresenta detalhes da precipitação na região Centro-Oeste. Segundo o autor a região possui um verão chuvoso e quente, enquanto o inverno é seco e com temperaturas amenas. A variação sazonal do regime de precipitação define dois regimes de precipitação, inverno seco e verão chuvoso.


Kayano e Andreoli (2009) resumiram as variações sazonais e de baixa frequência da precipitação no Nordeste do Brasil. A região possui intensa variabilidade interanual da precipitação e apresenta três tipos de clima: clima litorâneo, clima tropical e tropical semiárido. A diversidade se deve a atuação de diversos mecanismos: posição geográfica, relevo, natureza da superfície e sistemas de pressão atuantes na região. As variações de precipitação também estão associadas ao El Niño-Oscilação Sul (ENOS).

Vasconcelos Júnior (2014), relata que 60% do território do nordeste brasileiro apresenta clima semiárido, com uma significativa irregularidade da precipitação temporal e espacial. Para o autor a pluviometria da região é basicamente regulada pela TSM.

E para a região Norte, a pluviosidade aponta uma significativa heterogeneidade espacial e sazonal, sendo a região com maior total pluviométrico anual. Observa-se algumas sub-regiões, a primeira e com maior pluviosidade engloba o litoral do Amapá e o setor ocidental da região. O segundo centro está na parte central da Amazônia, o terceiro centro localiza-se na parte sul da região amazônica e há ainda um quarto centro a leste da bacia Amazônica, segundo Marengo e Nobre (2009). Ainda segundo os autores há uma defasagem da ordem de seis meses entre o máximo de chuva observado na região norte da região Amazônica (meses de junho e julho) e a região sul com o período chuvoso iniciando em dezembro.

Utilizando dados em grade (XAVIER et al., 2015) no período de 1980 – 2013 foi calculada a climatologia da precipitação em todo o Brasil (Figura 1).

Figura 1 – Climatologia da precipitação no Brasil, utilizando dados em grade



Fonte: Grupo de Pesquisa em Clima (GPC); Xavier et al. (2015).

Uma importante influência observada para todas as regiões do Brasil é a TSM. Segundo Cataldi et al. (2010), a variabilidade das condições da TSM tem uma influência notável no sistema atmosférico, sendo de grande relevância, o seu conhecimento para o desenvolvimento

de prognósticos climáticos. Para KHAN et al. (1998) diversas pesquisas indicam que anomalias das precipitações na região Sul do Brasil estão sob influência da temperatura do mar de algumas regiões do oceano Pacífico e do oceano Atlântico.

Andreoli e Kayano (2007), descrevem que a precipitação da região nordeste tem sido fortemente relacionada às anomalias de TSM. Os autores relatam que a TSM do Atlântico Sul é de suma importância para a precipitação do Nordeste e possui um peso de influência maior quando comparado com o Atlântico Norte. Luz (2010) conclui que a TSM do Atlântico Sul pode alterar consideravelmente os padrões de precipitação no estado de São Paulo.

As regiões geográficas do Brasil não refletem a real distribuição climatológica da precipitação, bem como a TSM pode influenciar de forma diferente cada região. Sendo necessário encontrar sub-regiões com maior similaridade para que as previsões sazonais consigam ser fidedignas com a realidade observada. Desta forma as literaturas citadas servem como um amparo teórico para o início de uma modelagem na busca de sub-regiões através da técnica de análise multivariada de cluster e dentro de cada sub-região encontrar a relação de com a TSM através da Correlação de Pearson.

2.2 ANÁLISE MULTIVARIADA

A Análise Multivariada pode auxiliar a determinar as variáveis que mais influenciam na precipitação pluviométrica. Para Gerhardt et al. (2001), a análise multivariada é um conjunto de técnicas estatísticas que trata simultaneamente muitas variáveis.

A técnica estatística de análise multivariada mostra-se, cada vez mais, como uma poderosa ferramenta para análise e avaliação de dados em diversas áreas. Por ser multidisciplinar, conforme Vicini (2005) e Vicini et al. (2018) está inserida em várias áreas do conhecimento, por isso, faz-se necessária a sua aplicação, o seu entendimento e a sua interpretação como ferramenta de pesquisa. Segundo Kubrusly e Saboia (2006), a utilização de técnicas de análise multivariada tem se mostrado eficiente, pois permite uma visão mais global dos fenômenos estudados.

“Análise Multivariada corresponde a um grande número de métodos e técnicas que utilizam, simultaneamente, todas as variáveis na interpretação teórica de um conjunto de dados obtidos” (MOITA NETO, 2004, p. 3). De acordo com Vicini (2005) e Vicini e et al. (2018), o desafio da análise multivariada consiste em interpretar um conjunto de dados e ser capaz de traduzir as informações que estão contidas nele.

Com auxílio da análise multivariada de agrupamento, pretende-se determinar as sub-regiões com similaridades de precipitação acumulada mensal.

2.2.1 Análise de agrupamentos

A técnica de análise de agrupamentos permite verificar a relação de interdependência entre as variáveis, segundo Souza e Silva (2009). Ainda segundo os autores um *cluster* visa agrupar variáveis com características comuns de maior homogeneidade nos grupos e grande heterogeneidade entre os grupos, sem perder informações de todo o conjunto de dados em estudo.

Para Vicini (2005) e Saad (2009), a análise de agrupamentos estuda todo um conjunto de relações interdependentes, sendo que o objetivo é encontrar e separar objetos em grupos similares. A técnica não faz distinção entre variáveis dependentes e independentes, relação do tipo causa e efeito.

A análise de agrupamentos (*cluster analysis*) não pressupõe um número nem uma estrutura de conglomerados. Toma como base similaridades (ou proximidades) entre itens (objetos, indivíduos ou variáveis), que podem ser, de alguma forma, medidas. Como resultado, obtém-se certo número de conglomerados no qual se agrupam, devido a sua proximidade, de acordo com Rinaldi, Morabito e Tachibana (2009).

Quando o interesse é verificar como as amostras se relacionam, ou seja, o quanto estas são semelhantes, segundo as variáveis utilizadas no trabalho, destacam-se dois métodos, que podem ser utilizados: a análise de agrupamento hierárquico e a análise fatorial com análise de componentes principais (VICINI, 2005, p. 11).

Para contornar a influência de diferentes escalas, faz-se necessário padronizar as variáveis, segundo Marchesan, Souza e Menezes (2011) e Saad (2009), ou seja, subtraímos a média do grupo de cada valor e dividimos pelo desvio padrão:

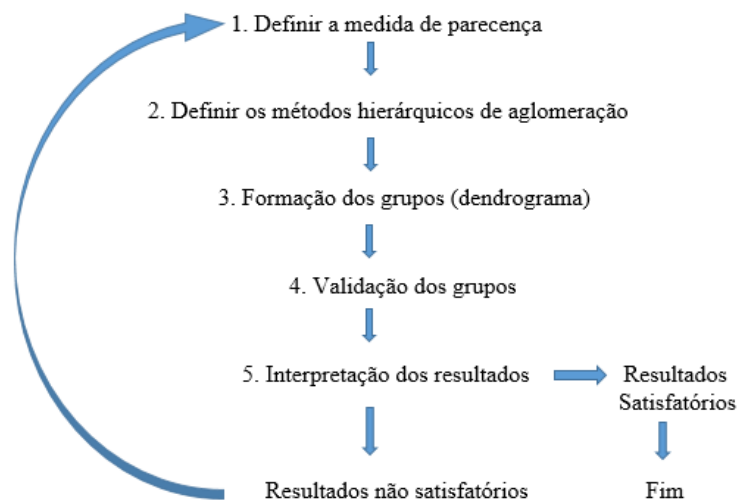
$$Z_{ij} = \frac{X_{ij} - \bar{X}_j}{S_j}$$

Sendo Z_{ij} o valor normalizado, X_{ij} é o valor observado no mês i e ano j , \bar{X}_j é a média de todas observações do mês i e S_j é o desvio padrão das observações. Isso garante que as variáveis sejam consideradas com importâncias equivalentes.

A técnica segue as seguintes etapas discutidas em Souza, Schimidt e Turcato (2011), Rinaldi, Morabito e Tachibana (2009), Vicini (2005), Souza e Silva (2009), Marchesan, Souza e Menezes (2011), Saad (2009), Santos (2017) e Vicini et al. (2018):


- 1) Definir a medida de parecnça, as mais usuais são: distância euclidiana, City-Block, Mahalanobis e coeficiente de correlação. As medidas de parecnça se dividem em dois grupos: de similaridade, quanto menor as distâncias, mais próximos estão os objetos, correlação cuja distância é calculada pela equação $d_{ij} = 1 - r_{ij}$ ou dissimilaridade, quanto maior o valor, mais distantes estão os objetos, exemplo distância euclidiana, City-block.
- 2) Definir os métodos hierárquicos de aglomeração: os agrupamentos são formados a partir da matriz de parecnça; os métodos mais usuais são: Ligação Simples (*Single Linkage*), Método de Ligação Completa (*Complete Linkage*), Método da Média das Distâncias (*Average Linkage*), Método do Centroide (*Centroid Method*) e Método de Ward.
- 3) Formação dos grupos: o número de grupos pode ser definido por meio de algum conhecimento que se tenha sobre os dados, conveniência de análise ou ainda com base nos resultados da análise;
- 4) Validação dos grupos: ao final do processo de formação de grupos, é importante caracterizá-los. O uso de estatísticas descritivas é recomendado para essa fase da análise;
- 5) Interpretação dos resultados.

Figura 2 – Aplicação do método de análise de agrupamentos



O dendrograma fornece uma inspeção visual em busca de observações atípicas e oferece uma interpretação do agrupamento, garantindo que eles sejam verdadeiramente distintos, cabendo ao pesquisador eliminar variáveis que não se agrupam ou que não diferem significativamente ao longo dos grupamentos. A Figura 3 representa um exemplo de dendrograma.

Figura 3 – Dendrograma esquemático para um grupo de 5 membros



Fonte: Adaptado de Wilks (2006).

Nesta pesquisa, a análise de agrupamento hierárquico vai auxiliar a identificar quais as sub-regiões, dentro de cada região, com maior similaridade das séries históricas de precipitação. Após, serão definidas através da Correlação de Pearson, as sub-regiões que mais sofrem interferências da TSM nos padrões de precipitação, com objetivo de utilizar a TSM como variável exógena no modelo de previsão ARIMAX.

A distância euclidiana será utilizada como medida de parença. A distância Euclidiana é descrita como:

$$\|X - Y\| = \sqrt{\sum_{K=1}^K (X_K - Y_K)^2} \quad \|X - Y\| = \sqrt{\sum_{K=1}^K (X_K - Y_K)^2}$$

Sendo \$X_k\$ e \$Y_k\$ as séries, temporal e espacial, dos membros X e Y, respectivamente, e K números totais de dados das séries analisadas.

Com base em uma nova matriz contendo as distâncias Euclidianas entre todos os membros conforme definido acima, é determinada a mínima variância intra-grupo, através de:

$$W = \sum_{i=1}^n x_i^n - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \quad W = \sum_{i=1}^n x_i^n - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2$$

Sendo x a distância Euclidiana para n grupos. Assim, o resultado é disposto por meio do dendrograma (exemplo figura 3) com os níveis de similaridade. Com esta técnica é possível identificar as sub-regiões brasileiras com similaridades na precipitação acumulada mensal.

2.3 SÉRIES TEMPORAIS

Uma ST é um conjunto de observações ordenadas em intervalos de tempo, comumente iguais e que apresentam dependência serial, segundo Morettin e Toloí (2004). Para Martínez e Zanprano (2003, p. 130), “uma ST é um processo estocástico gerador de observações no tempo de uma determinada variável y a qual representa medições sucessivas de algum fenômeno de interesse”. De acordo com Detzel (2015), uma série temporal é um encadeamento de observações de uma variável no tempo que guardam um certo grau de dependência entre si.

Para Tibulo (2014), uma ST é um conjunto de dados ordenados no tempo em intervalos iguais durante um período específico, que pode ser obtido por meio de coletas regulares como, por exemplo: número diário de nascidos vivos, consumo de energia elétrica/água mensal de um determinado estabelecimento, taxa de juros, índice de inflação, preços médios mensais de *commodities*, temperatura máxima e mínima diária, índices mensais pluviométricos, valores diários da poluição, entre outros.

Silva et al. (2008) relatam que o objetivo do estudo de ST é captar a dependência serial das observações, analisar e modelar essa dependência. Para Martínez e Zamprogno (2003) o que se busca na investigação de uma ST é descobrir o mecanismo gerador da série, descrever seu comportamento, verificar a existência de ciclos, variações e tendências, com o intuito de se fazer previsões de valores futuros que sirvam de base para tomada de decisões. Os métodos baseiam-se na ideia que as observações passadas contenham a memória do comportamento da série em estudo.

O estudo de ST busca fornecer um aporte para tomada de decisões, reduzindo a incerteza em planejamentos futuros através de informações captadas das próprias séries históricas, segundo Bressan e Lima (2002), Morettin e Toloí (2004). Para Batista (2009) e Conti (2005), o que se busca em uma ST é examinar o comportamento da série, os fatores que influenciam em seu mecanismo gerador, na busca de identificar as relações de causa e efeito, com o intuito de

construir um modelo matemático que possibilite realizar previsões para embasar decisões futuras. Camelo et al. (2017) reforçam que a previsão através de ST é um processo de prever valores futuros a partir do conhecimento de seus valores passados.

Santos e Costa (2008) defendem que uma ST é simplesmente uma realização de um processo estocástico. Dessa forma, assume-se que cada valor de uma série $Z = (Z_1, Z_2, \dots, Z_t)$, é extraído aleatoriamente de uma distribuição de probabilidade. Assim, se fosse possível especificar a função de distribuição de probabilidade de uma determinada ST, se poderia determinar também a probabilidade de um resultado futuro da série. Para Box et al. (1994), um processo estocástico é qualquer fenômeno estatístico que evolui no tempo de acordo com preceitos probabilísticos.

Keiel e Bender (2018), afirmam que a base para análise de ST é a estacionariedade, uma série estacionária pode ser descrita pela sua média, variância e correlação. Ainda segundo os autores um processo estocástico é estacionário se sua distribuição de probabilidade não varia durante seu deslocamento no tempo. Já Ozaki e Admi (2012) apontam que uma série não estacionária, pode se tornar estacionária aplicando sobre ela um certo número de diferenciações.

Os modelos clássicos de séries no tempo são compostos de: tendência, variações cíclicas, variações sazonais e erros aleatórios. As tendências mais simples são as que apresentam um comportamento linear crescente ou decrescente. As variações cíclicas são variações com períodos de amplitude maior de um ano. Já as variações sazonais são as que ocorrem regularmente dentro do período de um ano, segundo Lúcio et al. (2010).

A aplicação de modelos estatísticos a dados de precipitação sazonal, pode ser uma ferramenta de apoio aos modelos dinâmicos quando por algum motivo os mesmos vierem a falhar. De acordo com Martínez e Zamprogno (2003, p. 130), o processo de obter previsão é muito mais que a posição simplista de aventurar valores, pois, precisa da construção de um modelo adequado do sistema a ser tratado. Para Rossi (2014) a previsão de séries de dados se encontra em grande desenvolvimento em consequência da necessidade de modelos confiáveis e com grande precisão.

A seguir, são apresentados alguns conceitos importantes referentes à modelos de séries temporais desenvolvidos.

2.4 MODELOS COMBINADOS DE PREVISÃO

Vários modelos estatísticos foram desenvolvidos para auxiliar na tarefa de previsão de ST, como por exemplo: os modelos de Alisamento Exponencial (simples, linear de Brown, bi

paramétrico de Holt, sazonal de Holt-Winters), modelos autorregressivos (AR), de médias móveis (MA), Modelos mistos (ARIMA, SARIMA, ARCH, GARCH, ARMAX), entre outros, segundo Tibulo (2014).

A utilização conjunta de diversos modelos estatísticos de ST pode ser uma alternativa para alcançar melhores resultados de ajuste e previsão. Mancuso e Werner (2014) afirmam que há uma tendência de utilização de modelos combinados de previsões individuais para diminuir o erro da previsão.

Para Moço (2017) a premissa básica do trabalho de combinação é criar uma nova previsão com base na combinação de diferentes modelos, sendo que para cada um deles é dado certo peso. Dessa forma, o trabalho se concentra na forma pela qual esses pesos serão determinados. Para o autor a combinação de diversos modelos de previsão possibilita melhores resultados de previsão.

A proposta de previsões que combinem diversos modelos é discutida em Lucio et al. (2010). Para cada modelo ajustado, observa-se a correlação entre a série ajustada e a série observada, verificando o desempenho do modelo. A agregação dos resultados (previsões) é feita ponto a ponto, por uma média ponderada, onde são atribuídos pesos proporcionais aos quadrados das correlações obtidas entre série ajustada e observada.

Para Santos e Toledo Filho (2014) o quadrado do coeficiente de correlação de Pearson é o coeficiente de determinação e pode ser chamado simplesmente de r^2 . É uma medida da proporção da variabilidade em uma variável que é explicada pela variabilidade da outra. Figueiredo Filho e Silva Júnior (2009), reforçam que o coeficiente de correlação de Pearson (r) é uma medida de associação linear entre variáveis.

Para o modelo agregado, foram utilizados os resultados das previsões das seguintes classes de modelos estocásticos: ARIMA, ARIMAX e Alisamento Exponencial. Para agregação das previsões a correlação a ser utilizada é obtida através da comparação entre ST observada e ajustada e deve ser significativa a um nível ($\alpha = 5\%$). Para testar a significância da correlação foi utilizado o t de *Student* com as seguintes hipóteses: H_0 = correlação igual a zero (não têm correlação significativa), H_1 : existe correlação significativa entre as duas séries.

2.4.1 Modelos Box-Jenkins

Segundo Morettin e Tolo (1987), Ozaki e Admi (2012) a construção dos modelos Box-Jenkins é baseada em um ciclo iterativo, no qual a escolha do modelo é feita com base nos próprios dados. Para Box et al. (1994), a busca de um modelo estocástico que represente uma

ST é um processo iterativo que consiste de três fases: identificação, estimação e diagnóstico, resumidas a seguir:

1) Fase de identificação:

- Investigar detalhadamente a série;
- Analisar a presença de tendência, sazonalidade, periodicidades, condição de estacionariedade;
- Observar a autocorrelação serial; e
- Escolher a classe de modelos adequadas ao estudo de acordo com as características da série.

2) Fase da estimação:

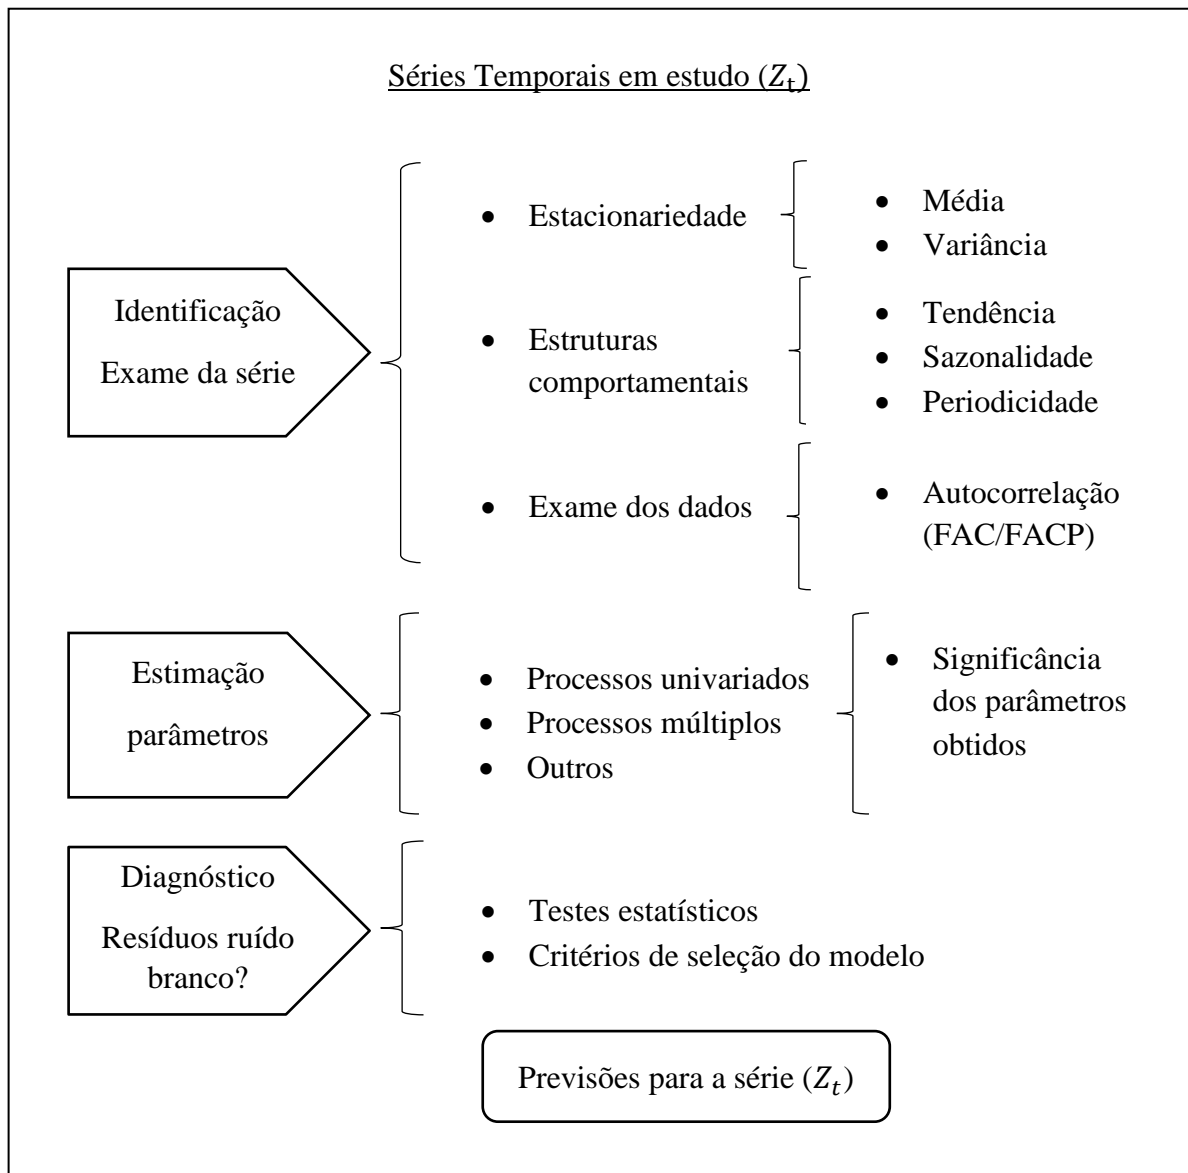
- Após identificadas as características da série, optar pelos processos univariados, múltiplos, entre outros; e
- Estimar os parâmetros.

3) Fase diagnóstica:

- Confirmação do ajuste do modelo (testes estatísticos); e
- Aplicar critérios de seleção/adequação de modelos.

Na Figura 4 é apresentado um esquema de análise de ST.

Figura 4 – Etapas para o estudo de ST



Fonte: Barbiero (2003, p. 38).

Os Modelos Autorregressivo, Integrado e de Médias Móveis, são modelos estatísticos que buscam compreender o comportamento da correlação serial e, com base nesse comportamento, realizar previsões futuras, segundo Danfá (2009).

O modelo Autorregressivo (AR), Integrado (I) e de Médias Móveis (MA), popularmente conhecido como ARIMA (p, d, q), é representado pela equação:

$$\Delta^d \tilde{Z}_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t - \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}}$$

em que os parâmetros ϕ_1, \dots, ϕ_p são os parâmetros referentes à parte autorregressiva AR (p), $\theta_1, \dots, \theta_q$ são os parâmetros de médias móveis MA (q), ε_t é o erro que não pode ser estimado pelo modelo, e o (d) é a ordem de integração, ou seja, é o número de diferenças simples aplicadas na série para torná-la estacionária, chamada integrada (I) de ordem d.

Para Detzel (2015), séries de fenômenos naturais, não possuem um equilíbrio, sendo marcadas por sazonalidades o que torna impróprio aplicações de formulações estacionárias, sendo necessário contornar essa condição. Ainda segundo o autor, quando os dados são observados em períodos inferiores a um ano a série pode apresentar autocorrelação para o período sazonal e os modelos que conseguem captar essa autocorrelação sazonal são conhecidos como SARIMA (Autorregressivos, integrados e de médias móveis que leva em conta a componente sazonal) ou modelos ARIMA multiplicativos.

Medeiros et al. (2018) descrevem que o SARIMA é o modelo adequado para contemplar a sazonalidade ou ciclos sazonais. De acordo com Lizzi (2012) esta classe de modelo permite a inclusão da sazonalidade, característica importante em ST com picos ou declínios periódicos recursivos durante sua evolução temporal. Para Ozaki e Admi (2012), quando a série Z_t exibe um comportamento sazonal, com defasagens em períodos múltiplos o modelo ARIMA, pode ser generalizado para um modelo SARIMA com a inclusão de um operador sazonal.

Para Morettin e Tolo (2004), o modelo SARIMA se subdivide em (p, d, q) referente a parte ordinal ou simples e (P, D, Q) referente aos termos autoregressivos (P), diferenciação (D) e média móvel (MA) para a parte sazonal e são números inteiros e não negativos. A equação do modelo é representada por:

$$\begin{aligned} \nabla^D \Delta^d \tilde{Z}_t = & \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t - \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}} \\ & + \underbrace{\Phi_1 Z_{t-1s} + \Phi_2 Z_{t-2s} + \dots + \Phi_P Z_{t-P}}_{\text{autorregressivo sazonal (P)}} - \underbrace{\Theta_1 \varepsilon_{t-1s} - \Theta_2 \varepsilon_{t-2s} - \dots - \Theta_Q \varepsilon_{t-Q}}_{\text{médias móveis sazonal (Q)}} \end{aligned}$$

Os parâmetros Φ_1, \dots, Φ_P são referentes à parte sazonal autorregressiva; $\theta_1, \dots, \theta_Q$ são os parâmetros sazonais de médias móveis; ε_t é o erro que não pode ser estimado do modelo; e D representa o número de diferenças da parte sazonal. A parte ordinal ou simples segue a mesma representação do modelo ARIMA.

Para séries estacionárias são propostos os modelos Autorregressivo (AR) e Médias Móveis (MA) que se caracterizam por suas séries desenvolverem-se no tempo em torno da

média. A combinação dos processos autorregressivo e de médias móveis, define o modelo ARMA, segundo Bueno (2008) e Morettin e Toloi (2004).

Medeiros et al. (2018), descrevem que em um modelo ARMA, o valor futuro da variável é assumido como sendo uma função linear de várias observações passadas e de erros aleatórios.

Os modelos do tipo ARMA (p, q), são indicados para séries que não podem ser explicadas puramente pelos modelos AR ou MA. O modelo relaciona os valores futuros com as observações passadas e podem ser representadas por:

$$\tilde{Z}_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t - \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}}$$

Os modelos (AR), (MA) e (ARMA) possuem uma característica em comum que considera modelos nos quais a série é estacionária $d = 0$. Sendo \tilde{Z}_t as observações históricas da série, ϕ_p os parâmetros autorregressivos, θ_q as ordens do modelo (MA) e ε_t representa os erros que não podem ser explicados pelo modelo. O modelo pode ser puramente autorregressivo (AR), com $d = q = 0$, ou de Médias Móveis (MA), $p = d = 0$.

Os modelos descritos até aqui são univariados, ou seja, seu comportamento serial é obtido através da análise de suas observações passadas, não utilizando informações contidas em outras ST, ou seja, considera-se que os dados passados possuem as informações suficientes para obter as principais características da série. Para Cas (2018) modelos univariados são aqueles em que os valores correntes de uma série de tempo são relacionados apenas com seus próprios valores passados ou com os valores correntes e passados dos resíduos da série temporal.

Entretanto a precipitação sazonal pode sofrer influências de fatores exógenos. Para buscar captar a existência dessa influência será testado o modelo multivariado de previsão de ST descritos a seguir.

2.4.2 Modelo ARIMAX

O modelo ARIMAX (p, d, q, r) é uma formulação geral dos modelos autorregressivos multivariados que é capaz de representar processos lineares estacionários e processos lineares não estacionários homogêneos com entradas exógenas, segundo Valer (2016). Para Keiel e Bender (2018), somente uma pequena parcela de trabalhos leva em consideração as influências exógenas no modelo em estudo.

Keiel e Bender (2018), relatam que o modelo ARIMAX é indicado para casos cuja a saída da série depende linearmente de uma variável explicativa, nesses casos, dá-se o nome de processos com entrada exógena X . Para Albuquerque, Silva e Maluf (2014), o modelo ARMAX é um modelo múltiplo que possibilita a análise de mais de uma variável correlacionada à previsão de \tilde{Z}_t , sendo a variável endógena dependente, que na presente pesquisa é a precipitação acumulada mensal e as variáveis explicativas exógenas independentes.

No modelo ARMAX (autorregressivo com médias móveis e entrada de variáveis exógenas) o valor atual da série \tilde{Z}_t é expresso linearmente em termos de seus valores passados (AR), em termos de valores anteriores do erro (MA) e adicionalmente termos presentes e passados de variáveis exógenas, de acordo com Medeiros (2018).

Segundo Martínez e Zamprogno (2003), o modelo ARIMAX é uma extensão do modelo ARIMA que permite a inclusão de uma ou mais variáveis explicativas (exógenas). Ozaki e Admi (2012), reforçam que o modelo citado se baseia em um modelo ARIMA em que são incorporadas variáveis explicativas ou covariáveis, na forma:

$$\Delta^d \tilde{Z}_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \underbrace{\beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_r Y_{t-r}}_{\text{variável independente}} + \underbrace{\varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}}$$

Sendo \tilde{Z}_t a variável dependente (nesse estudo precipitação sazonal), y_t a variável ou variáveis independentes (podem ser mais de uma variável que interfere no processo da precipitação sazonal), ϕ_i e θ_i os parâmetros desconhecidos autorregressivos e de médias móveis, respectivamente, β_i o coeficiente da variável ou variáveis exógenas e ε_t os resíduos do modelo que tem distribuição, $\varepsilon_t \sim N(0, \sigma^2)$, ou seja ruído branco (média zero, variância constante e erros descorrelacionados).

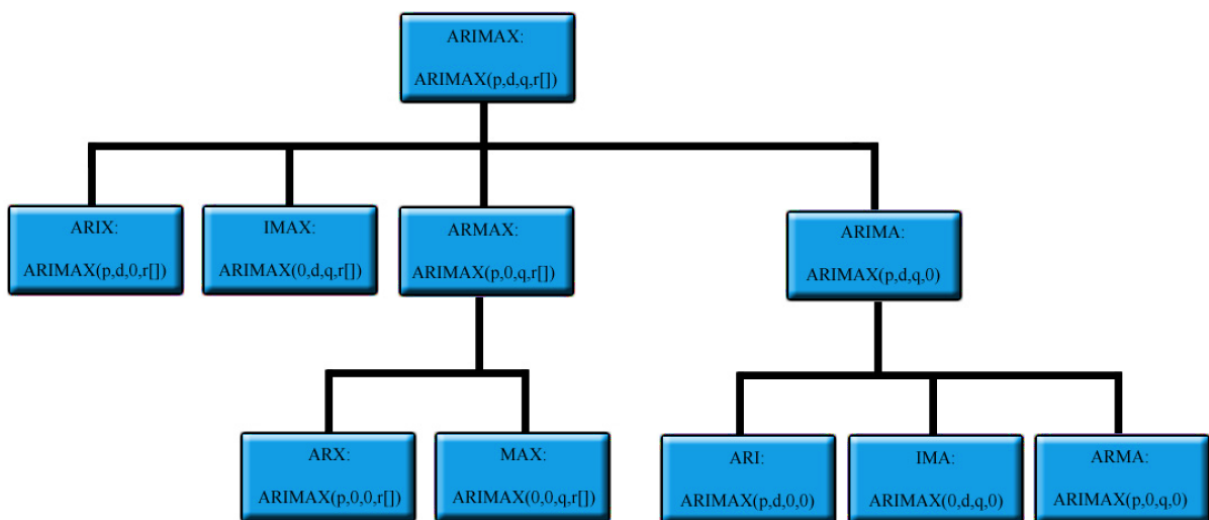
A estacionariedade das variáveis é necessária para a estimação dos parâmetros do modelo ARMAX, sob pena de incorrer em um modelo espúrio segundo Albuquerque, Silva e Maluf (2014). Não havendo estacionariedade nos dados, é necessário aplicar diferenciações sucessivas a fins de torná-la estacionária, e nesse caso o modelo passa a se denominar ARIMAX.

Para Andrade (2009), Keiel e Bender (2018) e Valer (2016) diferentes subclasses de modelo podem ser obtidas considerando um ou mais processos pertencentes à classe de modelos ARIMAX (p, d, q, r) . Desse modelo, considerando a estacionariedade, pode-se derivar outros

modelos como o autorregressivo com entrada exógena (ARX), média móvel com entrada exógena (MAX), ou autorregressivo, média móvel com entrada exógena ARMAX. Quando não há estacionariedade nas séries, utiliza-se os modelos integrados, tais como, o modelo Autorregressivo integrado média móvel com entradas exôgenas (ARIMAX), autorregressivo integrado com entradas exógenas (ARIX) e o modelo média móvel integrado com entradas exógenas (IMAX).

Os vários modelos lineares que derivam do modelo geral ARIMAX, estão expressos na Figura 5.

Figura 5 – Subdivisão do modelo ARIMAX



Fonte: Andrade (2009, p. 10).

Em séries temporárias em que há indícios de presença de sazonalidade é conveniente usar a extensão do modelo ARIMAX que contemple a inclusão dessa importante componente, e com a atualização o modelo passa a denominar-se SARIMAX.

Para a predição no modelo SARIMAX/ARIMAX, são necessários os valores das covariáveis, segundo Lizzi (2012). Nesta pesquisa a inclusão das covariáveis, para obtenção da previsão da precipitação sazonal será obtida pelos processos de Alisamento Exponencial Simples, Biparamétrico e Holt-Winters de acordo com as características da série.

2.4.3 Alisamento Exponencial

Um dos principais procedimentos que busca captar informações das séries é o método de Alisamento Exponencial. O método tem grande popularidade devido a sua simplicidade,

eficiência computacional e razoável precisão, Morettin e Tolo (1987), Martínez e Zamprogno (2003).

Para Carvalho (2018), existem diversas abordagens do amortecimento exponencial que se adequam a diversos padrões de séries de dados. A família de amortecimento está dividida em três principais categorias, Alisamento Exponencial de Holt-Winteres, Alisamento Exponencial Biparamétrico e o Alisamento Exponencial Simples.

A seguir são apresentados alguns conceitos importantes referentes à classe de modelos de Alisamento Exponencial.

2.4.3.1 *Alisamento Exponencial de Holt-Winters (AEHW)*

O método de AEHW é um dos mais utilizados para a previsão de curto prazo, devido à sua simplicidade, baixo custo de operação, boa precisão e capacidade de ajuste automático rápido a mudanças na série.

O modelo *HW* é dividido em dois subgrupos: aditivos e multiplicativos, de acordo com o comportamento das componentes da série. O primeiro considera que a amplitude da variação sazonal permanece uniforme ao longo do tempo, enquanto que no segundo ela muda com o passar do tempo, podendo ascender ou descender conforme for o caso. Para cada um dos procedimentos (aditivo ou multiplicativo), é necessário a estimação das constantes de amortecimento para o Nível (α), de Tendência (β) e de Sazonalidade (γ). Sendo (α, β, γ) as constantes de suavização que controlam o peso relativo ao nível (L_t), a tendência (T_t) e a sazonalidade (S_t), respectivamente, segundo Lúcio et al. (2010) e Nascimento (2013).

De acordo com Veríssimo et al. (2012) e Morettin e Tolo (2004), o método de Holt-Winter para efeitos sazonais aditivos é utilizado na modelagem de dados nos quais a amplitude do ciclo sazonal independe do nível local da série, ou seja, permanece constante com o passar do tempo, sendo indicado para casos em que a série demonstra um comportamento homogêneo. As equações: geral, nível, tendência, sazonalidade e previsão estão expressas no Quadro 1.

Quadro 1 – Equações de suavização exponencial sazonal de Holt-Winters Aditivo

Equação	HW Aditivo
Geral	$Z_t = L_t + T_t + S_t + \varepsilon_t, t = 1, 2, \dots$
Nível	$L_t = \alpha(Z_t - S_{t-1}) + (1 - \alpha)(L_{t-1} + T_{t-1}), 0 < \alpha < 1;$
Tendência	$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, 0 < \beta < 1;$
Sazonalidade	$S_t = \gamma(Z_t - L_t) + (1 - \gamma)S_{t-1}, 0 < \gamma < 1;$
Previsão	$\hat{Z}_t(h) = L_t + T_t h + S_{t+h-s}, h = 1, 2, \dots$
Sendo: (s) - comprimento da sazonalidade; (L_t) - nível da série; (T_t) - tendência; (S_t)-componente sazonal; $\hat{Z}_t(h)$ - previsão para o período h; (Z_t) - valor observado; (α, β, γ) - parâmetros exponenciais alisadores, do nível, da tendência e da sazonalidade, respectivamente.	

Fonte: Adaptado de Veríssimo et al. (2012) e Morettin e Toloi (2004).

Segundo Silva, Costa e Santos (2016), Veríssimo et al. (2012) e Morettin e Toloi (2004), o método de Holt-Winter para efeitos sazonais multiplicativo é utilizado na modelagem de dados nas quais a amplitude do ciclo sazonal varia proporcionalmente ao nível da série com o passar do tempo. A amplitude da série aumenta ou diminui com o passar do tempo, sendo indicado para casos em que a série apresenta comportamento mais explosivo (heterogêneo). Esse modelo é capaz de incorporar tanto a tendência linear quanto o efeito sazonal. As equações: geral, nível, tendência, sazonalidade e previsão estão expostas no Quadro 2.

Albuquerque e Serra (2006) ressaltam de maneira simples que o Holt-Winters multiplicativo (HWM) é utilizado quando a diferença entre o maior e o menor ponto de demanda nos ciclos cresce com o passar do tempo, ou seja, a amplitude da variação sazonal aumenta com o passar do tempo. Já no Holt-Winters aditivo (HWA), a diferença entre o maior e o menor ponto de demanda nos ciclos permanece constante com o passar do tempo, não alterando a variação sazonal com o passar do tempo.

Camelo et al. (2017), descrevem as seguintes etapas para aplicação dos modelos:

- (i) Aplicação dos modelos propostos aos dados, na busca de captar características como nível, tendência e sazonalidade;
- (ii) Medir a acurácia dos modelos; e
- (iii) A partir do ajuste dos modelos realizar previsões.

O modelo AEHW pode ser empregado para séries que apresentam comportamento geral, sendo de fácil aplicação. A determinação das constantes de suavização (α, β, γ) é realizada de modo a tornar mínima a soma dos quadrados dos erros ajustados.

Quadro 2 – Equações de suavização exponencial sazonal de Holt-Winters multiplicativo

Equação	HW multiplicativo
Geral	$Z_t = L_t \cdot S_t + T_t + \varepsilon_t, t = 1, 2, \dots$
Nível	$L_t = \alpha \frac{Z_t}{S_{t-1}} + (1 - \alpha)(L_{t-1} + T_{t-1}), 0 < \alpha < 1;$
Tendência	$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, 0 < \beta < 1;$
Sazonalidade	$S_t = \gamma \frac{Z_t}{L_t} + (1 - \gamma)S_{t-1}, 0 < \gamma < 1;$
Previsão	$\hat{Z}_t(h) = (L_t + T_t h)S_{t+h-s}, h = 1, 2, \dots$

Sendo: (s) - comprimento da sazonalidade; (L_t) - nível da série; (T_t) - tendência; (S_t) - componente sazonal; $\hat{Z}_t(h)$ - previsão para o período h; (Z_t) - valor observado; (α, β, γ) - parâmetros exponenciais alisadores, do nível, da tendência e da sazonalidade, respectivamente.

Fonte: Adaptado de Veríssimo et al. (2012) e Morettin e Toloi (2004).

2.4.3.2 Alisamento Exponencial Biparamétrico (AEB)

De acordo com Morettin e Toloi (2004) e Morettin e Toloi (1987), o método é indicado para séries com tendências lineares positivas ou negativas. O AEB estima o nível e a tendência da série aplicando constantes de alisamento diferentes para o nível e para a tendência. O método é similar ao alisamento exponencial simples, a diferença é que, em vez de suavizar só o nível, utiliza uma nova constante para a tendência.

Os valores das constantes nível, tendência e as previsões futuras, serão estimados de acordo com as equações do Quadro 3.

A previsão é realizada adicionando-se ao valor básico, L_t , a tendência multiplicada pelo número de passos à frente (h) desejado.

Quadro 3 – Equações de Alisamento Exponencial Biparamétrico

Equação	AEB
Geral	$Z_t = L_t + T_t + \varepsilon_t, t = 1, 2, \dots$
Nível	$L_t = \alpha(Z_t) + (1 - \alpha)(L_{t-1} + T_{t-1}), 0 < \alpha < 1;$
Tendência	$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, 0 < \beta < 1;$
Previsão	$\hat{Z}_t(h) = L_t + T_t h, h = 1, 2, \dots$

Sendo: (L_t) - nível da série; (T_t) - tendência; $\hat{Z}_t(h)$ - previsão para o período h; (Z_t) - valor observado; (α, β) - parâmetros exponenciais alisadores, do nível, da tendência.

Fonte: Adaptado de Morettin e Toloi (2004).

2.4.3.3 Alisamento Exponencial Simples (AES)

O método AES é uma média ponderada que dá pesos para as variáveis mais recentes de acordo com Morettin e Toloi (2004) e Morettin e Toloi (1987).

As equações geral e previsões do método podem ser descritas de acordo com o Quadro 4:

Quadro 4 – Equações de Alisamento Exponencial Simples

Equação	AEB
Geral	$\bar{Z}_t = \alpha Z_t + (1-\alpha)\bar{Z}_{t-1}$, para $t = 1, 2, \dots, n$
Previsão	$\hat{Z}_t(h) = \bar{Z}_{t-1}$ $\hat{Z}_t(h) = \alpha Z_t + (1-\alpha)\hat{Z}_{t-1}(h+1)$
Sendo: Z_t o valor no instante t ; \bar{Z}_t o valor exponencial suavizado, \bar{Z}_{t-1} o valor exponencial suavizado no instante $t - 1$; α a constante de suavização assumindo valores no intervalo $0 \leq \alpha \leq 1$; $\hat{Z}_t(h)$ à previsão h passos a frente e \hat{Z}_{t-1} a previsão imediatamente anterior	

Fonte: Adaptado de Morettin e Toloi (2004).

A previsão de todos os valores futuros é dada pelo último valor exponencial suavizado. O AES é um método muito usado devido ao fácil entendimento, grande flexibilidade da constante de suavização e à necessidade de armazenar somente Z_t , \bar{Z}_t e α .

A seguir são apresentados os critérios que foram considerados na seleção do melhor modelo ajustado.

2.5 MÉTODOS PARA SELEÇÃO DE MODELOS/MEDIDAS DE ACURÁCIA

Uma atenção especial será dada ao resíduo (erro) que é a diferença entre o valor previsto e o observado. Para determinação dos modelos, esta pesquisa usa diferentes critérios descritos na literatura, com o intuito de encontrar o modelo que mais se aproxime dos dados observados.

Para os Modelos da classe Box Jenkins, os critérios a serem utilizados são: AIC (*Akaike Information Criterion*) proposto por Akaike (1974) e BIC (*Bayesian Information Criterion*) desenvolvido por Akaike (1978). Ambos, levam em conta o número de parâmetros do modelo, ou seja, privilegia o modelo mais parcimonioso (menor número de parâmetros) como o mais adequado. As equações dos modelos AIC e BIC estão descritas, no Quadro 5.

Quadro 5 – Critérios AIC e BIC

<i>Akaike Information Criterion</i>	<i>Bayesian Information Criterion</i>
$AIC = \ln(\hat{\sigma}_e^2) + \frac{2(p + q)}{n}$	$BIC = \ln(\hat{\sigma}_e^2) + \frac{(p + q)\ln(n)}{n}$
Sendo n o número de observações da amostra, $\hat{\sigma}_e^2$ a variância estimada dos erros e (p,q) o número de parâmetros de cada componente AR e MA. Os critérios levam em conta a variância do erro, o tamanho da amostra n e os valores de (p, q).	

Fonte: Adaptado de Akaike (1974 e 1978).

Os critérios podem assumir qualquer valor, negativos ou positivos e só ganham sentido quando usados para comparar modelos. Quanto menores forem esses valores, melhor é a adequação do modelo para realizar previsões. No entanto, cabe salientar que para usar os critérios os modelos devem ser ajustados no mesmo período amostral. Com base nesses critérios é possível selecionar o melhor modelo dentre os ajustados. Para Martínez e Zamprogno (2003), os critérios permitem identificar o modelo que maximize as informações contidas nele.

Além dos critérios estabelecidos acima, a condição de ruído branco dos resíduos é considerada, $\varepsilon_t \sim N(0, \sigma^2)$, ou seja, faz-se necessário que os erros do modelo sejam decorrelacionados ao longo do tempo, possuam média zero e variância constante (MORETTIN; TOLOI, 2004).

Para medir a acurácia dos valores preditos e atestar a qualidade das previsões entre as classes de modelos utilizadas nessa pesquisa, o Quadro 6, descreve os critérios de avaliação: Erro quadrático médio (EQM), Soma dos quadrados dos erros (SSE), Média absoluta dos desvios (MAD) e o Erro Absoluto Médio Percentual (MAPE) de acordo com Tidre, Biase e Silva (2013), Esquivel, Senna e Gomes (2012), Barbosa e Chaves (2012) Arsego (2017) e Feliciano (2009).

Quadro 6 – Critérios de avaliação sobre a qualidade das previsões

Critério	Notação	Equação
Erro quadrático médio	EQM	$EQM = \frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n}$
Soma dos quadrados dos erros	SSE	$SSE = \sum_{t=1}^n (Z_t - \hat{Z}_t)^2$
Média absoluta dos desvios	MAD	$MAD = \frac{\sum_{t=1}^n Z_t - \hat{Z}_t }{n}$
Erro Absoluto Médio Percentual	MAPE	$MAPE = \frac{\sum_{t=1}^n \left \frac{Z_t - \hat{Z}_t}{Z_t} \right }{n} \cdot 100\%$
Sendo: Z_t o valor da série no instante t ; \hat{Z}_t o valor previsto para o instante t ; n o número período de tempos.		

Fonte: Adaptado de Tibulo et al. (2020)

Quanto menores os valores encontrados nos critérios (EQM), (SSE), (MAD) e o (MAPE), mais próximos dos valores previstos estão os valores observados. Indicando o melhor modelo ajustado.

2.6 CLASSES PARA CATEGORIZAÇÃO DA PRECIPITAÇÃO

Para a categorização das previsões sazonais da precipitação, optou-se pela técnica de Quantis. Segundo Batista (2012) pode-se abordar a análise de variáveis meteorológicas através da técnica de quantis. Para Lopes et al. (2013), é uma prática estatística simples, porém apropriada, que visa distribuir em classes as variáveis em estudo, de modo a definir limites para os índices pluviométricos, classificando em abaixo da normal (climatológica), normal (climatológica) ou acima da normal (climatológica).

Para de Xavier e Xavier (1999) e Xavier et al. (2002), os valores finais previstos para a precipitação trimestral acumulada, estimativas pontuais de cada série climatológica, são confrontados com os valores quantílicos e classificados nas categorias. Esta pesquisa utiliza as ordens quantílicas descritas no Quadro 7, amplamente discutido em Santos et al. (2016), Xavier e Xavier (1999).

Quadro 7 – Intervalos de classe para categorização da precipitação

Classificação	Classes de Precipitação		
Muito Seco	$X_i \leq Q_{0,15}$	$p_i \leq Q_{0,15}$	Abaixo da Normal
Seco	$Q_{0,15} < X_i \leq Q_{0,35}$	$Q_{0,15} < p_i \leq Q_{0,35}$	
Normal	$Q_{0,35} < X_i < Q_{0,65}$	$Q_{0,35} < p_i < Q_{0,65}$	Normal
Chuvoso	$Q_{0,65} \leq X_i < Q_{0,85}$	$Q_{0,65} \leq p_i < Q_{0,85}$	Acima da Normal
Muito Chuvoso	$X_i \geq Q_{0,85}$	$p_i \geq Q_{0,85}$	

Sendo: $Q_{15}, Q_{35}, Q_{65}, Q_{85}$ os quantis; X_i valores mensais Observadas de precipitação; Para cada valor de X_i é calculado a ordem quantílica correspondente ($X_i \Leftrightarrow p_i$).

Fonte: Adaptado de Xavier e Xavier (1999), Lopes et al. (2013), Santos et al. (2016).

Portanto, X_1, X_2, \dots, X_n é uma série de precipitação em um determinado período em que ao longo dos n meses são calculados os quantis ($Q_{15}, Q_{35}, Q_{65}, Q_{85}$). Para cada valor X_i de precipitação é calculada a ordem quantílica correspondente p_i .

Os intervalos percentuais de cada quantil representam as probabilidades ou frequências esperadas para cada um dos eventos que podem vir a ocorrer na sequência da série temporal de uma variável X, desde que as características da precipitação sejam mantidas, de acordo com Gouvea (2018) e Santos et al. (2016).

Para Lopes et al. (2013), as classes permitem selecionar os eventos climáticos de interesse para um determinado período, tais como episódios de secas ou chuvosos, bem como o padrão normal. A técnica dos quantis é uma metodologia que consiste estritamente na distribuição em ordenamento crescente de uma série amostral contínua, para o qual atribui-se uma probabilidade para cada valor amostral.

Os quantis aparecem em diferentes denominações ligadas ao número de ordens quantílicas. Quartis quando o conjunto de dados $p = 0,25; 0,50; 0,75$, quintis para $p = 0,20; 0,40; 0,60; 0,80$, decis para $p = 0,10; 0,20; 0,30; 0,40; 0,50; 0,60; 0,70; 0,80; 0,90$. A escolha da ordem quantílica está relacionada ao número de subconjuntos no qual o conjunto de dados da variável X, no presente estudo a precipitação, será dividida.

Neste trabalho a ST está constituída pelos totais de precipitação acumulada mensal. Para classificar as previsões da precipitação sazonal são utilizadas as ordens quantílicas $Q_{0,15}; Q_{0,35}; Q_{0,65}; Q_{0,85}$ para estabelecer as classes em relação aos valores observados (X_i) de precipitação (Quadro 7), o que permite selecionar os eventos climáticos em categorias de secos a chuvosos.

2.7 TESTE ESTATÍSTICO DEIBOLD – MARIANO (1995)

A precisão das previsões é de suma importância para o estudo de modelos de ST. Entretanto, em muitos casos a diferença estatística entre dois métodos de previsão não é significativa, ou seja, qualquer um dos modelos testados pode representar a ST em estudo.

Para testar a significância estatística da diferença das previsões entre modelos, foi aplicado o teste de Diebold e Mariano (1995). A hipótese nula do teste bicaudal de Diebold-Mariano (DM) é que as duas estimativas possuem a mesma capacidade preditiva e a hipótese alternativa é que há diferença significativa entre as previsões.

A comparação é feita entre os erros de previsão dos modelos, comparando dois modelos por vez. Valores negativos do teste indicam superioridade do primeiro modelo do par em relação ao segundo e valores positivos indicam superioridade do segundo modelo do par testado. Valores absolutos do teste DM maiores do que os pontos críticos 1,96 ($\alpha = 5\%$) e 1,66 ($\alpha = 10\%$) indicam rejeição da hipótese nula (diferença entre a média dos erros quadrados é nula) a 95% e 90% de confiança respectivamente, ou seja, os modelos não possuem a mesma capacidade preditiva (Diebold e Mariano (1995), Harvey Leybourne e Newbold (1997)).

Sua aplicação foi realizada com o pacote Forecast do software estatístico R Studio. Para o teste Diebold-Mariano foi utilizado um nível significância de 5% e 10%.

3 METODOLOGIA

Diante dos objetivos deste estudo, fez-se uma pesquisa exploratória e descritiva, pois, segundo Gil (2002), tais pesquisas têm como objetivo principal o aprimoramento de ideias, levantamento bibliográfico, análise de exemplos e estabelecimento de relação entre variáveis.

Quanto aos procedimentos técnicos, Gil (2002) caracteriza como:

- Pesquisa Bibliográfica: desenvolvida com base em material já elaborado, constituído principalmente de livros e artigos científicos e
- Estudo de caso: estudo teórico aplicado a uma determinada situação, gerando possíveis hipóteses a estudos futuros.

Para realização deste estudo, foram considerados os dados da série histórica correspondente a precipitação acumulada mensal, extraídos de Xavier et al., (2015) das regiões Sul, Sudeste e Centro Oeste do Brasil. Compreendidas entre as latitudes ($20,625^{\circ}\text{S}$ a $33,62^{\circ}\text{S}$) e longitudes ($42,62^{\circ}\text{W}$ a $57,62^{\circ}\text{W}$) no período de 01 de janeiro de 1980 a 31 de dezembro de 2013. Interpolados para 1° latitude por 1° grau de longitude, sendo a série um ponto central, feita através da média com os pontos de 25 a 50Km em volta. No total foram obtidas 107 séries históricas de precipitação acumulada, contendo cada série 408 observações (meses).

As séries de TSM selecionadas para o mesmo período com 5° de latitude por 5° de longitude, sendo a série um ponto central, compreendida na faixa entre 60° Norte e 60° Sul são do conjunto ERSSTv5 de dados da NOAA, (Huang et al. 2017). Foram obtidas 1418 séries históricas de TSM, contendo cada série 408 observações (meses). Há TSM é estimada por imagens de satélite na escala de graus Celcius.

Para empletação da presente pesquisa foram consideradas as seguintes etapas:

- 1) Realizar de um levantamento de estudos referentes à previsão da precipitação sazonal através de modelos estatísticos de ST;
- 2) Executar revisão bibliográfica sobre os modelos de ST considerados, análise multivariada de agrupamento, correlação de Pearson, técnicas de acurácia, técnicas quantílicas e teste estatístico DM;
- 3) Organizaros bancos de dados de precipitação acumulada mensal e TSM para serem trabalhados no software RStudio;
- 4) Através do emprego de técnicas de Análise Multivariada de agrupamento determinar sub-regiões com características similares nas séries temporais de precipitação dentro de cada região. Para região Sul, determinar sub-regiões compreendidas nas faixas de latitudes ($24,625^{\circ}\text{S}$ a $33,625^{\circ}\text{S}$) e de longitudes

(48,625°W a 57,625°W). Para as regiões Sudeste e Centro Oeste, determinar sub-regiões compreendidas na faixa de latitude (20,625°S a 23,625°S) e de longitude (52,625°W a 54,625°W). Utilizando o processo de aglomeração hierárquica com o método de ligação completo (na busca de maior homogeneidade dentro de cada grupo), sendo a métrica de similaridade a distância Euclidiana;

- 5) Determinar a climatologia de cada sub-região, utilizando-se de técnicas quantílicas, descritas no item 2.6. Classificar as previsões nas categorias: Abaixo da normal, Normal e Acima da normal;
- 6) Após definida as sub-regiões com similaridades de precipitação acumulada mensal, avaliar a influência da TSM na precipitação em cada sub-região através da análise da Correlação de Pearson. Comparando a média das séries históricas de precipitação acumulada mensal de cada sub-região com as 1418 séries históricas de TSM.
- 7) Com a variável exógena (TSM) e endógena definida (média precipitação acumulada mensal de cada sub-região), o próximo passo é ajustar modelos de ST que possibilitem entender o comportamento da série e realizar previsões futuras.
- 8) Empregar modelos de séries temporais univariados para a previsão da precipitação acumulada (ARIMA e Alisamento Exponencial, descritos nos itens 2.4 e 2.4.3, do referencial teórico respectivamente);
- 9) Empregar modelos de ST multivariados (ARIMAX) que permitam a introdução de variáveis exógenas (TSM), descrito no item 2.4.2 do referencial teórico;
- 10) Empregar técnicas de modelos combinados (agregação das previsões dos modelos univariados e multivariados). A agregação das previsões nesta pesquisa é feita ponto a ponto através de uma média ponderada que leva em conta o quadrado das correlações obtidos entre série observada e ajustada. A técnica está descrita no item 2.4 do referencial teórico;
- 11) Através de critérios de seleção (descritos no item 2.5), escolher os melhores modelos que representem a variável precipitação acumulada mensal de cada sub-região encontrada;
- 12) Empregar a técnica quantílica para classificar as previsões climáticas em abaixo da normal, normal ou acima da normal;
- 13) Comparar o desempenho dos modelos através das técnicas de acurácia, descritos no item 2.5 do referencial teórico;

- 14) Aplicar o teste estatístico DM (descritos no item 2.7 do referencial teórico) para verificar se há diferença estatística significativa entre as previsões dos modelos testados;
- 15) Verificar se os modelos produzem resultados satisfatórios;
- 15) Produzir diagnósticos de previsões, utilizado como métrica a técnica quantílica; e
- 16) Concluir se os modelos propostos de previsão ST podem ser empregados para a previsão da precipitação acumulada mensal de cada sub-região.

Para realizar o ajuste dos modelos utilizou-se o software RStudio conforme “script” no apêndice.

4 ANÁLISE DOS RESULTADOS

Neste capítulo são apresentados e discutidos os resultados dos modelos de previsão de ST propostos, análise multivariada de agrupamento, técnicas de acurácia e quantílicas descritas no capítulo 2.

4.1 SUB-REGIÕES COM CARACTERÍSTICAS SIMILARES DE PRECIPITAÇÃO

A primeira região a ser analisada é a região Sul que está compreendida entre as latitudes (24,62°S a 33,62°S) e longitudes (48,62°W a 57,62°W), num total de 56 séries históricas completas de precipitação acumulada mensal, conforme o Quadro 8.

Quadro 8 – Nomenclatura das séries de dados da região Sul do Brasil

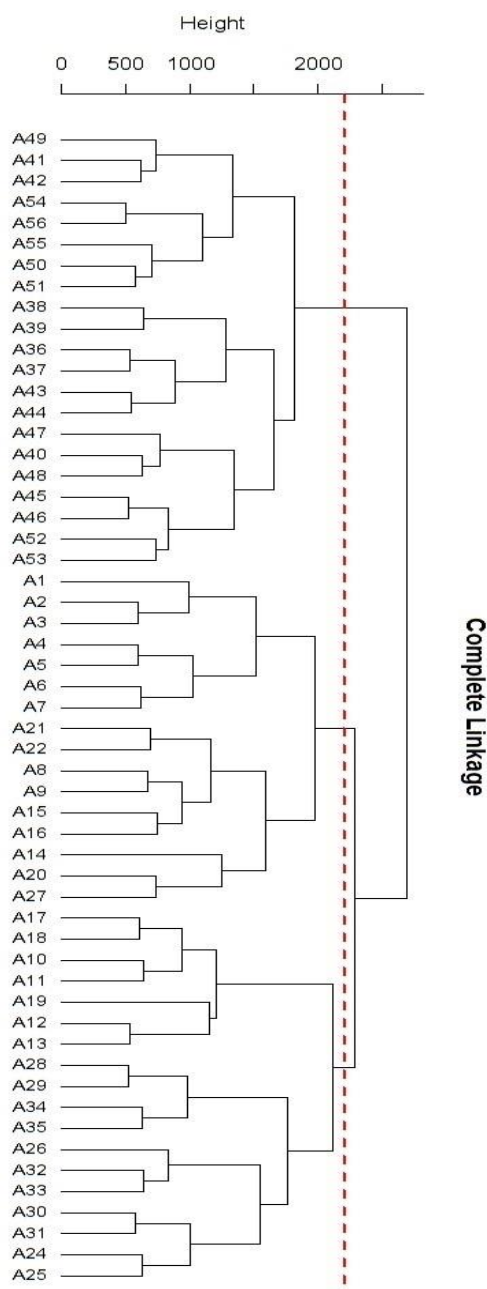
Série	Lat. E Long.	Série	Lat. E Long.	Série	Lat. E Long.
A1	24,62S e 48,62W	A20	27,62S e 48,62W	A39	29,62S e 55,62W
A2	24,62S e 49,62W	A21	27,62S e 49,62W	A40	29,62S e 56,62W
A3	24,62S e 50,62W	A22	27,62S e 50,62W	A41	30,62S e 50,62W
A4	24,62S e 51,62W	A23	27,62S e 51,62W	A42	30,62S e 51,62W
A5	24,62S e 52,62W	A24	27,62S e 52,62W	A43	30,62S e 52,62W
A6	24,62S e 53,62W	A25	27,62S e 53,62W	A44	30,62S e 53,62W
A7	24,62S e 54,62W	A26	27,62S e 54,62W	A45	30,62S e 54,62W
A8	25,62S e 49,62W	A27	28,62S e 49,62W	A46	30,62S e 55,62W
A9	25,62S e 50,62W	A28	28,62S e 50,62W	A47	30,62S e 56,62W
A10	25,62S e 51,62W	A29	28,62S e 51,62W	A48	30,62S e 57,62W
A11	25,62S e 52,62W	A30	28,62S e 52,62W	A49	31,62S e 51,62W
A12	25,62S e 53,62W	A31	28,62S e 53,62W	A50	31,62S e 52,62W
A13	25,62S e 54,62W	A32	28,62S e 54,62W	A51	31,62S e 53,62W
A14	26,62S e 48,62W	A33	28,62S e 55,62W	A52	31,62S e 54,62W
A15	26,62S e 49,62W	A34	29,62S e 50,62W	A53	31,62S e 55,62W
A16	26,62S e 50,62W	A35	29,62S e 51,62W	A54	32,62S e 52,62W
A17	26,62S e 51,62W	A36	29,62S e 52,62W	A55	32,62S e 53,62W
A18	26,62S e 52,62W	A37	29,62S e 53,62W	A56	33,62S e 53,62W
A19	26,62S e 53,62W	A38	29,62S e 54,62W		

Fonte: Autor.

Com a finalidade de agrupar séries históricas com comportamentos similares de precipitação e definir sub-regiões dentro da região Sul, realizou-se, então, a Análise de Agrupamentos. Utilizou-se como processo de aglomeração hierárquica o método de ligação completo e a métrica de similaridade a distância Euclidiana.

Na Figura 6, mostra-se o comportamento do dendrograma com todas as 56 séries de precipitação acumulada mensal, na qual se pode identificar a formação de três grupos, os quais possuem as variáveis de maior relevância dentro do conjunto em estudo.

Figura 6 – Dendrograma das séries históricas na região Sul



Realizando-se um corte gráfico vertical (“linha de Fenon”) na altura 2100, valor este em que foi verificado o maior salto entre os grupos. A técnica de corte gráfico/definição dos grupos é descrita detalhadamente em Vicini et al. (2018).

O corte gráfico definiu três grupos que são heterogêneos entre si. O grupo 1 com 16 séries de dados, o grupo 2 com 18 séries de dados e o grupo 3 com 21 séries de dados. O Quadro 9 expõem os grupos formados com homogeneidade dentro dos grupos e maior heterogeneidade entre os grupos.

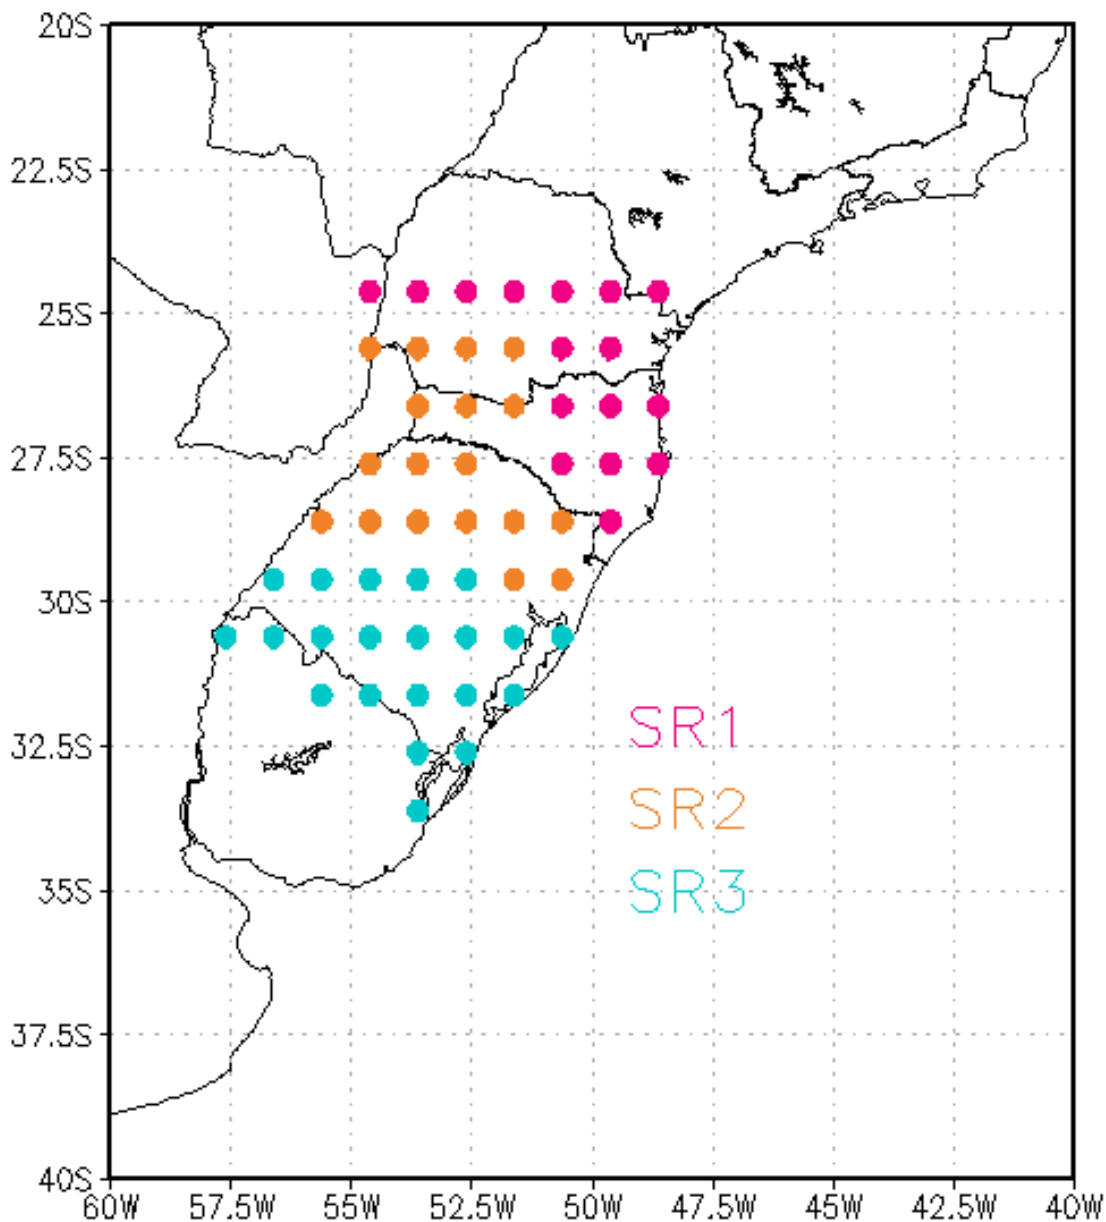
Quadro 9 – Sub-regiões da região Sul com similaridades nas séries históricas de precipitação mensal acumulada

Cluster 1 (Subregião 1)		Cluster 2 (Subregião 2)		Cluster 3 (Subregião 3)	
Série	Lat. E Long.	Série	Lat. E Long.	Série	Lat. E Long.
A1	24,62S e 48,62W	A10	25,62S e 51,62W	A36	29,62S e 52,62W
A2	24,62S e 49,62W	A11	25,62S e 52,62W	A37	29,62S e 53,62W
A3	24,62S e 50,62W	A12	25,62S e 53,62W	A38	29,62S e 54,62W
A4	24,62S e 51,62W	A13	25,62S e 54,62W	A39	29,62S e 55,62W
A5	24,62S e 52,62W	A17	26,62S e 51,62W	A40	29,62S e 56,62W
A6	24,62S e 53,62W	A18	26,62S e 52,62W	A41	30,62S e 50,62W
A7	24,62S e 54,62W	A19	26,62S e 53,62W	A42	30,62S e 51,62W
A8	25,62S e 49,62W	A24	27,62S e 52,62W	A43	30,62S e 52,62W
A9	25,62S e 50,62W	A25	27,62S e 53,62W	A44	30,62S e 53,62W
A14	26,62S e 48,62W	A26	27,62S e 54,62W	A45	30,62S e 54,62W
A15	26,62S e 49,62W	A28	28,62S e 50,62W	A46	30,62S e 55,62W
A16	26,62S e 50,62W	A29	28,62S e 51,62W	A47	30,62S e 56,62W
A20	27,62S e 48,62W	A30	28,62S e 52,62W	A48	30,62S e 57,62W
A21	27,62S e 49,62W	A31	28,62S e 53,62W	A49	31,62S e 51,62W
A22	27,62S e 50,62W	A32	28,62S e 54,62W	A50	31,62S e 52,62W
A27	28,62S e 49,62W	A33	28,62S e 55,62W	A51	31,62S e 53,62W
		A34	29,62S e 50,62W	A52	31,62S e 54,62W
		A35	29,62S e 51,62W	A53	31,62S e 55,62W
				A54	32,62S e 52,62W
				A55	32,62S e 53,62W
				A56	33,62S e 53,62W

Fonte: Autor.

A Figura 7, facilita a visualização da distribuição da precipitação acumulada mensal da região Sul.

Figura 7 – Sub-regiões da região Sul com Similaridades nas séries históricas de precipitação mensal acumulada



Fonte: Autor.

Observa-se três sub-regiões dentro da região Sul, com as similaridades de precipitação acumulada mensal. A Sub-Região Sul 1 (SR1), representa o Cluster 1, a Sub-Região Sul 2 (SR2), representa o Cluster 2 e a Sub-Região Sul 3 (SR3), representa o Cluster 3.

4.2 CORRELAÇÃO ENTRE AS SUB-REGIÕES E A TSM

Só serão consideradas as correlações de Pearson significativas ($p - valor < 0,05$) e as maiores correlações (r). As séries de precipitação de cada sub-região, foram comparadas com a TSM até seis defasagens. As séries que não atingirem o índice pretendido serão desconsideradas. Os dados de TSM estão coletados em séries mensais no período compreendido entre 1980 e 2013 no espaçamento ($5^\circ \times 5^\circ$), nas latitudes compreendidas entre 60° Norte e 60° Sul.

A Tabela 1 e Figura 8, demonstram as correlações (r) de acordo com suas respectivas coordenadas para a região SR1 e defasagens que variam de defasagem 0 até 6 meses.

A defasagem com duas diferenças (dois meses) foi a que apresentou melhor resultado de correlação, optou-se por utilizar as séries desta defasagem com correlação superior a 0,40. As demais séries, defasagens (0, 1, 3, 4, 5, 6) não foram utilizadas devido a deficiência computacional para processar o enorme conjunto de dados. A correlação encontrada para as defasagens (0, 1, 4, 5, e 6), foram inferiores a 0,40.

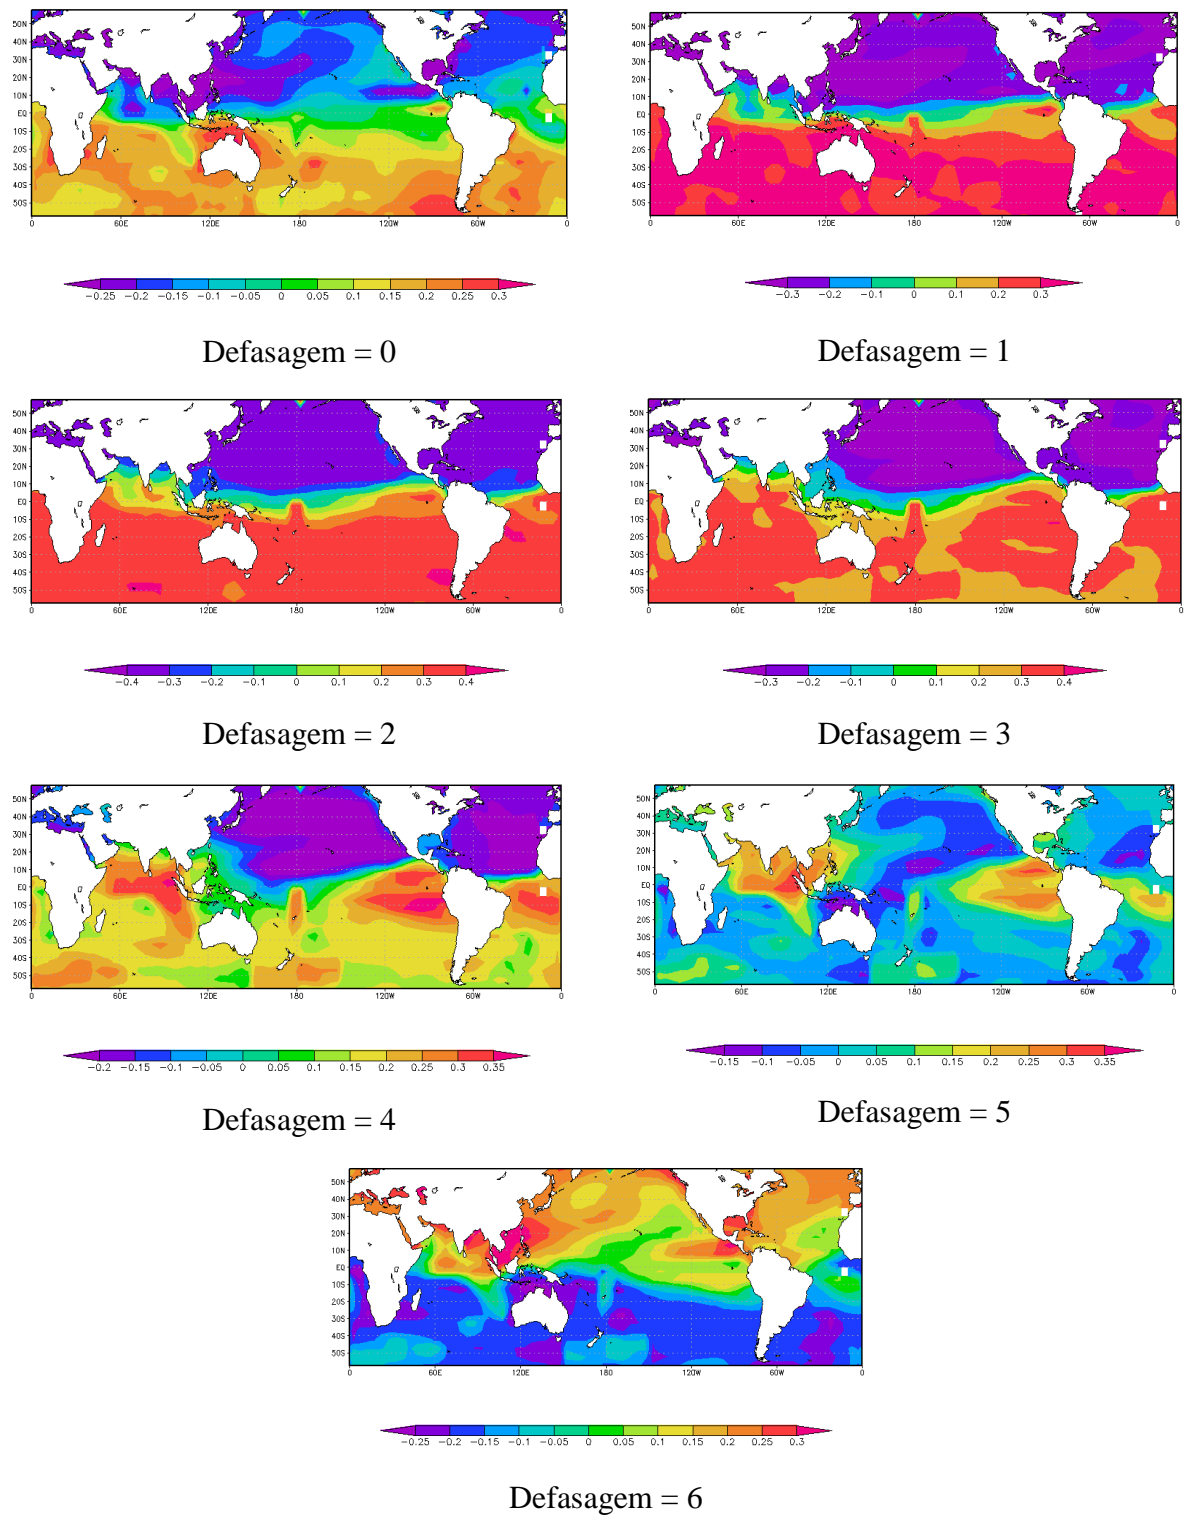
Tabela 1 – Correlações entre a região SR1 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

Defasagem 2									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lon	Lon	Lon	
20S	15S	35W	30W	0,400	50S	45S	105W	110W	0,406
25S	20S	35W	30W	0,403	20S	15S	25W	40W	0,407
45S	40S	115W	110W	0,406	40S	35S	14W	135W	0,405
50S	45S	100E	105E	0,404	50S	45S	95E	100E	0,408
50S	45S	115E	120E	0,402	50S	45S	110E	115E	0,405
20S	15S	40W	35W	0,403	45S	40S	120W	115W	0,405
25S	20S	40W	35W	0,401					

Fonte: Autor.

A Figura 8 demonstra as correlações encontradas nas defasagens de 0 até 6 meses entre a precipitação acumulada mensal em SR1 e a TSM compreendida entre 60° norte a 60° sul.

Figura 8 – Correlação entre a TSM e precipitação acumulada mensal para SR1



Fonte: Autor.

As regiões SR2 e SR3 apresentaram menores coeficientes de correlação entre elas e a TSM, quando comparadas com a SR1. Nas séries de TSM analisadas, não foram encontradas $r > 0,30$ para SR2 e SR3. Desta forma escolheu-se as melhores séries de TSM que demonstram correlações significativas para cada região, mesmo as mesmas sendo consideradas correlações um pouco mais fracas.

Na Tabela 2 pode-se verificar os valores mais altos de correlação entre a precipitação acumulada mensal e as séries de TSM e na Figura 9 as correlações entre a precipitação e a TSM nas sete defasagens consideradas.

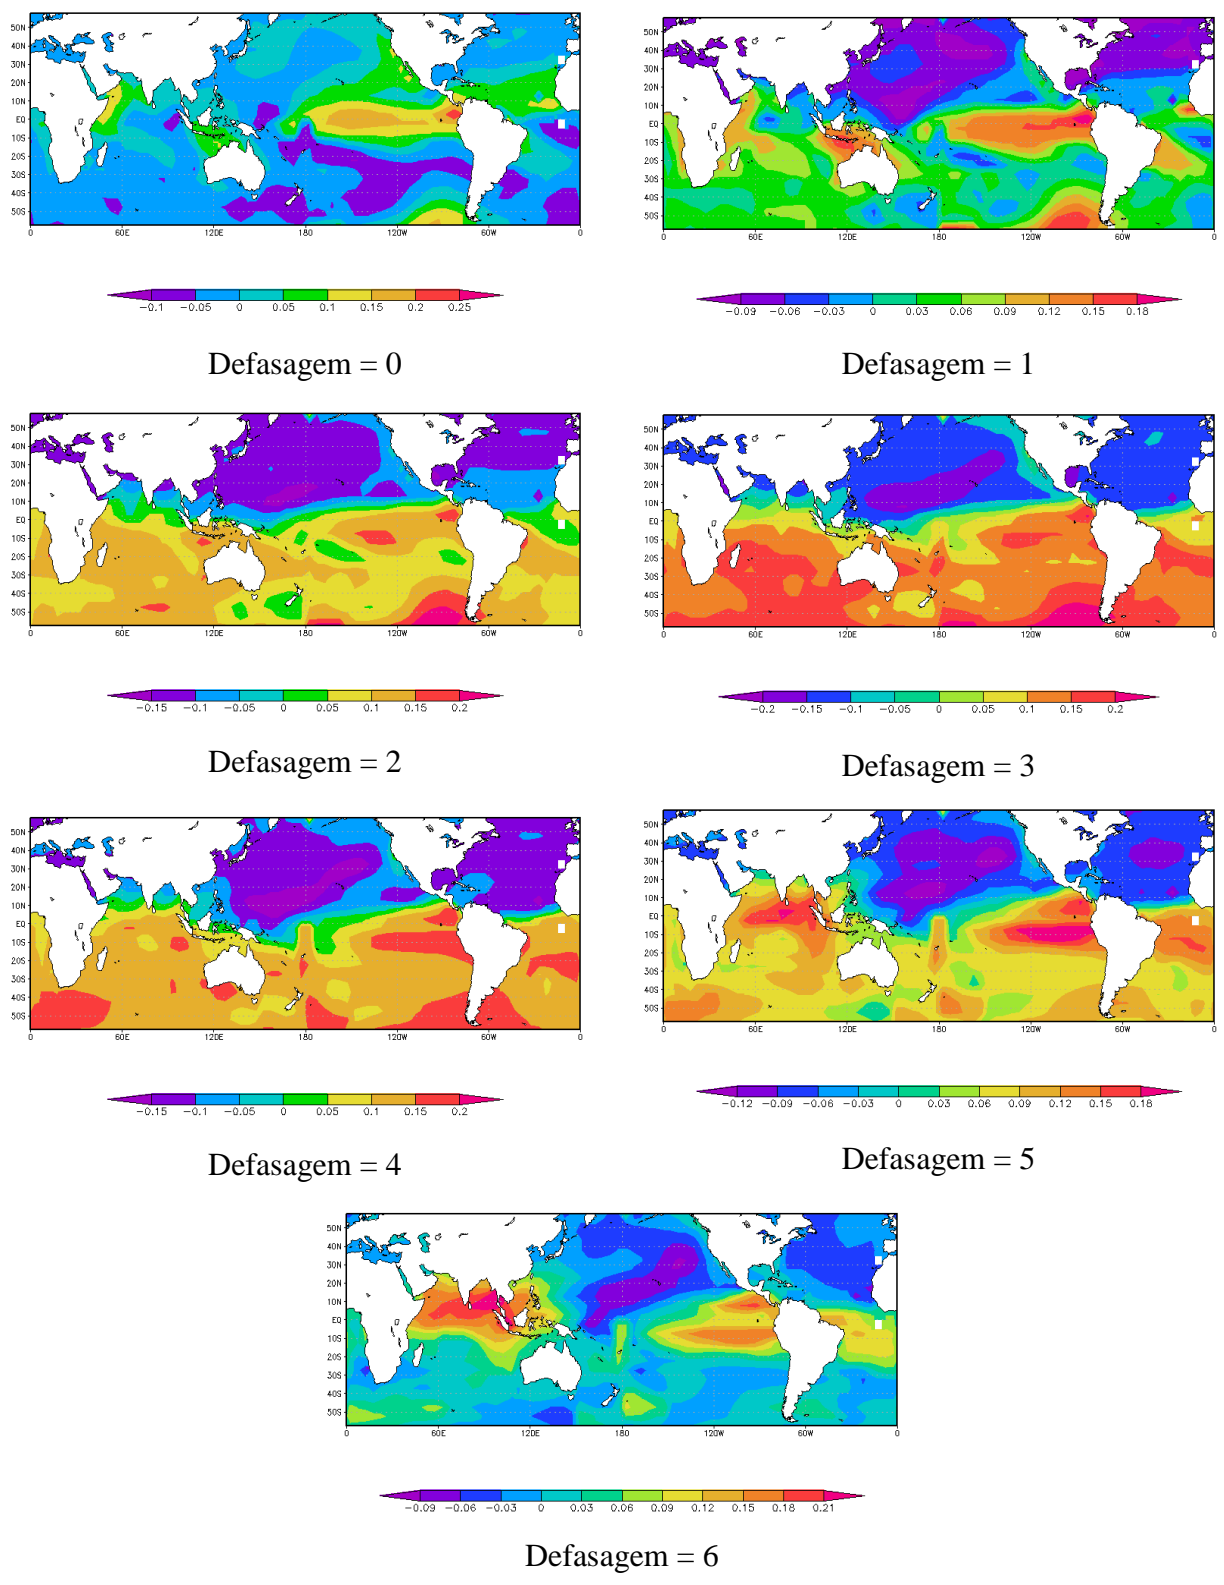
Tabela 2 – Correlações entre a região SR2 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

Defasagem 2									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lon	Lon		
55S	50S	120W	115W	0,226	55S	50S	130W	125W	0,222
Defasagem 3									
Lat	Lat	Lon	Lon		Lat	Lon	Lon		
55S	50S	125W	120W	0,237	60S	55S	115W	110W	0,237
60S	55S	135W	130W	0,239	60S	55S	120W	115W	0,239

Fonte: Autor.

A Figura 9, expressa as correlações encontradas nas defasagens de 0 até 6 meses para a precipitação acumulada mensal em SR2 com a TSM compreendida entre 60° norte a 60° sul.

Figura 9 – Correlação entre TSM e precipitação acumulada mensal para SR2



Fonte: Autor.

A Tabela 3 expressa as correlações da SR3, porém com valores mais altos que os encontrados em SR2. A influência da TSM nesta sub-região é mais imediata sendo a influência na precipitação para o mesmo mês ou com um mês de defasagem.

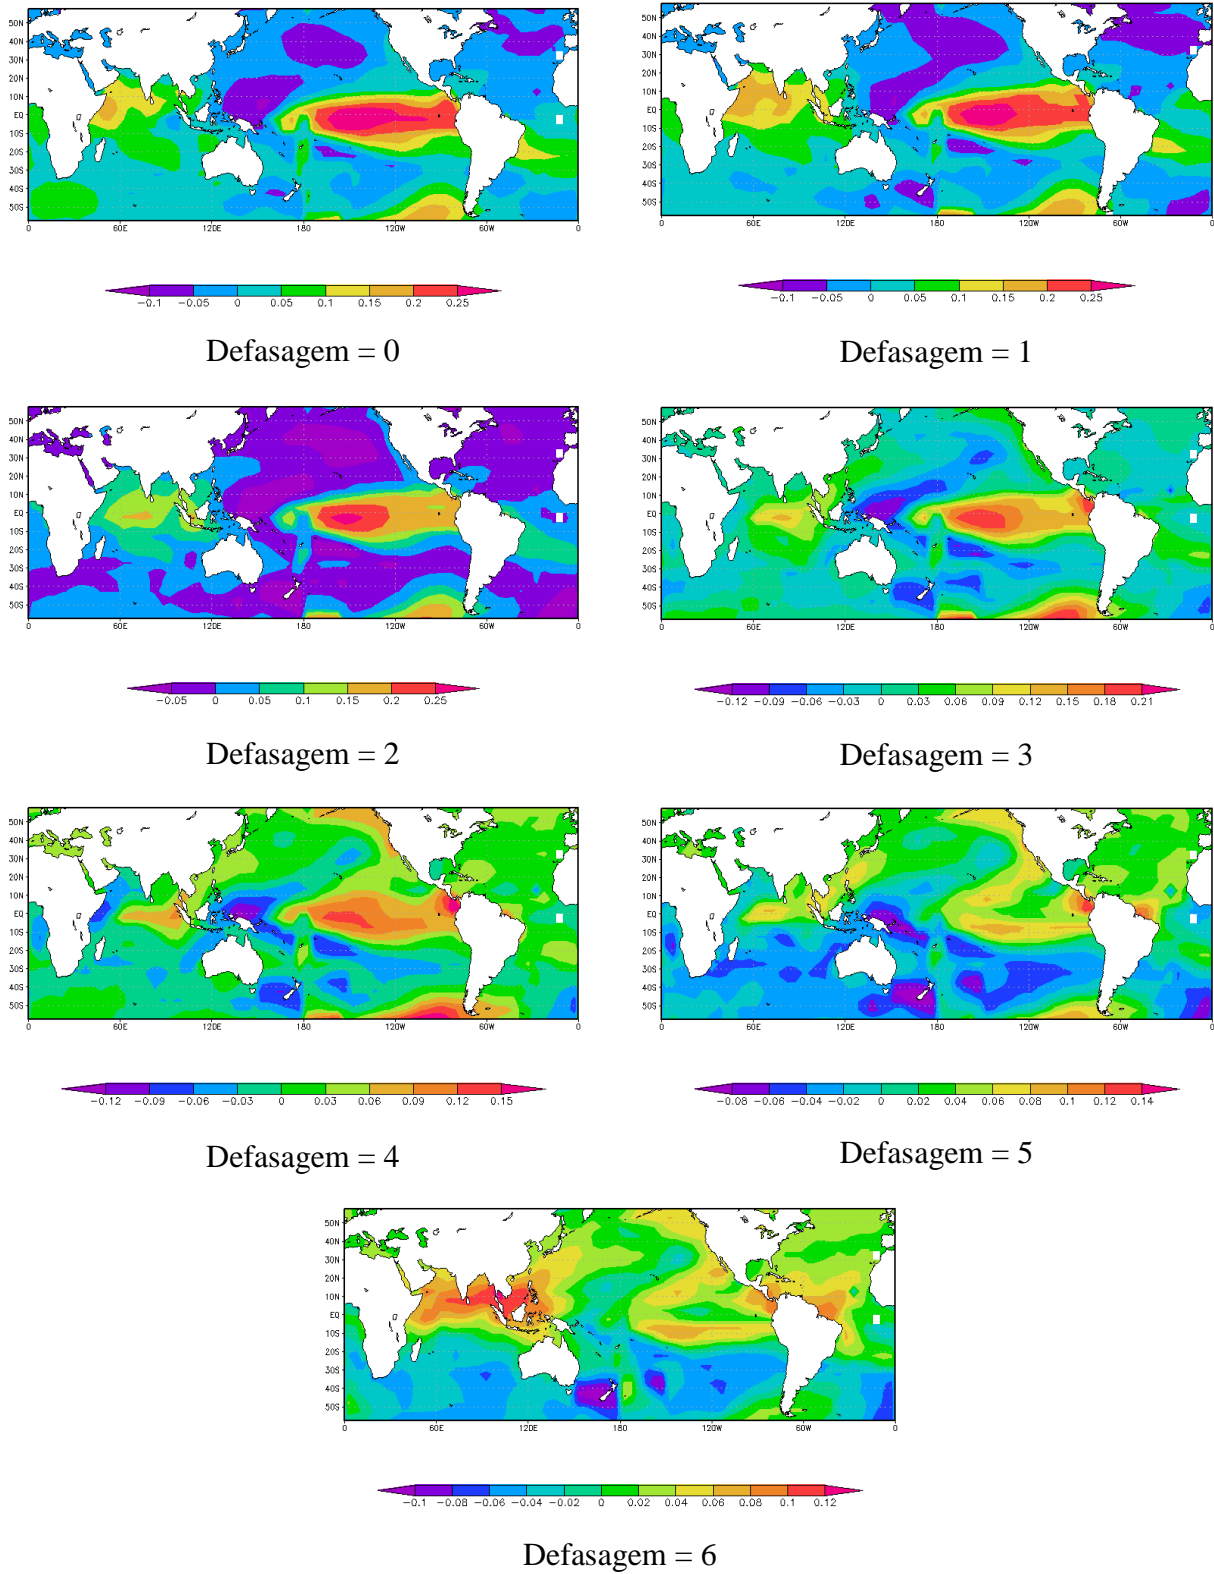
Tabela 3 – Correlações entre a região SR3 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

Defasagem 0									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lon	Lon		
5S	0S	140W	135W	0,278	5S	0S	145W	140W	0,285
5S	0S	150W	145W	0,288	5S	0S	160W	155W	0,285
Defasagem 1									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lon	Lon		
5S	0S	150W	145W	0,274	5S	0S	160W	155W	0,278
10S	5S	155W	150W	0,273	5S	0S	145W	140W	0,269

Fonte: Autor.

As correlações entre a precipitação acumulada mensal e a TSM da SR3 (Figura 10), também apresentam valores mais baixos, mas significativos, e as maiores correlações encontradas estão expostas na Tabela 3. As mesmas com o passar das defasagens vão se aproximando de zero, fenômeno que ocorre com as demais sub-regiões. Cabe ressaltar que estas correlações indicaram os valores mais altos no Oceano Pacífico tropical na região de atuação do fenômeno El Niño, o que era de se esperar, visto que o Rio Grande do Sul tem a precipitação fortemente impactada por este fenômeno.

Figura 10 – Correlação entre TSM e precipitação acumulada mensal para SR3



Fonte: Autor.

Tendo em vista que o intuito é utilizar a TSM como variável exógena no modelo de previsão ARIMAX, utilizou-se as médias das séries de TSM de cada defasagem expostas nas tabelas acima (Tabela 2, 3 e 4).

4.2.1 Análise da Sub-Região Sul 1 (SR1)

A série histórica de precipitação acumulada mensal que compõe a SR1 é obtida através da média das 16 séries históricas com maior similaridade, definidas pela análise de agrupamentos da seção anterior. As coordenadas que compõe a série estão descritas no Quadro 9 (Sub-regiões da região Sul com similaridades nas séries históricas de precipitação mensal).

Os valores quantílicos da região SR1, auxiliam a determinar e classificar a climatologia do local. O Quadro 10, demonstra os valores encontrados de acordo com a metodologia proposta no item 2.6 e servem para comparação/classificação das previsões futuras nas categorias, muito seco, seco, normal, chuvoso e muito chuvoso.


Quadro 10 – Classificação climatológica SR1

Classificação	Classes de Precipitação	
Muito Seco	$X_i \leq 78,41$	Abaixo da Normal
Seco	$78,41 < X_i \leq 110,3$	
Normal	$110,3 < X_i < 159,85$	Normal
Chuvoso	$159,85 \leq X_i < 200,7$	Acima da Normal
Muito Chuvoso	$X_i \geq 200,7$	
Sendo: X_i valores mensais observados de precipitação acumulada em milímetros.		

Fonte: Autor.

A Figura 11, apresenta uma primeira inspeção visual da categorização de toda a série em estudo SR1 e corroborar com o entendimento do Quadro 10. É possível observar que os valores da categoria “Muito chuvoso” são mais extremos que o seu extremo “Muito seco”. Enquanto que os últimos variam entre 0 e ~80mm, os primeiros podem variar de 200 até ~380mm.

Figura 11 – Classificação climatológica SR1



Fonte: Autor.

Após a categorização da série histórica através do Quadro 10 – Classificação climatológica SR1 e da Figura 11, faz-se necessário verificar as principais medidas descritivas da precipitação mensal acumulada da região em estudo SR1.

Os valores da média, desvio padrão, coeficiente de variação e valores máximo e mínimo das variáveis, utilizados neste estudo, estão expostos na Tabela 4. Analisando as distribuições dos dados, verificamos que a média aritmética é maior que a mediana, desta forma, temos uma distribuição assimétrica positiva a direita quando os valores se concentram na extremidade inferior da escala e se distribuem gradativamente em direção à extremidade superior, em suma, o terceiro quartil se afasta da mediana, enquanto que o primeiro quartil se aproxima da mesma o que indica tendência da precipitação acumulada mensal em distribuição normal ou abaixo da normal. O grau de concentração de valores, em torno de um valor médio, grandeza de afastamento que podem ser: homogêneas (fraca dispersão quando $C_v < 30\%$) ou heterogêneas (forte dispersão quando $C_v \geq 30\%$), enaltecem que a série em estudo é heterogênea. O grau de achatamento da distribuição, em relação a distribuição normal, a curtose ($C > 0,263$) distribuição é Platicúrtica, evidencia que a curva é mais achatada que a normal, ou seja, os dados se concentram em menor número em torno da média em relação a distribuição normal, a média não é representativa.


Tabela 4 – Medidas descritivas da precipitação acumulada mensal da SR1, 1980 a 2013

Medida Descritiva	Resultado
Média	139,44
Mediana	130,675
Desvio Padrão	64,88
Coefficiente de variação	46,53%
Valor máximo	371,46
Valor mínimo	10,29
Curtose	0,30
Assimetria	0,577

Fonte: Autor.

Inicialmente, pode-se observar, na Figura 12, o comportamento da série original buscando identificar suas componentes, como tendência, ciclos e/ou sazonalidade.

Figura 12 – Série Original da precipitação acumulada mensal da SR1, 1980 a 2013




Fonte: Autor.

Analisando, de forma visual, a Figura 12, verifica-se dois picos com precipitação acumulada consideráveis (índices elevados de precipitação), os anos de 1983 e 1997 que estão relacionados a ocorrência do fenômeno El Niño. Na análise estatística a ST não possui indícios de sazonalidade e ou ciclos, não demonstrando de forma explícita a presença de tendências crescentes ou decrescentes. Entretanto, como a série é extensa (precipitação acumulada mensal de 1980 a 2013) a inspeção gráfica pode apresentar distorções em sua avaliação. Desta forma, se faz necessário aplicar testes estatísticos para verificar as condições de estacionariedade e sazonalidade.

A decomposição da série original também auxilia a identificar componentes importantes da série como a presença de sazonalidade e/ou tendência. Na Figura 13, pode-se observar a decomposição da série em estudo nas suas componentes, tendência, sazonalidade e variações aleatórias.

Figura 13 – Decomposição da série temporal em componentes tendência, sazonalidade e aleatoriedade




Fonte: Autor.

Observa-se, na Figura 13, que a série tem um comportamento definido ao longo do tempo e, portanto, pode ser ajustada num modelo de previsão de ST. Também há de se considerar a presença de sazonalidade.

O gráfico das médias mensais, Figura 14, ajuda a detectar visualmente a presença de sazonalidade da ST. Como se pode observar, há indícios de que a ST apresenta média e variância não constantes, o que indica não estacionariedade na parte sazonal da ST.

Figura 14 – Média mensal de precipitação acumulada SR1



Fonte: Autor.

Observando a Figura 14, pode-se verificar ainda uma maior incidência de precipitação para os meses de outubro, dezembro, janeiro e fevereiro e menores acumulados de precipitação para os meses de abril, junho e agosto. A região SR1 é a mais ao norte das três e que apresenta características de uma precipitação monçônica, com maiores valores no verão.

Após a etapa inicial de análise descritiva e gráfica dos dados foram realizados testes estatísticos para confirmar se há estacionariedade e sazonalidade.

Para testar a presença ou não de estacionariedade foi utilizado o teste Dickey-Fuller, com as seguintes hipóteses do teste: $H_0 = \phi_1 = 1$: a série não estacionária e $H_1 = \phi_1 < 1$: a série é estacionária. Para o nível de significância $\alpha = 5\%$, encontrou-se as seguintes estatísticas de teste, $\hat{\tau} = -7,5266$ (valor calculado) e $\tau = -2,88$ (valor tabelado), $p - \text{valor} = 0,01$. Rejeita-se da hipótese nula (H_0) se $\hat{\tau} < \tau$. O teste, rejeita a hipótese nula H_0 (não estacionária), aceitando a hipótese alternativa H_1 de estacionariedade dos dados. Para Nascimento (2013) quando a série é estacionária, as propriedades estatísticas como média, variância e autocorrelação observadas no passado são as mesmas no futuro. Desta forma essas propriedades são de fundamental importância para o ajuste da série temporal.

Para avaliar a sazonalidade foi realizado o teste Kruskal-Wallis, sendo considerado as hipóteses: H_0 : não existe sazonalidade; e H_1 : existe sazonalidade. Como resultado do teste foi encontrado um $p - \text{valor} < 5,848^{-16}$, rejeitando-se a hipótese nula H_0 (e aceita a hipótese alternativa H_1 de presença de efeito sazonal na série, ao nível de significância $\alpha = 5\%$).

Para dar início a modelagem de ajuste e previsão de ST foram reservados os três últimos meses do ano de 2013 para fins de comparação das previsões. Ou seja, foram eliminados da série original os meses de setembro com precipitação acumulada de 177 mm (acima da normal/chuvoso), outubro com precipitação acumulada de 120,75 mm (precipitação normal), novembro com precipitação acumulada de 115,71 mm (precipitação normal). Para fins de comparação será utilizado a precipitação sazonal do período setembro, outubro e novembro, período de primavera para a região em estudo.

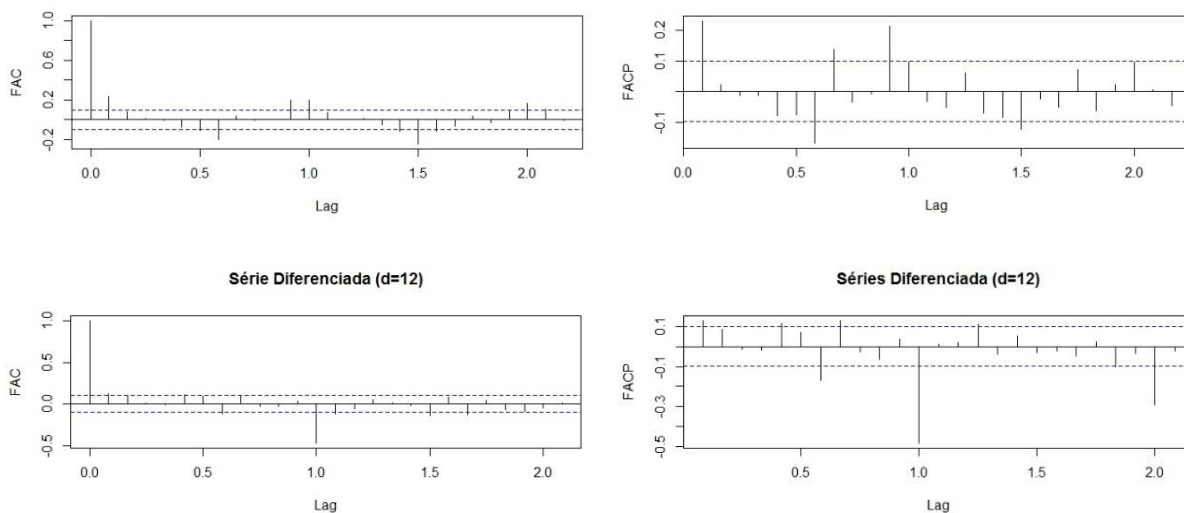
4.2.2 Modelos de ST para Sub-Região Sul 1

4.2.2.1 Modelo SARIMA (SON)

O primeiro modelo a ser ajustado a ST de precipitação acumulada da SR1 é o modelo SARIMA tendo em vista os testes estatísticos detectarem a presença de sazonalidade.

Os gráficos das funções de autocorrelação (FAC) e de autocorrelação parcial (FACP), expressos na Figura 15, demonstram as correlações seriais no domínio do tempo. Com base em suas frequências estimadas, é possível verificar sazonalidades e ciclos na série. Os lags significativos (linha verticais que ultrapassam as linhas tracejadas horizontais) são significativos e fornecem indícios da ordem de ajuste dos modelos. Na Figura 15, os correlogramas sem diferenças fornecem os indícios necessários para início do ajuste dos modelos (parâmetros autoregressivos, de médias móveis e a necessidade de diferenciações na ST). Já o gráfico com diferenças de ordem 12, confirmam a presença de sazonalidade se repetindo de 12 em 12 meses.

Figura 15 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP)



Fonte: Autor.

A FAC em nível corrobora com os testes estatísticos que a série é estacionária, não demonstrando fortes correlações entre os *lag*, não sendo necessário aplicar diferenciações para estabilizar a série ou seja, ST decresce rapidamente para zero. De acordo com Morettin (1987) o número de diferenciações d é aquele necessário para que a função de autocorrelação amostral (FAC) da série transformada decresça rapidamente para zero e possa ser analisado como um processo autoregressivo e de médias móveis. Ao se analisar os FAC e FACP em nível, percebem-se evidências de um modelo estacionário autorregressivo de ordem 1 a 3 e de médias móveis de ordem 1 ou 2. O FAC e O FACP com 12 diferenciações confirmam a presença de sazonalidade no *lag* 12. Os testes estatísticos e a análise gráfica indicam que um modelo do tipo SARIMA deve ser considerado. Essa análise é sumária e serve para dar início ao processo de modelagem, embora vários modelos de ordens diferentes foram considerados e testados.

Na Tabela 5, estão expostos alguns modelos concorrentes ajustados para a série SR1, com os respectivos valores de AIC e BIC e os parâmetros do modelo.

Tabela 5 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (SON)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1419$	4355,16	4371,06
	$\Phi_1 = 0,0061$		
	$\theta_1 = 0,0439$		
(1,0,0) (0,1,2) ₁₂	$\phi_1 = 0,1412$	4344,9	4360,78
	$\Theta_1 = -0,9920$		
	$\Theta_2 = -0,8690$		
(1,0, 0) (1,1,2) ₁₂	$\phi_1 = 0,1416$	4345,54	4365,39
	$\Phi_1 = 0,8334$		
	$\Theta_1 = -0,1317$		
	$\Theta_2 = -0,8683$		

Fonte: Autor.

Considerando os três melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual (ruído branco). O modelo SARIMA (1,0,0)(0,1,2)₁₂, com um parâmetro autorregressivo (p), um parâmetro de diferenças (D) na parte sazonal e dois parâmetros de médias móveis (Q) na parte sazonal atende a todas as condições de erros descorrelacionados, média zero, variância constante ao longo do tempo e normalidade dos resíduos, concluindo a última etapa da escolha do modelo para realizar previsões futuras. Estas considerações são válidas para todos os modelos SARIMA a partir deste ponto. Em resumo, foi utilizado o modelo com uma defasagem autorregressiva na parte ordinal que é explicado pelo mês anterior a previsão, uma diferença na parte sazonal o que demonstra variabilidade condicionada a sazonalidade e dois parâmetros de médias móveis na parte sazonal explicado pelos erros de previsão de dois meses passados.

Nessa etapa do trabalho, foram obtidas as previsões da série SR1 para um horizonte de três passos à frente, ou seja, meses que não foram considerados no ajuste do modelo. As previsões para o modelo ajustado SARIMA (1,0,0) (0,1,2)₁₂ podem ser observadas na Tabela 6.

Os resultados das previsões do modelo SARIMA $(1,0,0)(0,1,2)_{12}$ para o período sazonal setembro, outubro e novembro de 2013 (SON), estão na Tabela 6, assim como os respectivos valores da série observada correspondente a cada período e a classificação climatológica do período previsto e observado de acordo com as características regionais.


Tabela 6 – Classificação climatológica das previsões, segundo o modelo SARIMA $(1,0,0)(0,1,2)_{12}$, para região SR1 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	146,03mm	177mm	Normal	Acima da Normal
Out/2013	158,70mm	120,75mm	Normal	Normal
Nov/2013	137,48mm	115,71mm	Normal	Normal

Fonte: Autor.

Na Figura 16, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 16 – Modelo SARIMA $(1,0,0)(0,1,2)_{12}$ ajustado à série observada



Fonte: Autor.

Encontrou-se uma correlação significativa e positiva de 0,481, p – valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.2.2.2 Modelo SARIMAX (SON)

Para o ajuste do modelo SARIMAX, utilizou-se a TSM como variável exógena explicativa, com a finalidade de verificar se a mesma pode auxiliar a melhorar a qualidade das previsões da precipitação acumulada mensal.

Dentre os diversos modelos testados, na Tabela 7, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 7 – Modelos concorrentes SARIMAX e os respectivos critérios para a série SR1 (SON)

SARIMAX (p, q, r [D])	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (0,1,2) [1] ₁₂	$\phi_1 = 0,0935$ $\theta_1 = -0,9680$ $\theta_2 = -0,0320$ TSM= 65,0408	4325,49	4345,34
(1,1,1) (0,1,1) [1] ₁₂	$\phi_1 = 0,1399$ $\theta_1 = -0,9858$ $\theta_1 = -0,9926$ TSM= 65,5065	4347,05	4366,24
(0,0,0) (0,1,2) [1] ₁₂	$\theta_1 = -0,9585$ $\theta_2 = -0,0414$ TSM= 65,4159	4326,91	4342,79

Fonte: Autor.

Considerando os três melhores modelos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual. O modelo SARIMAX (1,0,0)(0,1,2)[1]₁₂, com um parâmetro autorregressivo (p), um parâmetro de diferenças (D) na parte sazonal e dois parâmetros de médias móveis (Q) na parte sazonal, um parâmetro exógeno (TSM), atende a todas as condições de erros descorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo para realizar previsões futuras. Estas considerações são válidas para todos os modelos SARIMAX a partir deste ponto. Nessa etapa do trabalho, foram obtidas as previsões da série SR1 para um horizonte de 3 passos à frente, ou seja, meses que não foram considerados no ajuste do modelo (o mesmo foi feito para todas as previsões das séries SR e SRS). As

previsões para o modelo ajustado SARIMAX (1,0,0)(0,1,2)[1]₁₂ podem ser observadas na Tabela 8.


Tabela 8 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,2) [1]₁₂, para região SR1 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	161,8196	177mm	Acima da Normal	Acima da Normal
Out/2013	175,0710	120,75mm	Acima da Normal	Normal
Nov/2013	146,9309	115,71mm	Normal	Normal

Fonte: Autor.

Na Figura 17, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 17 – Modelo SARIMAX (1,0,0)(0,1,2)[1]₁₂ ajustado à série observada (SON)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,5224 e significativa, $p - \text{valor} < 0,02^{-16}$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.2.2.3 Alisamento Exponencial Modelo Holt-Winters (SON)

Devido a presença de sazonalidade detectadas pelos testes estatísticos o modelo de alisamento exponencial que contempla essa importante componente é o Holt-Winters.

De acordo com as características da série, foi ajustado um modelo aditivo ou multiplicativo e, posteriormente, foi feita a comparação, utilizando os critérios de seleção. Os parâmetros exponenciais alisadores (α, β, γ) , são para o nível, tendência e sazonalidade, respectivamente.

No ajuste dos modelos, os valores das constantes de suavização que melhor se ajustaram ao modelo aditivo foram: $\alpha = 0,1156$ (constante de suavização do nível); $\beta = 0,0152$ (constante de suavização da tendência) e $\gamma = 0,1503$ (constante de suavização da sazonalidade) e, para o multiplicativo, foi: $\alpha = 0,0424$ (constante de suavização do nível); $\beta = 0,0235$ (constante de suavização da tendência) e $\gamma = 0,1112$ (constante de suavização da sazonalidade).

Utilizando os critérios de seleção descritos na metodologia, o modelo multiplicativo ajustou-se de forma mais adequada à série histórica em relação ao modelo aditivo. Como a série tem comportamento heterogêneo descrito na análise estatística descritiva esse resultado já era esperado.

Os resultados das previsões do modelo Holt-Winters multiplicativo para o período sazonal setembro, outubro e novembro de 2013, estão na Tabela 9, assim como os respectivos valores da série observada correspondente a cada período e classificação climatológica de acordo com as características regionais.

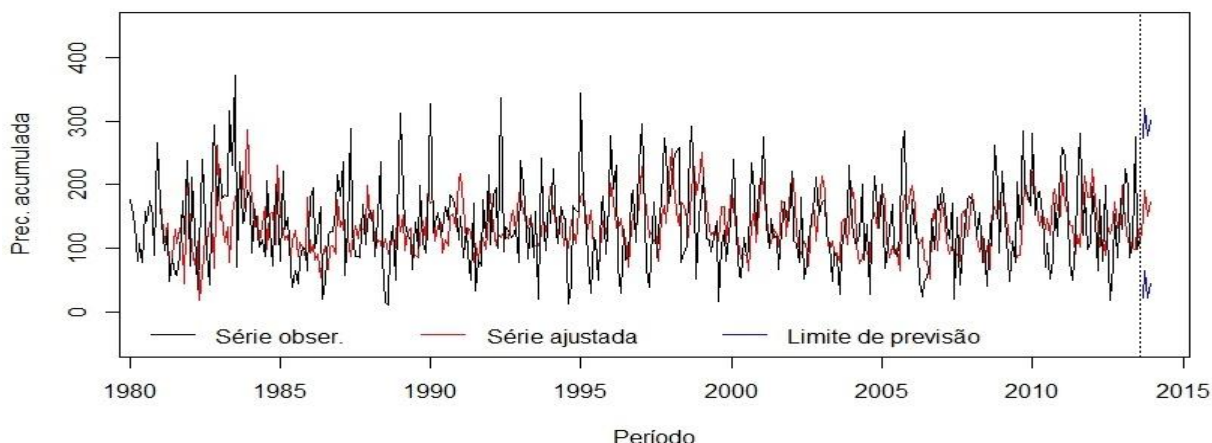
Tabela 9 – Classificação climatológica das previsões, segundo o modelo Holt-Winters multiplicativo, para região SR1 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	147,92mm	177mm	Normal	Acima da Normal
Out/2013	192,28mm	120,75mm	Acima da Normal	Normal
Nov/2013	157,03mm	115,71mm	Normal	Normal

Fonte: Autor.

Na Figura 18, podem ser observados os valores reais e previstos, além do intervalo de previsão ($h = 3$) do modelo Holt-Winters multiplicativo.

Figura 18 – Holt-Winters multiplicativo ajustado à variável SR1 (SON)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,45 (moderada) e significativa, p – valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.2.4 Modelos Combinados (SON)

A agregação dos resultados das previsões é feita, ponto a ponto, por uma média ponderada, na qual são atribuídos pesos proporcionais ao quadrado das correlações obtidas pelo ajuste de cada modelo individual. Sendo consideradas as correlações significativas ao nível de significância de 95% entre a série observada e ajustada. Para a combinação das previsões (Set, Out, Nov) utilizou-se as seguintes correlações: SARIMA ($r = 0,481$), SARIMAX ($r = 0,5224$) e HWM ($r = 0,45$). Os valores finais previstos para a precipitação trimestral acumulada são classificados em categorias, de “Abaixo da Normal” a “Normal” e Acima da Normal segundo os quantis em que se enquadrem dentro da distribuição de frequências climatológicas correspondentes.

Tabela 10 – Classificação climatológica das previsões, segundo os modelos combinados, para região SR1 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	152 mm	177mm	Normal	Acima da Normal
Out/2013	174 mm	120,75mm	Acima da Normal	Normal
Nov/2013	146 mm	115,71mm	Normal	Normal

Fonte: Autor.

A previsão combinada não se aproxima das previsões com a série observada categoricamente. A Tabela 11, demonstra uma comparação do desempenho dos modelos

Tabela 11 – Comparação dos Modelos utilizando os critérios de seleção (SON)


Modelo	MAPE (%)	EQM	MAD	SSE
HW Multiplicativo	26,12%	2678,86	49,28	10715,5
SARIMA (1,0,0) (0,1,2) ₁₂	22,57%	1223,15	34,01	4932,6
SARIMAX (1,0,0)(0,1,2) [1]	26,64%	1773,2	38,73	7092,8
COMBINADO	25,7%	14079	40	7095

Fonte: Autor.

A comparação do desempenho das previsões dos modelos utilizando os critérios expostos na Tabela 11, dimensionam a capacidade dos modelos para a região em estudo. Os valores em azul na tabela denotam os menores valores encontrados para cada um dos critérios, quanto menor o valor mais próximo o valor previsto é do valor observado. Em todos os critérios utilizados o Modelo SARIMA obteve melhor desempenho de previsão quando analisado na forma pontual e categórica.

A Figura 19, visa auxiliar a identificar visualmente o desempenho dos modelos, corroborando com Tabela 11. É possível observar que todos os modelos subestimaram a previsão de setembro de 2013 e superestimaram nos dois meses seguintes. O modelo SARIMA apresentou os melhores resultados, no entanto as diferenças entre eles são pequenas (barras em degradê na figura) o que sugere a robustez dos modelos.

Figura 19 – Desempenho dos modelos para SR1 (SON)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos diferentes modelos, foi aplicado o teste de Diebold e Mariano (1995) ao nível significância de 5% e 10%.

Tabela 12 – Teste Diebold e Mariano (1995) (SON)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	-0,825	-	SARIMAX x HWM	-2,0523	**
SARIMA x HWM	-1,80	*	SARIMAX x Combinado	-0,005	-
SARIMA x Combinado	-1,459	-	HWM x Combinado	1,995	**

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

Os resultados do teste indicam que há diferença significativa entre as previsões dos modelos SARIMA x HWM, com superioridade para o primeiro modelo, SARIMAX x HWM com superioridade para o primeiro modelo do par, HWM e Combinado, com superioridade preditiva do HWM.

4.2.2.5 Modelo SARIMA (JJA)

Novamente iniciaremos o ajuste da ST com o modelo Sarima, mas agora para os meses de junho, julho e agosto de 2013 (JJA).

Na Tabela 13, estão expostos alguns modelos concorrentes ajustados para a série SR1, com os respectivos valores de AIC e BIC, os parâmetros do modelo.

Considerando os três melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC. O modelo SARIMA (1,0,0) (1,1,2)₁₂, com um parâmetro autorregressivo (p), um parâmetro autorregressivo (P) na parte sazonal, um parâmetro de diferenças (D) na parte sazonal e dois parâmetros de médias móveis (Q) na parte sazonal atende a todas as condições de análise residual. Em resumo o modelo com uma defasagem autorregressiva na parte ordinal e sazonal que é explicado pelo mês anterior a previsão, uma diferença na parte sazonal o que demonstra variabilidade condicionada a sazonalidade e dois parâmetros de médias móveis na parte sazonal explicado pelos erros de previsão de dois meses passados.

Tabela 13 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (JJA)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1494$	4307,75	4328,6
	$\Phi_1 = -0,0053$		
	$\theta_1 = -0,1000$		
(1,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1491$	4308,76	4325,65
	$\theta_1 = -0,9920$		
(1,0,0) (1,1,2) ₁₂	$\phi_1 = 0,1480$	4306,67	4326,48
	$\Phi_1 = -0,8419$		
	$\theta_1 = -0,1275$		
	$\theta_2 = -0,8725$		

Fonte: Autor.

Os resultados das previsões do modelo SARIMA (1,0,0) (1,1,2)₁₂ para o período sazonal junho, julho e agosto de 2013, estão na Tabela 14, assim como os respectivos valores da série observada correspondente a cada período e a classificação climatológica do período previsto e

observado de acordo com as características regionais. É possível observar uma tendência do modelo em subestimar os valores observados, pois tanto em junho quanto em agosto os valores previstos foram abaixo do observado.


Tabela 14 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(1,1,2)₁₂, para região SR1 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	127,37mm	275,92mm	Normal	Acima da Normal
Jul/2013	108,51mm	98,99mm	Abaixo da Normal	Abaixo da Normal
Ago/2013	84,30mm	116,29mm	Abaixo da Normal	Normal

Fonte: Autor.

Na Figura 20, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%. Percebe-se que a St ajustada não consegue contemplar os maiores valores da série observada.

Figura 20 – Modelo SARIMA (1,0,0)(1,1,2)₁₂ ajustado à série observada



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,48995 e significativa, p -valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.2.6 Modelo SARIMAX (JJA)

O modelo SARIMAX foi ajustado utilizando a TSM como variável exógena explicativa e com isso identificar a influência da TSM na variável precipitação acumulada mensal.

Vários modelos SARIMAX foram testados e na Tabela 15, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC. Além destas informações a análise residual foi considerada para a escolha dos três melhores modelos ajustados. O modelo SARIMAX (1,0,0)(0,1,1)[1]₁₂, com um parâmetro autorregressivo (p), um parâmetro de diferenças (D) na parte sazonal e um parâmetro de médias móveis (Q) na parte sazonal, um parâmetro exógeno (TSM), atende a todas as condições de erros descorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo para realizar previsões futuras.

Tabela 15 – Modelos concorrentes SARIMAX e os respectivos critérios

SARIMAX (p, q, r [l])	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (0,1,2) [1] ₁₂	$\phi_1 = 0,01014$ $\theta_1 = -0,9819$ $\theta_2 = -0,0181$ TSM= 63,2121	4287,74	4307,55
(1,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,1032$ $\theta_1 = -0,9926$ TSM= 62,8326	4285,85	4301,7
(1,0,0) (1,1,2) [1] ₁₂	$\phi_1 = 0,01015$ $\Phi_1 = -0,7926$ $\theta_1 = -0,1758$ $\theta_2 = -0,824$ TSM= 62,775	4288,92	4312,70

Fonte: Autor.

As previsões para o modelo ajustado SARIMAX (1,0,0)(0,1,1) [1]₁₂, para os meses de JJA podem ser observadas na Tabela 16. Apesar da previsão encontrada para estes três meses não ser muito precisa, observa-se que o ajuste da ST apresentado na Figura 21 é mais fiel em representar os valores extremos de precipitação do que o modelo SARIMA, principalmente depois dos anos 2000.


Tabela 16 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,1) [1]₁₂, para região SR1 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	178,12mm	275,92mm	Acima da Normal	Acima da Normal
Jul/2013	126,07mm	98,99mm	Normal	Abaixo da Normal
Ago/2013	112,04mm	116,29mm	Normal	Normal

Fonte: Autor.

Na Figura 21 é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 21 – Modelo SARIMAX (1,0,0)(0,1,1) [1]₁₂ ajustado à série observada



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,5291 e significativa, $p - \text{valor} < 0,02^{-16}$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.2.2.7 Alisamento Exponencial Modelo Holt-Winters (JJA)

O modelo Holt-Winters contempla a presença de sazonalidade detectada pelos testes estatísticos e no ajuste dos modelos, os valores das constantes de suavização que melhor se ajustaram ao modelo aditivo foram: $\alpha = 0,1167$ (constante de suavização do nível); $\beta = 0,0152$ (constante de suavização da tendência) e $\gamma = 0,1493$ (constante de suavização da sazonalidade) e, para o multiplicativo, foi: $\alpha = 0,0443$ (constante de suavização do nível); $\beta =$

0,02256 (constante de suavização da tendência) e $\gamma = 0,1124$ (constante de suavização da sazonalidade).

Utilizando os critérios de seleção descritos na metodologia, o modelo multiplicativo obteve melhores resultados de previsão (ajustou-se de forma mais adequada à série histórica) em relação ao modelo aditivo.

Os resultados das previsões do modelo para o período sazonal junho, julho e agosto de 2013, estão na Tabela 17, assim como os respectivos valores da série observada correspondente a cada período e classificação climatológica de acordo com as características regionais.


Tabela 17 – Classificação climatológica das previsões, segundo o modelo Holt-Winters multiplicativo, para região SR1 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	106,73mm	275,92mm	Abaixo da Normal	Acima da Normal
Jul/2013	115,30mm	98,99mm	Normal	Abaixo da Normal
Ago/2013	92,66mm	116,29mm	Abaixo da Normal	Normal

Fonte: Autor.

Na Figura 22, podem ser vistos os valores observados e previstos, além do intervalo de previsão ($h = 3$) do modelo Holt-Winters multiplicativo. Novamente a série ajustada consegue reproduzir o padrão da precipitação, no entanto os valores extremos são subestimados.

Figura 22 – Holt-Winters multiplicativo ajustado à variável SR1



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,4591 e significativa, $p - valor < 0,02 - 16$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.2.8 Modelos Combinados (JJA)

Os valores finais previstos para a precipitação trimestral acumulada através da combinação das previsões dos modelos propostos e a categorização das previsões estão expostos na Tabela 18. As correlações utilizadas para o ajuste utilizadas foram: SARIMA ($r = 0,48995$), SARIMAX ($r = 0,5291$) e HWM ($r = 0,4591$).

Tabela 18 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR1 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	140,7 mm	275,92mm	Normal	Acima da Normal
Jul/2013	117 mm	98,99mm	Normal	Normal
Ago/2013	97,3 mm	116,29mm	Abaixo da Normal	Normal

Fonte: Autor.

A previsão combinada obteve dificuldades de ajuste para o mês de junho de 2013, devido ao grande acúmulo de precipitação acima do esperado para este mês. A Tabela 19, demonstra uma comparação do desempenho dos modelos.

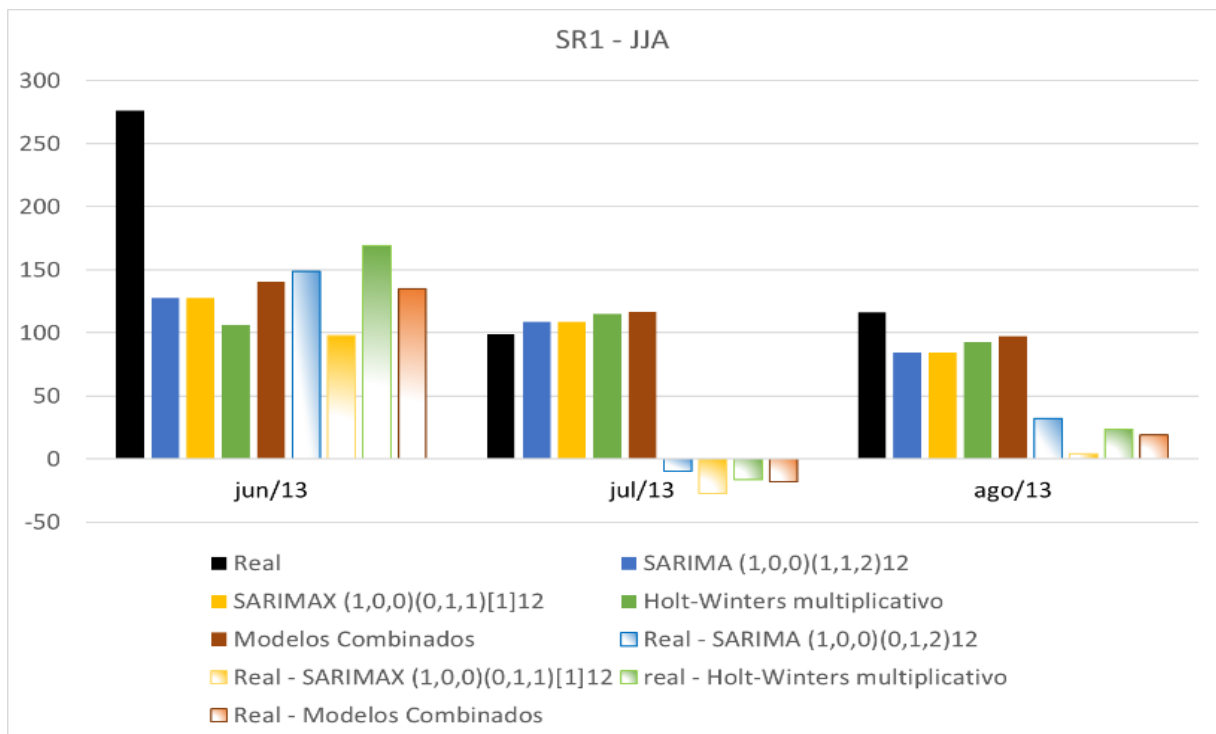
Tabela 19 – Comparação dos Modelos utilizando os critérios de seleção (JJA)

Modelo	MAPE (%)	EQM	MAD	SSE
HW Multiplicativo	32,68%	9815	69,68	29445
SARIMA(1,0,0) (1,1,2) ₁₂	30,34%	7761	63,44	23285
SARIMAX(1,0,0) (0,1,1) [1]	22,13%	3438	43,01	10315
COMBINADO	27,8%	9536	57,01	18900

Fonte: Autor.

A comparação do desempenho das previsões dos modelos utilizando os critérios expostos na Tabela 19, dimensionam a capacidade dos modelos para a região em estudo. Em todos os critérios utilizados o Modelo SARIMAX obteve melhor desempenho em relação aos seus concorrentes. No entanto nenhum dos modelos individualmente acertou todas as categorias da precipitação observada, isso fica muito claro ao avaliar a Figura 23, pois as diferenças entre a observação e a previsão (barras em degradê) é relativamente alta no mês de junho e agosto.

Figura 23 – Desempenho dos modelos para SR1 (JJA)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos diferentes modelos, foi aplicado o teste de Diebold e Mariano (1995) ao nível significância de 5% e 10%.

Tabela 20 – Teste Diebold e Mariano (1995) (JJA)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	1,0364	-	SARIMAX x HW	-1,0044	-
SARIMA x HW	-0,9312	-	SARIMAX x Combinado	-0,9865	-
SARIMA x Combinado	1,1457	-	HW x Combinado	1,0191	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

De acordo com os resultados do teste não há diferença significativa nas previsões dos modelos propostos. Isto vem corroborar com o encontrado na Figura 23.

4.2.2.9 Modelo SARIMA (MAM)

A terceira estação prevista será de março, abril e maio de 2013 (MAM) e o modelo a ser ajustado a ST de precipitação acumulada da sub-região sul 1 é o modelo SARIMA e na Tabela 21, estão expostos os principais modelos concorrentes ajustados e seus valores de AIC, BIC e os parâmetros específicos do modelo.

Tabela 21 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (MAM)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (1,1,0) ₁₂	$\phi_1 = 0,1541$	4339,82	4411,69
	$\Phi_1 = -0,0484$		
(1,0,0) (0,0,2) ₁₂	$\phi_1 = 0,2084$	4427,63	4447,56
	$\theta_1 = -0,1252$		
	$\theta_2 = -0,0919$		
(1,0,0) (1,1,2) ₁₂	$\phi_1 = 0,1475$	4275,18	4294,96
	$\Phi_1 = -0,8301$		
	$\theta_1 = -0,1371$		
	$\theta_2 = -0,8629$		

Fonte: Autor.

O modelo que melhor se ajustou utilizando os critérios de AIC, BIC e análise residual foi o SARIMA (1,0,0)(1,1,2)₁₂. Neste ajuste temos um parâmetro autorregressivo (p) na parte simples, um parâmetro de diferenças (D) e dois parâmetros de médias móveis (Q) na parte sazonal. Todos atendem, as condições de erros descorrelacionados, ruído branco e normalidade dos resíduos. Em suma o modelo com uma defasagem autorregressiva é explicado pelo mês anterior a previsão, uma diferença na parte sazonal o que demonstra variabilidade condicionada a sazonalidade e dois parâmetros de médias móveis na parte sazonal explicado pelos erros de previsão de dois meses passados.

Os resultados das previsões do modelo SARIMA $(1,0,0)(1,1,2)_{12}$ para o período sazonal MAM/2013, estão na Tabela 22, assim como os respectivos valores da série observada correspondente a cada período e a classificação climatológica do período previsto e observado de acordo com as características regionais.


Tabela 22 – Classificação climatológica das previsões, segundo o modelo SARIMA $(1,0,0)(1,1,2)_{12}$, para região SR1 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	139,13mm	126,65mm	Normal	Normal
Abr/2013	121,06mm	85,66mm	Normal	Abaixo da Normal
Mai/2013	125,72mm	108,75mm	Normal	Abaixo da Normal

Fonte: Autor.

Na Figura 24, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 24 – Modelo SARIMA $(1,0,0)(1,1,2)_{12}$ ajustado à série observada para SR1 (MAM)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,4916 (moderada) e significativa, p -valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado, ou seja, na combinação dos três este será ponderado por um fator de 0,49.

4.2.2.10 Modelo SARIMAX (MAM)

Para o ajuste do modelo SARIMAX e identificar a influência da TSM na variável precipitação acumulada mensal, utilizou-se a TSM nas regiões indicadas na Tabela 1 como variável exógena explicativa.

Dentre os diversos modelos testados, na Tabela 23, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 23 – Modelos concorrentes SARIMAX e os respectivos critérios para SR1 (MAM)

ARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (0,1,2) [1] ₁₂	$\phi_1 = 0,01004$ $\theta_1 = -0,9768$ $\theta_2 = -0,0232$ TSM= 63,1567	4256,43	4276,21
(1,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,1027$ $\theta_1 = -0,999$ TSM= 62,6882	4258,61	4283,43
(1,0,0) (1,1,2) [1] ₁₂	$\phi_1 = 0,01008$ $\Phi_1 = -0,7662$ $\theta_1 = -0,1985$ $\theta_2 = -0,8013$ TSM= 62,67	4257,57	4381,3

Fonte: Autor.

Para o trimestre MAM o modelo SARIMAX (1,0,0)(0,1,2)[1]₁₂, com um parâmetro autorregressivo (p), um parâmetro de diferenças (D) e dois parâmetro de médias móveis (Q) na parte sazonal, um parâmetro exógeno (TSM), atende a todas as condições de erros decorrelacionados, ruído branco e normalidade dos resíduos foi o escolhido e as previsões para o modelo ajustado podem ser observadas na Tabela 24.

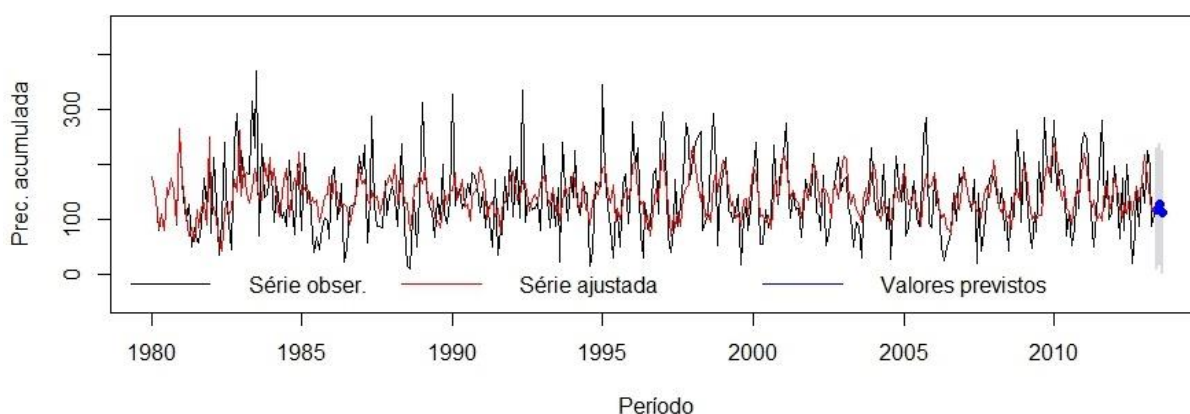
Tabela 24 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,2) [1]₁₂, para região SR1(MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	134,42mm	126,65mm	Normal	Normal
Abr/2013	112,17mm	85,66mm	Normal	Abaixo da Normal
Mai/2013	119,27mm	108,75mm	Normal	Abaixo da Normal

Fonte: Autor.

Na Figura 25, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 25 – Modelo SARIMAX (1,0,0)(0,1,1) [1]₁₂ ajustado à série observada SR1 (MAM)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,5284 (moderada) e significativa, p -valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma (correlação) será utilizada para o ajuste do modelo combinado. Comparando as previsões do modelo SARIMA (Tabela 22) com estas do modelo SARIMAX, observa-se que ambos apresentaram as mesmas categorias de previsão, no entanto, como este conseguiu um ajuste melhor, irá contribuir com um maior peso para o resultado final do modelo combinado.

4.2.2.11 Alisamento Exponencial Modelo Holt-Winters (MAM)

No ajuste dos modelos Holt-Winters, os valores das constantes de suavização que melhor se ajustaram ao modelo aditivo foram: $\alpha = 0,1185$ (constante de suavização do nível);

$\beta = 0,015$ (constante de suavização da tendência) e $\gamma = 0,1512$ (constante de suavização da sazonalidade) e, para o multiplicativo, foi: $\alpha = 0,0445$ (constante de suavização do nível); $\beta = 0,02230$ (constante de suavização da tendência) e $\gamma = 0,1128$ (constante de suavização da sazonalidade). Nesta previsão o modelo multiplicativo ajustou-se de forma mais adequada à série histórica em relação ao modelo aditivo.

Na Tabela 25 são apresentados os resultados das previsões do modelo para o período sazonal MAM bem como a classificação climatológica de acordo com as características regionais.


Tabela 25 – Classificação climatológica das previsões, segundo o modelo Holt-Winters multiplicativo, para região SR1 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	126,30 mm	126,65mm	Normal	Normal
Abr/2013	114,84 mm	85,66mm	Normal	Abaixo da Normal
Mai/2013	123mm	108,75mm	Normal	Abaixo da Normal

Fonte: Autor.

Na Figura 26, podem ser observados os valores reais e previstos, além do intervalo de previsão ($h = 3$) do modelo Holt-Winters multiplicativo.

Figura 26 – Holt-Winters multiplicativo ajustado à variável SR1 (MAM)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,4423 (moderada) e significativa, p -valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado. Dos três modelos utilizados neste período este foi o que apresentou a menor correlação entre a série observada e a série ajustada.

4.2.2.12 Modelos Combinados (MAM)

A Tabela 26 trás os resultados da agregação das previsões dos modelos propostos, para a precipitação trimestral acumulada período de março a maio de 2013. As correlações utilizadas para cada modelo foram: SARIMA ($r = 0,4916$), SARIMAX ($r = 0,5284$) e HWM ($r = 0,4423$).

Tabela 26 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR1 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	133 mm	126,65 mm	Normal	Normal
Abr/2013	115 mm	85,66 mm	Normal	Abaixo da Normal
Mai/2013	122 mm	108,75 mm	Normal	Abaixo da Normal

Fonte: Autor.

Como era de se esperar, já que os três modelos preveram a mesma categoria, a classificação sazonal previu também a categoria normal para o trimestre. No entanto podemos considerar que a previsão combinada obteve excelentes resultados o que reflete o bom ajuste dos demais modelos. A Tabela 27, demonstra o desempenho dos modelos.

Tabela 27 – Comparação dos Modelos utilizando os critérios de seleção (MAM)

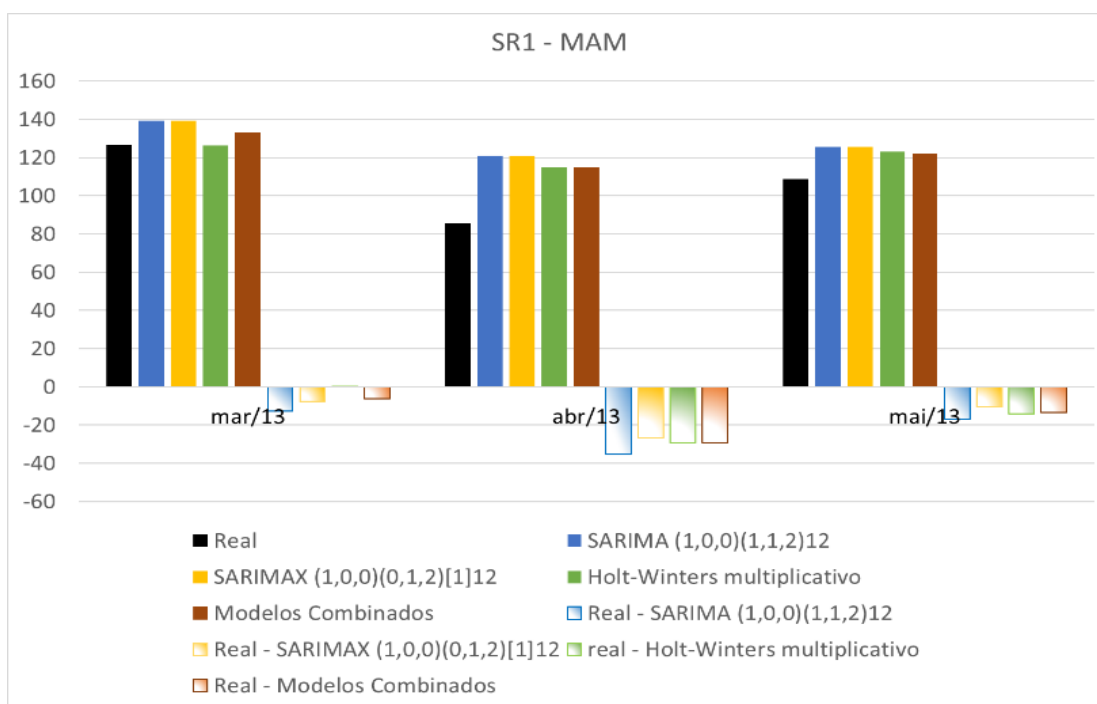
Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	15,81%	351	14,59	1054
SARIMA(1,0,0) (0,1,2) ₁₂	22,26%	565	21,61	1696
SARIMAX(1,0,0) (0,1,1) [1] ₁₂	15,58%	291	14,93	873
COMBINADO	17,48%	384	17,03	1153

Fonte: Autor.

A comparação do desempenho das previsões dos modelos utilizando os critérios expostos na Tabela 27, dimensionam a capacidade dos modelos para a região em estudo. Em todos os critérios utilizados o Modelo SARIMAX obteve melhor desempenho em relação aos seus concorrentes.

Na Figura 27, é possível verificar o desempenho das previsões dos modelos bem como a diferença entre os valores observados e previstos. Nota-se que mesmo não acertando a categorias das previsões, os valores previstos estão muito próximos.

Figura 27 – Desempenho dos modelos SR1 (MAM)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos diferentes modelos, foi aplicado o teste de Diebold e Mariano (1995) ao nível significância de 5% e 10%.

Tabela 28 – Teste Diebold e Mariano (1995) (MAM)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	1,9593	**	SARIMAX x HW	- 0,966	-
SARIMA x HW	2,23	**	SARIMAX x Combinado	1,450	-
SARIMA x Combinado	2,2975	**	HW x Combinado	1,36	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

Valores negativos indicam superioridade do primeiro modelo do par em relação ao segundo. Há diferença significativa nas previsões entre os modelos SARIMA x SARIMAX, SARIMA x HW e SARIMA x Combinado, com capacidade preditiva superior do segundo modelo do par em análise.

4.2.2.13 Modelo SARIMA (DJF)

O último trimestre de previsão é o verão de dezembro de 2012, janeiro e fevereiro de 2013 (DJF) e na Tabela 29 são apresentados os modelos SARIMA concorrentes ajustados para a série SR1, com os respectivos valores de AIC, BIC, e os parâmetros do modelo.

Tabela 29 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR1 (DJF)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (1,1,0) ₁₂	$\phi_1 = 0,1535$	4366,34	4378,18
	$\Phi_1 = -0,4828$		
(1,0,0) (0,0,2) ₁₂	$\phi_1 = 0,2113$	4394,83	4414,73
	$\Theta_1 = -0,1297$		
	$\Theta_2 = -0,0849$		
(1,0,0) (1,1,2) ₁₂	$\phi_1 = 0,1528$	4242,28	42262,02
	$\Phi_1 = -0,8176$		
	$\Theta_1 = -0,1471$		
	$\Theta_2 = -0,8528$		

Fonte: Autor.

Considerando os três melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC (quanto menor os valores destes dois parâmetros melhor é o modelo) o modelo SARIMA (1,0,0)(1,1,2)₁₂, atende a todas as condições de erros decorrelacionados, ruído branco e normalidade dos resíduos. O modelo em questão com uma defasagem autorregressiva é explicado por um mês anterior a previsão, uma diferença na parte sazonal o que demonstra variabilidade condicionada a sazonalidade e dois parâmetros de médias móveis na parte sazonal explicado pelos erros de previsão de dois meses passados.

A classificação climatológica das previsões é apresentada na Tabela 30, assim como os respectivos valores da série observada correspondente a cada período e a classificação climatológica do período previsto e observado de acordo com as características regionais.


Tabela 30 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(1,1,2)₁₂, para região SR1 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	152,24 mm	152,5 mm	Normal	Normal
Jan/2013	198,08 mm	129,22 mm	Acima da Normal	Normal
Fev/2013	169,51 mm	224,5 mm	Acima da Normal	Acima da Normal

Fonte: Autor.

Na Figura 28, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 28 – Modelo SARIMA (1,0,0)(1,1,2)₁₂ ajustado à série observada SR1 (DJF)



Fonte: Autor.

A correlação positiva e significativa, p -valor $< 0,02^{-16}$, entre a série observada e ajustada foi de 0,4934, cuja ponderação será usada para o ajuste do modelo combinado.

4.2.2.14 Modelo SARIMAX (DJF)

Os valores de 4223,32 para o AIC e 4243,06 para o BIC (Tabela 31), indicaram o modelo SARIMAX com um parâmetro autorregressivo (p), um parâmetro de diferenças (D) na

parte sazonal e dois parâmetro de médias móveis (Q) na parte sazonal, e um parâmetro exógeno (TSM) como o melhor a ser utilizado para este trimestre. As previsões para o modelo ajustado SARIMAX (1,0,0) (0,1,2) [1]₁₂ podem ser observadas na Tabela 32.

Tabela 31 – Modelos concorrentes SARIMAX e os respectivos critérios

SARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (1,1,0) [1] ₁₂	$\phi_1 = 0,0968$ $\Phi_1 = -0,4728$ TSM= 68,5898	4344,23	4360,03
(1,0,0) (0,1,2) [1] ₁₂	$\phi_1 = 0,1047$ $\theta_1 = -0,9748$ $\theta_2 = -0,0255$ TSM= 64,0851	4223,32	4243,06
(1,0,0) (1,1,2) [1] ₁₂	$\phi_1 = 0,1056$ $\Phi_1 = -0,7662$ $\theta_1 = -0,2006$ $\theta_2 = -0,7990$ TSM= 63,4367	4224,42	4248,11

Fonte: Autor.

Tabela 32 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0)(0,1,2) [1]₁₂, para região SR1 (DJF)


Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	166,11 mm	152,5 mm	Acima da Normal	Normal
Jan/2013	208,28 mm	129,22 mm	Acima da Normal	Normal
Fev/2013	182,78 mm	224,5 mm	Acima da Normal	Acima da Normal

Fonte: Autor.

Na Figura 29, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%. Encontrou-se uma correlação positiva de 0,5323

significativa, com $p - valor < 0,02^{-16}$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

Figura 29 – Modelo SARIMAX (1,0,0)(0, 1, 2)[1]₁₂ ajustado à série observada para SR1 (DJF)



Fonte: Autor.

4.2.2.15 Alisamento Exponencial Modelo Holt-Winters (DJF)

Os valores das constantes de suavização que melhor se ajustaram ao modelo aditivo foram Holt-Winters são: $\alpha = 0,1219$ (constante de suavização do nível); $\beta = 0,014$ (constante de suavização da tendência) e $\gamma = 0,1539$ (constante de suavização da sazonalidade) e, para o multiplicativo, foi: $\alpha = 0,0437$ (constante de suavização do nível); $\beta = 0,0223$ (constante de suavização da tendência) e $\gamma = 0,1142$ (constante de suavização da sazonalidade).

Utilizando os critérios de seleção descritos na metodologia, o modelo aditivo obteve melhores resultados de previsão ao contrário do que ocorreu nos outros trimestres, nos quais o modelo multiplicativo se ajustou melhor.

Os resultados das previsões do modelo para o período sazonal DJF, estão na Tabela 33, assim como os respectivos valores da série observada correspondente a cada período e classificação climatológica de acordo com as características regionais.


Tabela 33 – Classificação climatológica das previsões, segundo o modelo Holt-Winters aditivo para região SR1 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	158,54 mm	152,5 mm	Normal	Normal
Jan/2013	193,13 mm	129,22 mm	Acima da Normal	Normal
Fev/2013	167,17 mm	224,5 mm	Acima da Normal	Acima da Normal

Fonte: Autor.

Na Figura 30, são apresentados os valores observados e previstos, além do intervalo de previsão ($h = 3$) do modelo Holt-Winters aditivo.

Figura 30 – Holt-Winters aditivo ajustado à variável SR1 (DJF)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,4592 e significativa, p -valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.2.16 Modelos Combinados (DJF)

Os valores finais previstos para a precipitação trimestral acumulada período DJF/2013, através da combinação das previsões dos modelos propostos e a categorização das previsões estão expostos na Tabela 34. Utilizou-se os seguintes valores de correlação: SARIMA ($r = 0,4934$), SARIMAX ($r = 0,5323$) e (HWA ($r = 0,4592$)).

Tabela 34 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR1 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	159,3 mm	152,5 mm	Normal	Normal
Jan/2013	200 mm	129,22 mm	Acima da Normal	Normal
Fev/2013	174,2 mm	224,5 mm	Acima da Normal	Acima da Normal

Fonte: Autor.

A Tabela 35, demonstra uma comparação pontual do desempenho das previsões dos modelos.

Tabela 35 – Comparação dos Modelos utilizando os critérios de seleção (DJF)


Modelo	MAPE(%)	EQM	MAD	SSE
HW Aditivo	26,31%	2669	42,42	7804
SARIMA(1,0,0) (1,1,2) ₁₂	25,98%	2588	41,37	7765
SARIMAX(1,0,0) (0,1,2) [1] ₁₂	29,56%	2725	44,79	8176
COMBINADO	27,45%	3099	47,82	9299

Fonte: Autor.

De acordo com os resultados expostos na Tabela 35, em todos os critérios utilizados o modelo SARIMA obteve melhor desempenho em relação aos seus concorrentes.

A Figura 31, auxilia a verificar o desempenho dos modelos propostos. Vemos que dezembro foi muito bem previsto, por todos os modelos, seguido de fevereiro que teve uma ligeira subestimativa e janeiro uma superestimativa mais acentuada.

Figura 31 – Desempenho dos modelos para SR1 (DJF)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos diferentes modelos, foi aplicado o teste de Diebold e Mariano (1995) ao nível significância de 5% e 10%.

Tabela 36 – Teste Diebold e Mariano (1995) (DJF)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	-0,170	-	SARIMAX x HW	0,2387	-
SARIMA x HW	0,4311	-	SARIMAX x Combinado	0,2814	-
SARIMA x Combinado	0,0707	-	HW x Combinado	-0,193	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

Os resultados do teste demonstram que não há diferença significativa nas previsões dos modelos testados, ou seja, os modelos têm a mesma capacidade preditiva, o que também é corroborado pela Figura 31.

4.2.2.17 Síntese dos principais resultados encontrados para SR1

A Tabela 37 demonstra o desempenho dos modelos de forma pontual, através do critério de acurácia MAPE para SR1. Destaca-se o modelo SARIMA para o período sazonal (Set a Nov) e (Dez a Jan) sendo que não há diferença estatística nas previsões dos modelos para esse último período. Para o inverno, destaque para o modelo SARIMAX. Para o período (Mar a Maio), destaque para o modelo HW não havendo diferença estatística nas previsões entre os modelos HWM, SARIMAX e Combinado.

Tabela 37 – Desempenho dos modelos para SR1 de acordo com o critério MAPE

Modelo	MAPE(%) (Set a Nov)	MAPE(%) (Jun a Ago)	MAPE(%) Mar a Maio	MAPE(%) (Dez a Fev)
Holt-Winters	26,12%	32,68%	15,81%	26,31%
SARIMA	22,57%	30,34%	22,26%	25,98%
SARIMAX	26,64%	22,13%	15,58%	29,56%
COMBINADO	25,7%	27,8%	17,48%	27,45%

Fonte: Autor.

O Quadro 11 esboça o desempenho dos modelos na classificação categórica das previsões para SR1. Destaque para o modelo SARIMA e SARIMAX (Set a Nov), no período de inverno destaque para o SARIMAX, outono desempenho igual dos modelos e verão destaque para o modelo SARIMA, HWM e Combinado.

Quadro 11 – Classificação categóricas das previsões para SR1

(Continua)

Período	Observado	SARIMA	SARIMAX	HW	Combinado
		Previsto	Previsto	Previsto	Previsto
Primavera					
Set/2013	Acima da Normal	Normal	Acima da Normal	Normal	Normal
Out/2013	Normal	Normal	Acima da Normal	Acima da Normal	Acima da Normal
Nov/2013	Normal	Normal	Normal	Normal	Normal

Quadro 11 – Classificação categóricas das previsões para SR1

(Conclusão)

Período	Observado	SARIMA	SARIMAX	HW	Combinado
		Previsto	Previsto	Previsto	Previsto
Inverno					
Jun/2013	Acima da Normal	Normal	Acima da Normal	Abaixo da Normal	Normal
Jul/2013	Abaixo da Normal	Abaixo da Normal	Normal	Normal	Normal
Ago/2013	Normal	Abaixo da Normal	Normal	Abaixo da Normal	Abaixo da Normal
Outono					
Mar/2013	Normal	Normal	Normal	Normal	Normal
Abr/2013	Abaixo da Normal	Normal	Normal	Normal	Normal
Mai/2013	Abaixo da Normal	Normal	Normal	Normal	Normal
Verão					
Dez/2012	Normal	Normal	Acima da Normal	Normal	Normal
Jan/2013	Normal	Acima da Normal	Acima da Normal	Acima da Normal	Acima da Normal
Fev/2013	Acima da Normal	Acima da Normal	Acima da Normal	Acima da Normal	Acima da Normal

Fonte: Autor.

Ne sequência do trabalho foi analisado a sub-região sul 2.

4.2.3 Análise da Sub-Região Sul 2 (SR2)

A série histórica que compõe a região SR2 é obtida através da média das 18 séries históricas com maior similaridade, definidas pela análise de agrupamentos. As coordenadas que compõe a série estão descritas no Quadro 9 (Sub-regiões da região Sul com similaridades nas séries históricas de precipitação mensal).

Os valores quantílicos da região SR2, auxiliam a determinar e classificar a climatologia do local. O Quadro 12, demonstra os valores encontrados de acordo com metodologia proposta no item 2.6 e servem para comparações/classificação das previsões futuras nas categorias, muito

seco, seco, normal, chuvoso e muito chuvoso. É possível observar na região SR2 todos os valores de classes são mais altos que na SR1.


Quadro 12 – Classificação climatológica SR2

Classificação	Classes de Precipitação	
Muito Seco	$X_i \leq 83,69$	Abaixo da Normal (Seco)
Seco	$83,69 < X_i \leq 129,98$	
Normal	$129,98 < X_i < 171,51$	Normal
Chuvoso	$171,51 \leq X_i < 222,67$	Acima da Normal (Chuvoso)
Muito Chuvoso	$X_i \geq 222,67$	
Sendo: X_i valores mensais Observadas de precipitação acumulada.		

Fonte: Autor.

A Figura 32, busca auxiliar a categorização de toda a série em estudo SR2 e corroborar com o entendimento do Quadro 12. Fica muito claro que os extremos chuvosos de 1983 e 1997, relacionados ao fenômeno El Niño estão muito bem visíveis nesta ST.

Figura 32 – Classificação climatológica SR2



Fonte: Autor.

Após a categorização da série histórica Quadro 12 e Figura 32, faz-se necessário verificar as principais medidas descritivas da precipitação mensal acumulada da região em estudo SR2.

Os valores das médias e desvios padrões das variáveis, coeficiente de variação e valor máximo e mínimo, da série SR2, estão expostos na Tabela 38. Analisando as distribuições dos dados, assim como aconteceu com a SR1, a média aritmética é maior que a mediana, desta forma, temos uma distribuição assimétrica positiva a direita quando os valores se concentram na extremidade inferior da escala e se distribuem gradativamente em direção à extremidade superior, em suma, o terceiro quartil se afasta da mediana, enquanto que o primeiro quartil se aproxima da mesma, o que representa uma tendência a precipitação normal ou abaixo da normal.

O grau de concentração de valores enaltece que a série em estudo é heterogênea o que indica que a média não é representativa. E a curtose evidencia que a distribuição é mais achatada que a normal, ou seja, os dados se concentram em menor número em torno da média que a distribuição normal.


Tabela 38 – Medidas descritivas da precipitação acumulada mensal da SR2, 1980 a 2013

Medida Descritiva	Resultado
Média	154,44
Mediana	150,32
Desvio Padrão	68,85
Coeficiente de variação	44,52%
Valor máximo	478,49
Valor mínimo	23,71
Curtose	1,8
Assimetria	0,848

Fonte: Autor.

Na Figura 33 temos a representação, onde, segundo Box et al. (1994) verifica-se a condição de estacionariedade, estruturas comportamentais da série como tendência, sazonalidade, periodicidades, e ainda são observadas as autocorrelações.


Figura 33 – Série Original da precipitação acumulada mensal da SR2, 1980 a 2013



Fonte: Autor.

A decomposição da série original irá ajudar a identificar as componentes mais importantes da ST, por exemplo, se há presença de sazonalidade e/ou tendência. Na Figura 34, pode-se observar a decomposição da série em estudo nas suas componentes, tendência, sazonalidade e variações aleatórias.

Figura 34 – Decomposição da série temporal em componentes tendência, sazonalidade e aleatoriedade




Fonte: Autor.

Observa-se, na Figura 34, que a série tem um comportamento definido ao longo do tempo e, portanto, pode ser ajustada num modelo de previsão de série temporal. Também há de se considerar a presença de sazonalidade. É interessante observar que o impacto dos fortes eventos do El Niño de 1983 e 1997 aparecem como um pico de tendência.

O gráfico das médias mensais, Figura 35, ajuda a detectar visualmente a presença de sazonalidade na ST. Como se pode verificar, esta ST apresenta média e variância não constantes, indícios de não estacionariedade na parte sazonal da ST.

Figura 35 – Média mensal de precipitação acumulada SR2



Fonte: Autor.

Observando a Figura 35, há uma maior incidência de precipitação para o mês de outubro (apesar do maior valor individual aparecer em julho), e menor incidência para os meses de março e agosto. Com exceção destes três meses, os demais praticamente possuem médias muito próximas, mas variabilidade submensal considerável.

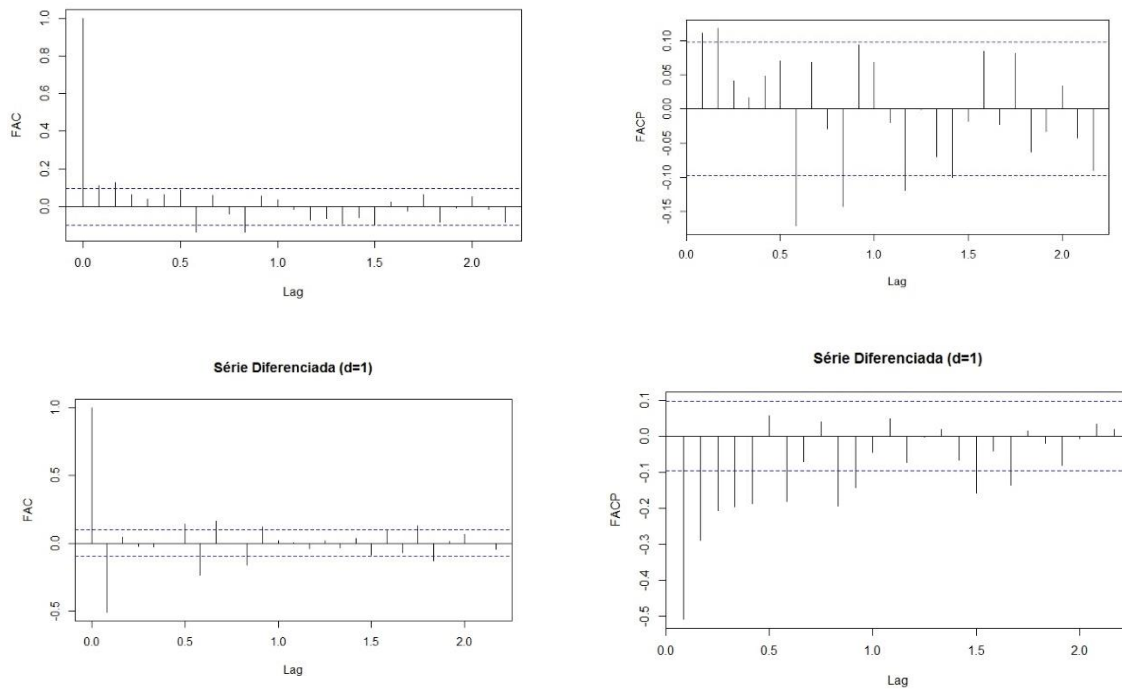
O teste estatístico de sequências (p -valor $> 0,05$), confirmou que a ST não possui tendência significativa e os testes estatísticos de Kruskal-Wallis e Friedman indicam a presença de sazonalidade, todos os três ao nível de significância $\alpha = 5\%$. O resultado para o teste de Dickey-Fuller Aumentado (ADF), segundo Dickey e Fuller (1981) revela que a série em estudo é estacionária.

4.2.4 Modelos de Séries Temporais para Sub-Região Sul 2

4.2.4.1 Modelo SARIMA (SON)

O modelo SARIMA foi o primeiro a ser ajustado e os gráficos das funções de autocorrelação (FAC) e de autocorrelação parcial (FACP) estão expressos na Figura 36. A análise da FAC e FACP evidenciou um modelo estacionário autorregressivo de ordem 1 a 4 e de médias móveis de ordem 1.

Figura 36 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) SR2



Fonte: Autor.

Na Tabela 39, estão expostos alguns modelos concorrentes ajustados para a série SR2, com os respectivos valores de AIC e BIC e os parâmetros do modelo. Neste caso, o modelo SARIMA que mais se ajustou foi o com dois parâmetros autorregressivo (p), uma diferença (D) na parte sazonal e um parâmetro de médias móveis (Q). Isto significa que o modelo com duas defasagens autorregressivas é explicado pelos dois meses anteriores a previsão, uma diferença na parte sazonal o que demonstra variabilidade condicionada a sazonalidade e um parâmetro de média móvel na parte sazonal explicado pelos erros de previsão de dois meses passados.

Tabela 39 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (SON)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,0949$	4439,58	4455,40
	$\phi_2 = 0,1716$		
	$\theta_1 = -0,9733$		
(1,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1176$	4450,65	4466,48
	$\Phi_1 = -0,056$		
	$\theta_1 = -0,9620$		
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,0963$	4441,14	4461,25
	$\phi_2 = 0,1685$		
	$\Phi_1 = -0,00255$		
	$\theta_1 = -0,9625$		

Fonte: Autor.

As previsões iniciaram pelo trimestre SON e podem ser observadas na Tabela 40, assim como os respectivos valores da série observada correspondente a cada período. Não só a classificação foi exata nos três meses de previsão, mas também os valores são muito próximos.


Tabela 40 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0)(0,1,1)₁₂, para região SR2 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	161,74 mm	165,46 mm	Normal	Normal
Out/2013	158,82 mm	160,02 mm	Normal	Normal
Nov/2013	154,70 mm	157,42 mm	Normal	Normal

Fonte: Autor.

Na Figura 37, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 37 – Modelo SARIMA ajustado à série observada SR2 (SON)



Fonte: Autor.

A correlação foi positiva, com valor de 0,37 e significativa, p-valor < 0,011, entre a série observada e ajustada. Fica claro que o a série ajustada só consegue capturar uma parcela pequena da ST observada.

4.2.4.2 Modelo SARIMAX (SON)

Para o ajuste do modelo SARIMAX, utilizou-se a TSM como variável exógena.

Dentre os diversos modelos testados, na Tabela 41, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 41 – Modelos concorrentes SARIMAX e os respectivos critérios para SR2 (SON)

ARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,0556$	4422,66	4442,56
	$\phi_2 = 0,1376$		
	$\theta_1 = -0,9559$		
	TSM = 26,68		
(1,0,1) [1] ₁₂	$\phi_1 = 0,6722$	4463,22	4483,23
	$\theta_1 = -0,5736$		
	TSM = 8,912		

(Continua)

Tabela 41 – Modelos concorrentes SARIMAX e os respectivos critérios para SR2 (SON)

ARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) [1] ₁₂	$\phi_1 = 0,0844$	4462,56	4482,57
	$\phi_2 = 0,0988$		
	TSM = 9,6121		

Fonte: Autor.

Considerando os três melhores modelos ajustados, de acordo com os critérios de seleção AIC e BIC. O modelo SARIMAX (2,0,0) (0,1,1) [1], com dois parâmetros autorregressivo (p), uma diferença na parte sazonal (D), um parâmetro de médias móveis (Q) e um parâmetro exógeno (TSM), atende a todas as condições de erros descorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo para realizar previsões futuras. As previsões para a série SR2, podem ser observadas na Tabela 42.


Tabela 42 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0)(0,1,1) [1]₁₂, para região SR2 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	136,22 mm	165,46 mm	Normal	Normal
Out/2013	145,71 mm	160,02 mm	Normal	Normal
Nov/2013	144,71 mm	157,42 mm	Normal	Normal

Fonte: Autor.

Na Figura 38, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 38 – Modelo SARIMAX (2,0,0)(0,1,1)[1]₁₂ ajustado à série observada SR2 (SON)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,3652 e significativa, p -valor $< 0,00072$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.2.4.3 Modelos de Alisamento Exponencial e de Holt-Winters (SON)

No ajuste dos modelos, os valores das constantes de suavização que melhor se ajustaram ao modelo HW Multiplicativo foram: $\alpha = 0,03628$ (constante de suavização do nível); $\beta = 0,020$ (constante de suavização da tendência) e $\gamma = 0,0921$ (constante de suavização da sazonalidade). Para o modelo de suavização exponencial simples, foi encontrado $\alpha = 0,0001$, o pequeno valor do coeficiente determina que as variáveis mais recentes possuem um peso menor para a estimação do modelo em relação aos valores passados.

Os resultados das previsões do modelo HW multiplicativo e AES para o período sazonal SON/2013, estão na Tabela 43, assim como os respectivos valores da série observada correspondente a cada período e classificação climatológica de acordo com as características regionais.


Tabela 43 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR2 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
HW multiplicativo				
Set/2013	169,86 mm	165,46 mm	Normal	Normal
Out/2013	232,54 mm	160,02 mm	Acima da Normal	Normal
Nov/2013	153,07 mm	157,42 mm	Normal	Normal
AES				
Set/2013	154,40 mm	165,46 mm	Normal	Normal
Out/2013	154,40 mm	160,02 mm	Normal	Normal
Nov/2013	154,40 mm	157,42 mm	Normal	Normal

Fonte: Autor.

Na Figura 39, tem-se a representação dos valores observados e previstos, além do intervalo de previsão ($h = 3$) do modelo Holt-Winters multiplicativo.

Figura 39 – Holt-Winters multiplicativo ajustado à variável SR2 (SON)



Fonte: Autor.

Encontrou-se uma correlação entre série ajustada e observada de -0,09 e não significativa, $p\text{-valor} > 0,05$, para o modelo AES, e correlação de 0,4423 e significativa, $p\text{-valor} < 0,05$, para o modelo HWM. A mesma será usada para o ajuste do modelo combinado.

4.2.4.4 Modelos Combinados (SON)

Os valores finais previstos para a precipitação trimestral acumulada período de setembro a novembro de 2013, através da combinação das previsões dos modelos propostos estão expostos na Tabela 44. Os valores de r utilizados foram: SARIMA ($r = 0,37$), SARIMAX ($r = 0,3652$) e HWM ($r = 0,4413$).

Tabela 44 – Classificação climatológica das previsões, segundo os modelos combinados, para região SR2 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	154,44	165,46 mm	Normal	Normal
Out/2013	186,02	160,02 mm	Acima da Normal	Normal
Nov/2013	151,01	157,42 mm	Normal	Normal

Fonte: Autor.

A previsão combinada aproxima as previsões com a série observada, exceto para o mês de outubro. A Tabela 45, demonstra uma comparação pontual do desempenho dos modelos propostos.

Tabela 45 – Comparação dos Modelos utilizando os critérios de seleção (SON)


Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	19,91%	1765,81	27,09	5297,41
SARIMA	3,99%	81,55	6,53	244,65
SARIMAX	11,56%	407,09	18,75	1221,49
COMBINADO	8,98%	279,42	14,46	838,25
AES	4,038%	54,54	6,56	163,02

Fonte: Autor.

A comparação do desempenho das previsões, o modelo SARIMA obteve melhor desempenho em relação a seus concorrentes. Na classificação categórica o modelo SARIMA e SARIMAX, atingiram 100% de acerto. A Figura 40 corrobora com os resultados expressos na Tabela 45.

A Figura 40, auxilia a identificar o melhor desempenho entre os modelos.

Figura 40 – Desempenho dos modelos para SR2 (SON)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos modelos propostos, foi aplicado o teste de Diebold e Mariano (1995).

Tabela 46 – Teste Diebold e Mariano (1995) (SON)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	-0,2189	**	SARIMAX x HWM	-0,73	-
SARIMA x HWM	-0,94	-	SARIMAX x Combinado	0,92	-
SARIMA x Combinado	-0,96	-	SARIMAX x AES	1,86	*
SARIMA x AES	0,63	-	HWM x Combinado	0,93	-
Combinado x AES	1,64	-	HWM x AES	0,97	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

Há diferença estatística entre o modelo SARIMA e o modelo SARIMAX capacidade preditiva melhor para o primeiro modelo. E entre o modelo SARIMAX e AES com vantagem para o modelo de alisamento exponencial.

A próxima etapa da pesquisa foi realizar previsões para o período de JJA/2013, inverno para a região em estudo.

4.2.4.5 Modelo SARIMA (JJA)

O primeiro modelo a ser ajustado a série temporal de precipitação acumulada da SR2, para a estação climática de inverno de 2013 é o modelo SARIMA.

Na Tabela 47, estão expostos alguns modelos concorrentes ajustados para a série SR2, com os respectivos valores de AIC e BIC, os parâmetros do modelo.

Tabela 47 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (JJA)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1011$	4405,28	4421,12
	$\phi_2 = 0,1684$		
	$\theta_1 = -0,9668$		
(1,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1238$	4415,73	4431,58
	$\Phi_1 = -0,0484$		
	$\Theta_1 = -0,9581$		
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1024$	4407,14	4426,25
	$\phi_2 = 0,1656$		
	$\Phi_1 = -0,0232$		
	$\Theta_1 = -0,958$		

Fonte: Autor.

Considerando os três melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC, o modelo SARIMA, com dois parâmetros autorregressivo (p) na parte ordinal, uma diferença e um parâmetro de médias móveis (Q) na parte sazonal, atende a todas as condições de análise residual. Em suma o modelo autorregressivo SARIMA com duas defasagens autorregressiva que é explicado pelos dois meses anterior a previsão, uma

defasagem de médias móveis na parte sazonal explicada pelo erro de previsão de um mês passado e uma defasagem afins de tornar estacionária a parte sazonal da ST, ou seja, tornar os efeitos da variância constantes. Os resultados das previsões do modelo SARIMA (2,0,0) (0,1,1)₁₂, estão expostos na Tabela 48.


Tabela 48 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1)₁₂ para região SR2 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	136,7 mm	210,95mm	Normal	Acima da Normal
Jul/2013	142,2 mm	84,81mm	Normal	Abaixo da Normal
Ago/2013	113,5 mm	195,56mm	Abaixo da Normal	Acima da Normal

Fonte: Autor.

Na Figura 41, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%. Observa-se que a ST ajustada não consegue captar adequadamente os movimentos da ST observada.

Figura 41 – Modelo SARIMA (1,0,0) (0,1,1)₁₂ ajustado à série observada SR2 (JJA)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,3380 (moderada) e significativa, p-valor < 0,0009, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.4.6 Modelo SARIMAX (JJA)

A TSM foi utilizada como variável exógena para o ajuste do modelo SARIMAX.

Na Tabela 49, estão os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 49 – Modelos concorrentes SARIMAX e os respectivos critérios para SR2 (JJA)

ARIMAX (p,q,r[l])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,0611$ $\phi_2 = 0,1331$ $\theta_1 = -0,9548$ TSM = 27,43	4387,76	4407,57
(1,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,0703$ $\theta_1 = -0,9578$ TSM = 27,46	4392,7	4408,56
(1,0,0) (1,1,1) [1] ₁₂	$\phi_1 = 0,0693$ $\Phi_1 = -0,0073$ $\theta_1 = -0,9601$ TSM = 27,59	4394,69	4414,51

Fonte: Autor.

Considerando os três melhores modelos ajustados, de acordo com os critérios de seleção AIC e BIC. O modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂, atende a todas as condições de erros decorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo para realizar previsões futuras. As previsões para o modelo ajustado SARIMAX podem ser observadas na Tabela 50.


Tabela 50 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1]₁₂, para região SR2 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	136,57mm	210,95mm	Normal	Acima da Normal
Jul/2013	139,98mm	84,81mm	Normal	Abaixo da Normal
Ago/2013	124,24mm	195,56mm	Normal	Acima da Normal

Fonte: Autor.

Na Figura 42, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 42 – Modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂ ajustado à série observada SR2 (JJA)



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,3819 (moderada) e significativa, p-valor $< 0,02^{-15}$ entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado. Ao contrário do que ocorreu no modelo SARIMA, o ajuste do modelo SARIMAX foi superior, conseguindo não só representar o comportamento geral da ST mas também alguns valores mais extremos.

4.2.4.7 Alisamento Exponencial Simple e de Holt-Winters (JJA)

As características da série sugerem o modelo HWM devido ao comportamento explosivo dos dados principalmente na componente sazonal onde a média e a variância não são constantes. No ajuste do modelo HWM encontrou-se $\alpha = 0,03651$; $\beta = 0,020$ e $\gamma = 0,0936$. Para fins de comparação nesta classe de modelos ajustou-se o AES.

Os resultados das previsões do modelo HWM e AES, estão expostos na Tabela 51.


Tabela 51 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR2 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
HW multiplicativo				
Set/2013	136,54mm	210,95mm	Normal	Acima da Normal
Out/2013	145,18mm	84,81mm	Normal	Abaixo da Normal
Nov/2013	112,43mm	195,56mm	Abaixo da Normal	Acima da Normal
AES				
Set/2013	154,40 mm	210,95mm	Normal	Acima da Normal
Out/2013	154,40 mm	84,81mm	Normal	Abaixo da Normal
Nov/2013	154,40 mm	195,56mm	Normal	Acima da Normal

Fonte: Autor.

Na Figura 43, podem ser visualizadas as ST dos valores observados e previstos, além do intervalo de previsão ($h = 3$) do modelo HWM. Percebe-se que o modelo não consegue se aproximar dos pontos mais extremos.

Figura 43 – Holt-Winters multiplicativo ajustado à variável SR2 (JJA)



Fonte: Autor.

A correlação entre série ajustada e observada é de $-0,0968$ não significativa para o modelo AES. Para o modelo HWM, $r = 0,423$ significativa, $p\text{-valor} < 0,05$. A mesma será usada para o ajuste do modelo combinado.

4.2.4.8 Modelos Combinados (JJA)

As correlações utilizadas no ajuste do modelo combinado foram: SARIMA (0,3380), SARIMAX (0,3815), HWM (0,423). Os valores previstos para JJA/2013, através da combinação das previsões dos modelos propostos estão expostos na Tabela 52.

Tabela 52 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR2 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	142,53mm	210,95mm	Normal	Acima da Normal
Jul/2013	146,06mm	84,81mm	Normal	Abaixo da Normal
Ago/2013	134,27mm	195,56mm	Normal	Acima da Normal

Fonte: Autor.

A previsão combinada obteve piores resultados em relação aos modelos concorrentes, principalmente devido ao grande acúmulo de precipitação no mês de junho de 2013, ou seja, a uma variabilidade contida nos dados. A Tabela 53, demonstra a comparação do desempenho dos modelos.


Tabela 53 – Comparação dos Modelos utilizando os critérios de seleção (JJA)

Modelo	MAPE(%)	EQM	MAD	SSE
SARIMA(2,0,0) (0,1,1) ₁₂	48,3%	3130,71	54,7	9392,13
SARIMAX(1,0,0) (0,1,1) [1]	45,18%	3736	69,29	11209
HW Multiplicativo	49,66%	5363	72,63	16091
COMBINADO	46,33%	4062	63,65	12188
ASE	43,3%	3244	55,7	9734,81

Fonte: Autor.

A comparação do desempenho das previsões dos modelos utilizando os critérios expostos na Tabela 53, apontam que os modelos em estudo não possuem desempenho satisfatório para previsões no período de inverno da região SR2. A flutuação dos valores observados para o período torna os modelos ineficientes, ou seja, há uma grande variabilidade na precipitação acumulada o que dificulta os modelos propostos de captar as informações contidas na ST em estudo. Fato esse também evidente quando as previsões são classificadas de forma categóricas e na Figura 44, é possível verificar visualmente que os modelos não se aproximam da série real.

Figura 44 – Desempenho dos modelos SR2 (JJA)



Fonte: Autor.

A Tabela 54, trás os resultados do teste Diebold e Mariano (1995). Valores negativos indicam superioridade do primeiro modelo do par em relação ao segundo.

Tabela 54 – Teste Diebold e Mariano (1995) (JJA)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x ARIMAX	-1,15	-	SARIMAX x HW	-1,22	-
SARIMA x HW	-1,89	*	SARIMAX x Combinado	-0,6	-
SARIMA x Combinado	-1,52	-	SARIMAX x AES	0,4	-
SARIMA x AES	-1,007	-	HW x Combinado	1,32	-
Combinado x AES	0,86	-	HW x AES	1,14	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%

Fonte: Autor.

O teste indica que há diferença significativa nas previsões entre os modelos SARIMA e HW com capacidade preditiva superior do modelo SARIMA. Os resultados acusam que praticamente todos os modelos tem a mesma capacidade de previsão. A estação climática

inverno, região SR2, não é prevista adequadamente pelos modelos em estudo conforme resultados expressos na Tabela 53 e classificações categoricas.

A próxima etapa do trabalho foi realizar previsões para o período de outono da SR2.

4.2.4.9 Modelo SARIMA (MAM)

O primeiro modelo a ser ajustado para o período de MAM/2013 da SR2, foi o SARIMA. Na Tabela 55, estão expostos alguns modelos concorrentes ajustados para a série SR2, com os respectivos valores de AIC e BIC e os parâmetros do modelo.

Tabela 55 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (MAM)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1017$	4370,58	4386,40
	$\phi_2 = 0,1727$		
	$\theta_1 = -0,9722$		
(1,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1249$	4381,65	4397,48
	$\Phi_1 = -0,445$		
	$\theta_1 = -0,962$		
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1026$	4372,14	4392,25
	$\phi_2 = 0,1704$		
	$\Phi_1 = -0,0187$		
	$\theta_1 = -0,9641$		

Fonte: Autor.

O modelo SARIMA (2,0,0) (0,1,1)₁₂, com dois parâmetros autorregressivos (p) na parte ordinal, uma diferença e um parâmetro de médias móveis (Q) na parte sazonal, atende a todas as condições de erros descorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo.

Os resultados das previsões do modelo SARIMA (2,0,0) (0,1,1)₁₂ para o período sazonal MAM/2013, estão na Tabela 56, onde é possível observar que na classificação categórica o modelo atinge dois dos três meses em análise.


Tabela 56 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1)₁₂, para região SR2 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	122,87mm	122,98mm	Abaixo da Normal	Abaixo da Normal
Abr/2013	160,60mm	136,73mm	Normal	Normal
Mai/2013	140,09mm	126,21mm	Normal	Abaixo da Normal

Fonte: Autor.

Na Figura 45, trás a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 45 – Modelo SARIMA (2,0,0) (0,1,1)₁₂ ajustado à série observada SR2



Fonte: Autor.

Ao contrário do que ocorreu com a representação da ST nos meses de JJA, aqui a ST ajustada conseguiu ser mais fidedigna a série observada. Encontrou-se uma correlação positiva de 0,3487 e significativa, p -valor $< 0,07^{-13}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.4.10 Modelo SARIMAX (MAM)

Entre os diversos modelos testados, na Tabela 57, estão expostos os modelos com melhor desempenho para a previsão da precipitação acumulada mensal.

Tabela 57 – Modelos concorrentes SARIMAX e os respectivos critérios para a série SR2 (MAM)

SARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1]	$\phi_1 = 0,0621$ $\phi_2 = 0,1378$ $\theta_1 = -0,9598$ TSM= 27,44	4353,05	4372,83
(1,0,0) (0,1,1) [1]	$\phi_1 = 0,0719$ $\theta_1 = -0,9625$ TSM= 27,42	4358,44	4374,27
(1,0,0) (1,1,1) [1]	$\phi_1 = 0,0701$ $\Phi_1 = -0,0126$ $\theta_1 = -0,9670$ TSM= 27,64	4360,40	4380,18

Fonte: Autor.

Considerando os três melhores modelos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual. O modelo SARIMAX com dois parâmetros autorregressivo (p), um parâmetro de diferenças (D) na parte sazonal e um parâmetro de médias móveis (Q) na parte sazonal, um parâmetro exógeno (TSM), atende a todas os pressupostos exigidos para o ajuste do modelo. As previsões do modelo ajustado SARIMAX (2,0,0) (0,1,1) [1]₁₂ para SR2 MAM podem ser apreciados na Tabela 58. Os resultados da classificação categórica mostram que o modelo alcança dois meses do total de três observados.


Tabela 58 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂, para região SR2 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	118,66mm	122,98mm	Abaixo da Normal	Abaixo da Normal
Abr/2013	156,30mm	136,73mm	Normal	Normal
Mai/2013	141,89mm	126,21mm	Normal	Abaixo da Normal

Fonte: Autor.

Na Figura 46, pode ser constatado o bom ajuste entre a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 46 – Modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂ ajustado à série observada SR2



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,4046 (moderada) e significativa, p-valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma (correlação) será utilizada para o ajuste do modelo combinado. Neste modelo a representação da ST observada está até melhor que a do modelo SARIMA, o que também é indicado pela correlação encontrada.

4.2.4.11 Alisamento Exponencial Modelo Holt-Winters (MAM)

No ajuste do modelo HWM foi encontrado os seguintes parâmetros: $\alpha = 0,03695$ (constante de suavização do nível); $\beta = 0,01995$ (constante de suavização da tendência) e $\gamma = 0,09285$ (constante de suavização da sazonalidade). Para o modelo AES, foi encontrado $\alpha = 0,0001$, e a constante de 154,21 mm, este modelo só utilizado para fins de comparação na classe de alisamento exponencial.

A classificação climatológica e os resultados das previsões do modelo HWM e AES para o período sazonal de inverno da SR2, estão na Tabela 59. Onde percebe-se que o modelo HWM, acerta 100% dos meses observados.


Tabela 59 – Classificação climatológica das previsões, segundo o modelo HWM e AES, para região SR2 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
HW multiplicativo				
Mar/2013	116,54mm	122,98mm	Abaixo da Normal	Abaixo da Normal
Abr2013	149,75mm	136,73mm	Normal	Normal
Maió/2013	125,65mm	126,21mm	Abaixo da Normal	Abaixo da Normal
AES				
Mar/2013	147,85 mm	122,98mm	Normal	Abaixo da Normal
Abr2013	147,85 mm	136,73mm	Normal	Normal
Maió/2013	147,85 mm	126,21mm	Normal	Abaixo da Normal

Fonte: Autor.

Os valores reais e ajustados, além do intervalo de previsão ($h=3$) do modelo HWM, podem ser visualizados na Figura 47.

Figura 47 – Holt-Winters multiplicativo ajustado à variável SR2



Fonte: Autor.

Encontrou-se a correlação de 0,4422 significativa, $p\text{-valor} < 0,02^{-16}$, para o modelo HWM e para o modelo AES simples uma correlação de -0,09 $p\text{-valor} = 0,056$. O modelo AES não foi usado para o modelo combinado devido a correlação não ser significativa entre a série

observada e ajustada. É possível observar, pela primeira vez, uma tentativa da ST se ajustar aos valores da ST observada, no entanto, muitas vezes isso ocorre fora de fase.

4.2.4.12 Modelos Combinados (MAM)

Os valores para o período de MAM de 2013, através da agregação das previsões dos modelos propostos estão expostos na Tabela 60. As correlações utilizadas para o modelo SARIMA, SARIMAX e HWM foram respectivamente; $r = 0,3487$, $r = 0,4046$ e $r = 0,4422$.

Tabela 60 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR2 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	118,86mm	122,98mm	Abaixo da Normal	Abaixo da Normal
Abr/2013	154,72mm	136,73mm	Normal	Normal
Mai/2013	134,82mm	126,21mm	Normal	Abaixo da Normal

Fonte: Autor.

A previsão do modelo HWM obteve os melhores resultados de previsão em relação aos modelos concorrentes tanto categóricas quanto pontuais. A Tabela 61, demonstra uma comparação do desempenho dos modelos.

Tabela 61 – Comparação dos Modelos utilizando os critérios de seleção (MAM)


Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	5,06%	70,43	6,67	211
SARIMA(2,0,0) (0,1,1) ₁₂	9,51%	254,14	12,62	762
SARIMAX(2,0,0) (0,1,1) [1] ₁₂	10,08%	215,83	13,19	647
COMBINADO	7,78%	138,82	10,24	414
AES	15,16%	403,48	19,21	1210

Fonte: Autor.

Na Tabela 61, é possível verificar o bom desempenho dos modelos propostos para a previsão da precipitação acumulada para a estação climática do autono da SR2.

Na Figura 48, também é possível determinar visualmente o desempenho satisfatório dos modelos testados.

Figura 48 – Desempenho dos modelos SR2 (MAM)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos diferentes modelos, faplicou-se o teste de Diebold e Mariano (1995) ao nível significância de 5% e 10%. A Tabela 62, expressa os resultados do teste.

Tabela 62 – Teste Diebold e Mariano (1995) (MAM)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	-1,32	-	SARIMAX x HWM	1,71	*
SARIMA x HWM	0	-	SARIMAX x Combinado	1,38	-
SARIMA x Combinado	-0,65	-	SARIMAX x AES	1,04	-
SARIMA x AES	-1,76	*	HWM x Combinado	-1,36	-
Combinado x AES	-1,1	-	HWM x AES	-1,73	*

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%

Fonte: Autor.

De acordo com o teste há diferença significativa nas previsões entre os modelos HWM, SARIMAX e AES, com capacidade preditiva superior do modelo HWM. Os resultados apontam que praticamente todos os modelos tem a mesma capacidade de preditiva. A estação climática outono, SR2, é prevista adequadamente pelos modelos em estudo conforme resultados expressos na Tabela 61. Não se recomenda o uso do modelo AES.

A próxima etapa do trabalho foi realizar previsões para o período de dezembro de 2012, janeiro e fevereiro de 2013, verão para a região em estudo SR2.

4.2.4.13 Modelo SARIMA (DJF)

Para estação de verão da SR2, o primeiro modelo a ser ajustado é o modelo SARIMA, com o objetivo de previsões sazonais para os meses DJF. Na Tabela 63, estão expostos alguns modelos concorrentes ajustados para a série SR2, com os respectivos valores de AIC e BIC, os parâmetros do modelo.

Tabela 63 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR2 (DJF)

SARIMA (p, d, q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1092$	4337,16	4352,95
	$\phi_2 = 0,1672$		
	$\theta_1 = -0,9729$		
(1,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1319$	4345,95	4357,8
	$\theta_1 = -0,9868$		
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1099$	4339,1	4358,84
	$\phi_2 = 0,1656$		
	$\Phi_1 = -0,0137$		
	$\theta_1 = -0,9668$		

Fonte: Autor.

Considerando os três melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual. O modelo SARIMA (2,0,0) (0,1,1)₁₂, atende a todas as condições de erros descorrelacionados, ruído branco e normalidade dos resíduos

sendo adequado para realizar previsões futuras. Os resultados das previsões do modelo SARIMA $(2,0,0)(0,1,1)_{12}$ estão na Tabela 64.


Tabela 64 – Classificação climatológica das previsões, segundo o modelo SARIMA $(2,0,0)(0,1,1)_{12}$, para região SR2 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	150,10 mm	258,54 mm	Normal	Acima da Normal
Jan/2013	148,75 mm	139,33 mm	Normal	Normal
Fev/2013	157,48 mm	173,15,5	Normal	Acima da Normal

Fonte: Autor.

Na classificação das previsões na forma categórica Tabela 64, bem como na Figura 49, pode se verificar, uma dificuldade do modelo em se aproximar dos valores observados.

Figura 49 – Modelo SARIMA $(2,0,0)(0,1,1)_{12}$ ajustado à série observada SR2



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,3507 e significativa, $p\text{-valor} < 0,7^{-16}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.4.14 Modelo SARIMAX (DJF)

Para o ajuste do modelo SARIMAX, utilizou-se a TSM como variável exógena explicativa. A Tabela 65, expõem os melhores modelos encontrados para SR2, período DJF, de acordo com os critérios de seleção AIC e BIC.

Tabela 65 – Modelos concorrentes SARIMAX e os respectivos critérios SR2

SARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1])	$\phi_1 = 0,0696$ $\phi_2 = 0,1324$ $\theta_1 = -0,9627$ TSM= 27,13	4320,2	4339,94
(1,0,0) (0,1,2) [1])	$\phi_1 = 0,0782$ $\theta_1 = -0,9573$ $\theta_2 = -0,016$ TSM= 27,42	4326,84	4346,58
(1,0,0) (1,1,2) [1])	$\phi_1 = 0,079$ $\Phi_1 = -0,9535$ $\theta_1 = 0,0265$ $\theta_2 = -0,9735$ TSM= 26,97	4326,48	4350,17

Fonte: Autor.

O modelo SARIMAX (1,0,0) (0,1,1) [1]₁₂, com um parâmetro autorregressivo (p), um parâmetro de diferenças (D) na parte sazonal e um parâmetro de médias móveis (Q) na parte sazonal, um parâmetro exógeno (TSM), atende a todas as condições de erros decorrelacionados, ruído branco e normalidade dos resíduos e concluem a etapa da escolha do modelo para realizar previsões futuras. As previsões para o modelo ajustado SARIMAX (1,0,0)(0,1,2) [1]₁₂ podem ser observadas na Tabela 66.


Tabela 66 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1]₁₂, para região SR2 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	164,10 mm	258,54 mm	Normal	Acima da Normal
Jan/2013	142,38 mm	139,33 mm	Normal	Normal
Fev/2013	165,48 mm	173,15 mm	Normal	Acima da Normal

Fonte: Autor.

Apesar das previsões pontuais se aproximarem das observadas Tabela 66, a classificação sazonal não reflete o bom desempenho do modelo. A Figura 50, demonstra a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 50 – Modelo SARIMAX (1,0,0)(0,1,1) [1]₁₂ ajustado à série observada SR2



Fonte: Autor.

A correlação entre série ajustada e observada é de 0,4057 significativa, p-valor < 0,02⁻¹⁶. A mesma será utilizada para o ajuste do modelo combinado.

4.2.4.15 Alisamento Exponencial Modelo Holt-Winters (DJF)

De acordo com características da ST, optou-se pelo ajuste do modelo HWM, os parâmetros encontrados foram: $\alpha = 0,03845$ (constante de suavização do nível); $\beta = 0,0191$

(constante de suavização da tendência) e $\gamma = 0,0944$ (constante de suavização da sazonalidade). Para fins de comparação dentro da classe de alisamento exponencial ajustou-se o modelo AES.

Os resultados das previsões do modelo HWM e AES para o período sazonal de DJF, estão na Tabela 67.


Tabela 67 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR2 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
HW multiplicativo				
Mar/2013	142,84 mm	258,54 mm	Normal	Acima da Normal
Abr2013	152,20 mm	139,33 mm	Normal	Normal
Mai/2013	141,37 mm	173,15 mm	Normal	Acima da Normal
AES				
Mar/2013	153,14 mm	258,54 mm	Normal	Acima da Normal
Abr2013	153,14 mm	139,33 mm	Normal	Normal
Mai/2013	153,14 mm	173,15 mm	Normal	Acima da Normal

Fonte: Autor.

Na Figura 51, podem ser observados os valores observados e previstos, além do intervalo de previsão ($h=3$) do modelo HWM.

Figura 51 – Holt-Winters multiplicativo ajustado à variável SR2



Fonte: Autor.

Encontrou-se uma correlação positiva de 0,36 e significativa, $p\text{-valor} < 0,02^{-16}$, entre a série observada e ajustada para o modelo HWM e para o modelo AES simples uma correlação de -0,09 não significativo.

4.2.4.16 Modelos Combinados (DJF)

Os valores finais previstos para a precipitação trimestral acumulada período de dezembro de 2012 a fevereiro de 2013, através da agregação das previsões dos modelos propostos estão expostos na Tabela 68. Utilizou-se as seguintes correlações: SARIMA (0,3507), SARIMAX (0,4057) e HWM (0,36).

Tabela 68 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR2 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	153,45 mm	258,54 mm	Normal	Acima da Normal
Jan/2013	147,30 mm	139,33 mm	Normal	Normal
Fev/2013	155,21 mm	173,15 mm	Normal	Acima da Normal

Fonte: Autor.

A previsão do modelo SARIMAX obteve os melhores resultados de previsão em relação aos modelos concorrentes. Na Tabela 69, pode se observar a comparação do desempenho dos modelos.

Tabela 69 – Comparação dos Modelos utilizando os critérios de seleção (DJF)


Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	24,11%	4854	53,4	14562
SARIMA(2,0,0) (0,1,1) ₁₂	19,25%	4031	44,5	12093
SARIMAX(2,0,0) (0,1,1) [1]	14,57%	3001	35,4	9003
COMBINADO	18,9%	3817	43,7	11451
AES	20,71%	3875	46,2	11626

Fonte: Autor.

A Tabela 69, demonstra o desempenho dos modelos propostos para a previsão da precipitação acumulada para a estação climática do verão região SR2. O mês de dezembro possui uma variabilidade climática considerável embutida na série o que prejudica uma previsão mais próxima do observada. A precipitação acumulada para o mês de dezembro de 2012, também é atípica para o período “fora do normal” o que dificulta inferir sobre a qualidade das previsões do modelo.

Na Figura 52, é possível analisar graficamente o desempenho dos modelos para o período de dezembro de 2012 a fevereiro de 2013. Onde podemos apreciar que para o mês de dezembro a precipitação acumulada é atípica (choveu muito acima da média esperada para o período), o que prejudica inferir sobre o desempenho dos modelos. Já para os demais meses os modelos se aproximaram de forma adequada., como pode ser visualizado na figura em tela.

Figura 52 – Desempenho dos modelos para SR2 (DJF)



Fonte: Autor.

Para testar se há significância estatística na diferença das previsões dos modelos propostos, foi aplicado o teste de Diebold e Mariano (1995).

Tabela 70 – Teste Diebold e Mariano (1995) (DJF)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	0	-	SARIMAX x HWM	1,70	*
SARIMA x HWM	-1,84	*	SARIMAX x Combinado	0	-
SARIMA x Combinado	0,85	-	SARIMAX x AES	0,22	-
SARIMA x AES	0,56	*	HWM x Combinado	0	-
Combinado x AES	0,50	-	HWM x AES	0,80	*

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%

Fonte: Autor.

O teste indica que há diferença significativa nas previsões entre os modelos HWM, SARIMAX, SARIMA e AES, com capacidade preditiva mais apurada para o modelo SARIMA e SARIMAX. Os resultados demonstram que praticamente quase todos os modelos tem a

mesma capacidade de previsão. A estação climática verão, região SR2, possui uma variabilidade climática, principalmente no mês de dezembro, que torna difícil ajustar os modelos de forma a produzir previsões que se aproximem do observado. As classificações categoriais das previsões não foram satisfatórias por se afastarem da série observada. A de considerar que o mês de Dez/2012, a precipitação foi atípica (choveu além do esperado).

4.2.4.17 Síntese dos principais resultados encontrados para SR2

De acordo com a Tabela 71, destaca-se o modelo SARIMA para o período sazonal (Set a Nov). Para o período (Mar a Maio), destaque para o modelo HWM não havendo diferença estatística nas previsões entre os modelos SARIMA, SARIMAX e Combinado. No verão destaque para o modelo SARIMAX não havendo diferença significativa nas previsões para o SARIMA e Combinado. Já para o inverno não se recomenda a utilização destes modelos devido as previsões não se aproximarem dos valores observados.

Tabela 71 – Desempenho dos modelos para SR2 de acordo com o critério MAPE

Modelo	MAPE(%) (Set a Nov)	MAPE(%) (Jun a Ago)	MAPE(%) (Mar a Maio)	MAPE(%) (Dez a Fev)
Holt-Winters	19,91%	49,66%	5,06%	24,11%
SARIMA	3,99%	48,3%	9,51%	19,25%
SARIMAX	11,56%	45,18%	10,08%	14,57%
COMBINADO	8,98%	46,33%	7,78%	18,9%

Fonte: Autor.

Na classificação categórica das previsões, Quadro 13, para a primavera destaque para o modelo SARIMA e SARIMAX. Para o período sazonal março a maio destaque para o HWM. Já para o verão o mês de dezembro teve chuvas atípicas para o período o que prejudicou as previsões. No inverno não houve destaque e não se recomenda a utilização dos modelos.

Quadro 13 – Classificação categóricas das previsões para SR2

Período	Observado	SARIMA	SARIMAX	HWM	Combinado
		Previsto	Previsto	Previsto	Previsto
Primavera					
Set/2013	Normal	Normal	Normal	Normal	Normal
Out/2013	Normal	Normal	Normal	Acima da Normal	Acima da Normal
Nov/2013	Normal	Normal	Normal	Normal	Normal
Inverno					
Jun/2013	Acima da Normal	Normal	Normal	Normal	Normal
Jul/2013	Abaixo da Normal	Normal	Normal	Normal	Normal
Ago/2013	Acima da Normal	Abaixo da Normal	Normal	Abaixo da Normal	Normal
Outuno					
Mar/2013	Abaixo da Normal	Abaixo da Normal	Abaixo da Normal	Abaixo da Normal	Abaixo da Normal
Abr/2013	Normal	Normal	Normal	Normal	Normal
Mai/2013	Abaixo da Normal	Normal	Normal	Abaixo da Normal	Normal
Verão					
Dez/2012	Acima da Normal	Normal	Normal	Normal	Normal
Jan/2013	Normal	Normal	Normal	Normal	Normal
Fev/2013	Acima da Normal	Normal	Normal	Normal	Normal

Fonte: Autor.

A próxima etapa do trabalho foi analisar a região Sul 3.

4.2.5 Análise da Sub-Região Sul 3 (SR3)

A série histórica que compõe a SR3 é obtida através da média das 21 séries históricas com maior similaridade, definidas pela análise de agrupamentos. As coordenadas que compõem a série estão descritas no Quadro 9 (Sub-regiões da região Sul com similaridades nas séries históricas de precipitação mensal).

Os valores quantílicos da região SR3, auxiliam a determinar e classificar a climatologia do local. O Quadro 14, demonstra os valores encontrados de acordo com metodologia proposta no item 2.6 e servem para comparações/classificação das previsões futuras nas categorias, muito seco, seco, normal, chuvoso e muito chuvoso.


Quadro 14 – Classificação climatológica SR3

Classificação	Classes de Precipitação	
Muito Seco	$X_i \leq 62,9$	
Seco	$62,9 < X_i \leq 92,39$	
Normal	$92,39 < X_i < 140,15$	
Chuvoso	$140,15 \leq X_i < 188,58$	
Muito Chuvoso	$X_i \geq 188,58$	
Sendo: X_i valores mensais observadas de precipitação acumulada mensal em milímetros.		

Fonte: Autor.

A Figura 53, busca auxiliar a categorização de toda a série em estudo SR3 e corroborar com o entendimento do Quadro 14. Esta região do país é conhecida por homogeneidade na precipitação, comportamento este que pode ser facilmente observado na sua ST e também na pouca diferença entre a sua média e mediana descrita na Tabela 72.

Figura 53 – Classificação climatológica SR3



Fonte: Autor.

Após a categorização da série histórica Quadro 14 e Figura 53, faz-se necessário verificar as principais medidas descritivas da precipitação mensal acumulada da região em estudo SR3.

Os valores das médias e desvios padrões das variáveis, coeficiente de variação e valor máximo e mínimo, da série SR3, estão expostos na Tabela 72. Verificou-se que a média aritmética é maior que a mediana, desta forma, temos uma distribuição assimétrica positiva a direita o que representa uma tendência a precipitação normal ou abaixo da normal.

O grau de concentração de valores, em torno de um valor médio, grandeza de afastamento, enaltece que a série em estudo é heterogênea o que indica que a média não é representativa. A distribuição é Platicúrtica, ou seja, os dados se concentram em menor número em torno da média que a distribuição normal.


Tabela 72 – Medidas descritivas da precipitação acumulada mensal da SR3, 1980 a 2013

Medida Descritiva	Resultado
Média	124,2
Mediana	113,6
Desvio Padrão	62,35
Coeficiente de variação	50,2%
Valor máximo	454,9
Valor mínimo	7,2
Curtose	1,7
Assimetria	0,840

Fonte: Autor.

Para dar início ao ajuste dos modelos, observa-se, na Figura 54, que a ST possui indícios de sazonalidade, não demonstrando de forma explícita a presença de tendências crescentes ou decrescentes. Entretanto, como a ST é extensa a inspeção gráfica pode apresentar distorções em sua avaliação.


Figura 54 – Série Original da precipitação acumulada mensal da SR3, 1980 a 2013



Fonte: Autor.

Na decomposição da ST, Figura 55, pode-se observar um comportamento definido ao longo do tempo e, portanto, pode ser ajustada num modelo de previsão de série temporal. Também há de se considerar a presença de sazonalidade. Como se pode verificar, esta ST apresenta média e variância não constantes, indícios de não estacionariedade na parte sazonal da ST.


Figura 55 – Decomposição da série temporal em componentes tendência, sazonalidade e aleatoriedade



Fonte: Autor.

Analisando a Figura 56, é possível observar uma maior incidência de precipitação para o mês de fevereiro, março, setembro e outubro, e menor incidência para os meses de janeiro, março, agosto e dezembro. As médias de precipitação dos demais meses praticamente são idênticas com uma variabilidade considerável dentro de cada mês.

Figura 56 – Média mensal de precipitação acumulada SR3



Fonte: Autor.

Após a etapa inicial de inspeção visual (análise gráfica) dos dados, foram realizados o teste estatístico de sequências (p -valor $> 0,05$), confirmando que série não possui indícios de tendência significativa ao nível de $\alpha = 5\%$, e os testes estatísticos para sazonalidade de Kruskal-Wallis e Friedman indicam a presença de sazonalidade ao nível de significância $\alpha = 5\%$. O resultado para o teste de Dickey-Fuller Aumentado (ADF), segundo Dickey e Fuller (1981) revela que a série em estudo é estacionária. Entretanto deve ser considerada a possibilidade de não estacionariedade da componente sazonal da ST.

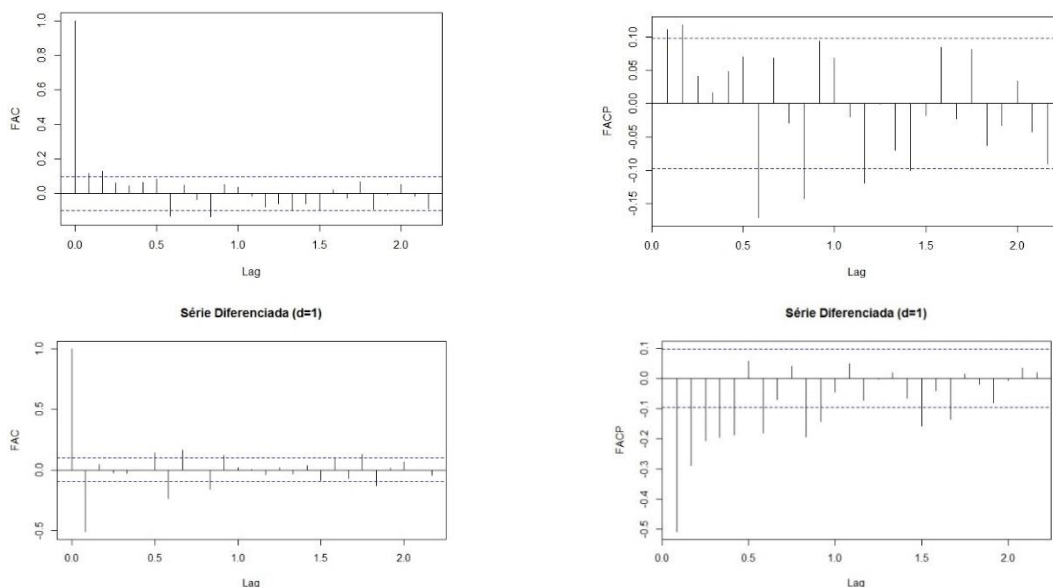
As previsões da SR3, foram realizadas de acordo com as estações climáticas (primavera, inverno, outono e verão) respectivamente.

4.2.6 Modelos de Séries Temporais para Sub-Região Sul 3

4.2.6.1 Modelo SARIMA (SON)

Iniciou-se o ajuste do modelo SARIMA através dos gráficos de FAC e FACP, Figura 57.

Figura 57 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP)



Fonte: Autor.

Observando os FAC e FACP em nível, percebe-se evidências de um modelo estacionário autorregressivo de ordem 1 a 3 e de médias móveis de ordem 1 a 2. Os testes estatísticos e a análise gráfica indicam que um modelo do tipo SARIMA. A sazonalidade não estacionária deve ser considerada tendo em vista que a média e variância não são constantes ao longo do tempo, sendo necessário aplicar diferenciações na parte sazonal. Na Tabela 73, estão expostos alguns modelos concorrentes ajustados para a série SR3, com os respectivos valores de AIC e BIC e os parâmetros do modelo.

Tabela 73 – Modelos concorrentes ARIMA e os respectivos critérios para a série SR3

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1451$ $\phi_2 = 0,1316$ $\Phi_1 = -0,0364$ $\theta_1 = -0,9581$	4380	4400
(1,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1671$ $\Phi_1 = -0,0401$ $\theta_1 = -0,9581$	4385	4401

(Continua)

Tabela 73 – Modelos concorrentes ARIMA e os respectivos critérios para a série SR3

SARIMA (p, d, q) (P, D, Q)	Parâmetros	(Conclusão) Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1452$ $\phi_2 = 0,1304$ $\theta_1 = -0,9529$	4379	4395

Fonte: Autor.

O modelo SARIMA com dois parâmetros autorregressivo (p) na parte ordinal, uma diferença (D) e um parâmetro de médias móveis (Q) na parte sazonal, atende a todas as condições de erros descorrelacionados, ruído branco e normalidade dos resíduos o que torna apto o modelo para realizar previsões futuras.

As previsões para SON do modelo SARIMA (2,0,0) (0,1,1)₁₂ podem ser observadas na Tabela 74. As previsões se aproximaram adequadamente para os meses de S e O, para o mês de N o modelo não conseguiu aproximar a previsão do observado.


Tabela 74 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1)₁₂, para região SR3 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	130,23 mm	125,09 mm	Normal	Normal
Out/2013	141,45 mm	142,88 mm	Acima da Normal	Acima da Normal
Nov/2013	119,67 mm	228,35 mm	Normal	Acima da Normal

Fonte: Autor.

Na Figura 58, percebe-se que o modelo não consegue captar os extremos de precipitação, tanto para períodos secos como chuvosos o que auxilia a entender a dificuldade da previsão para o mês de novembro.

Figura 58 – Modelo SARIMA ajustado à série observada SR3



Fonte: Autor.

A correlação entre série observada e ajustada a ser usada no modelo Combinado é de 0,31 significativa, p-valor < 0,011.

4.2.6.2 Modelo SARIMAX (SON)

Para o ajuste do modelo SARIMAX, utilizou-se a TSM como variável exógena.

Dentre os diversos modelos testados, na Tabela 75, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 75 – Modelos concorrentes SARIMAX e os respectivos critérios para SR3 (SON)

ARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,1007$	4366	4382
	$\phi_2 = 0,0863$		
	$\theta_1 = -0,9559$		
	TSM= 22,65		
(1,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,1096$	4367	4383
	$\theta_1 = -0,9559$		
	TSM= 23,47		

(Continua)

Tabela 76 – Modelos concorrentes SARIMAX e os respectivos critérios para SR3 (SON)

ARIMAX (p,q,r[])	Parâmetros	(Conclusão) Critérios de seleção	
		AIC	BIC
(2,0,0) (1,1,1) [1] ₁₂	$\phi_1 = 0,0968$	4367	4390
	$\phi_2 = 0,0805$		
	$\Phi_1 = -0,0701$		
	$\Theta_1 = -0,9559$		
	TSM= 9,6121		

Fonte: Autor.

Considerando os três melhores modelos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual. O modelo SARIMAX (2,0,0)(0,1,1) [1], atende a todas os pressupostos exigidos para realizar previsões futuras. As previsões e a classificação climatológica da série SR3 para um horizonte de 3 passos à frente podem ser observadas na Tabela 76.


Tabela 76 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂, para região SR3 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	113,43 mm	125,09 mm	Normal	Normal
Out/2013	126,05 mm	142,88 mm	Normal	Acima da Normal
Nov/2013	104,88 mm	228,35 mm	Normal	Acima da Normal

Fonte: Autor.

Na Figura 59, percebe-se uma dificuldade do modelo em captar valores extremos, como observado também no modelo SARIMA.

Figura 59 – Modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂ ajustado à série observada SR3



Fonte: Autor.

Encontrou-se uma correlação de 0,36 e significativa, p -valor $< 0,00072$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.2.6.3 Modelos de Alisamento Exponencial e de Holt-Winters (SON)

As características da série, de não se desenvolver em torno de um determinado nível com flutuações aleatórias, havendo evidências de efeitos sazonais, sugerem o ajuste de um modelo HWA ou HWM.

O modelo HWA, demonstrou melhor desempenho em relação ao HWM para o período em análise. Os resultados das previsões do modelo HWA para o período sazonal SON, estão na Tabela 77. Como os demais modelos já testados para o período o HWA, também possui dificuldades em se aproximar do valor observado para o período de N.


Tabela 77 – Classificação climatológica das previsões, segundo o modelo HW aditivo para região SR3 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	138,91 mm	125,09 mm	Normal	Normal
Out/2013	142,2 mm	142,88 mm	Acima da Normal	Acima da Normal
Nov/2013	110,88 mm	228,35 mm	Normal	Acima da Normal

Fonte: Autor.

A Figura 60, apresenta os valores observados e previstos, além do intervalo de previsão ($h=3$) do modelo Holt-Winters aditivo. Em relação aos modelos concorrentes o HWA consegue se aproximar dos valores extremos com maior facilidade.

Figura 60 – Holt-Winters aditivo ajustado à variável SR3



Fonte: Autor.

Para o ajuste do modelo combinado, encontrou-se uma correlação entre série ajustada e observada de 0,34 e significativa, p -valor $< 0,05$.

4.2.6.4 Modelos Combinados (SON)

Os valores previstos através da combinação das previsões para o período de setembro a novembro e a classificação climatológica do período, estão expostos na Tabela 78. Como o modelo combinado é um reflexo dos demais modelos utilizados, verifica-se a mesma dificuldade de previsão para o mês de novembro.

Tabela 78 – Classificação climatológica das previsões, segundo os modelos combinados, para região SR3 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Set/2013	126,5 mm	125,09 mm	Normal	Normal
Out/2013	135,9 mm	142,88 mm	Normal	Acima da Normal
Nov/2013	111,1 mm	228,35 mm	Normal	Acima da Normal

Fonte: Autor.

A previsão do modelo combinada se aproxima com a série observada, exceto para o mês de novembro de 2013, que obteve um índice pluviométrico muito acima do normal para o mês o referido mês em análise. Na Tabela 79, observa-se a comparação do desempenho dos modelos.

Tabela 79 – Comparação dos Modelos utilizando os critérios de seleção (SON)


Modelo	MAPE(%)	EQM	MAD	SSE
HW Aditivo	20,8%	4663	43,7	13818
SARIMA	17,5%	3946	38,4	11811
SARIMAX	25,06%	5227	50,6	15264
COMBINADO	19,1%	4605	41	13766

Fonte: Autor.

O modelo SARIMA obteve melhor desempenho em todos os critérios utilizados em relação a seus concorrentes, conforme exposto na Tabela 79.

Na Figura 61, fica evidente a dificuldade dos modelos em prever o mês de N, para os demais períodos S e O, as previsões categóricas são eficientes para todas as classes de modelos testadas.

Figura 61 – Desempenho dos modelos para SR3 (SON)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos modelos propostos, aplicou-se o teste de Diebold e Mariano.

Tabela 80 – Teste Diebold e Mariano (1995) (SON)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SAIMAX	0	-	SARIMAX x HWA	-1,4	-
SARIMA x HWA	-1,85	*	SARIMAX x Combinado	-1,2	-
SARIMA x Combinado	0,85	-	HWA x Combinado	1,6	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

Há diferença estatística entre o modelo SARIMA e o HWA com capacidade preditiva superior para o primeiro modelo.

4.2.6.5 Modelo SARIMA (JJA)

Para o período de inverno da SR3, iniciou-se a modelagem com o modelo SARIMA.

Na Tabela 81, estão expostos alguns modelos concorrentes ajustados para a série SR3, com os respectivos valores de AIC e BIC, os parâmetros do modelo.

Tabela 81 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR3 (JJA)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1443$	4348	4364
	$\phi_2 = 0,1328$		
	$\theta_1 = -0,9668$		
(1,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1663$	4353	4365
	$\theta_1 = -0,9581$		
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1448$	4350	4370
	$\phi_2 = 0,1320$		
	$\Phi_1 = -0,0353$		
	$\theta_1 = -0,958$		

Fonte: Autor.

O modelo SARIMA $(2,0,0)(0,1,1)_{12}$, atende a todos os pressupostos exigidos para realizar previsões futuras. Os resultados das previsões do modelo SARIMA estão na Tabela 82, assim como os respectivos valores da série observada correspondente a cada período e a classificação climatológica do período Prevista e Observada.


Tabela 82 – Classificação climatológica das previsões, segundo o modelo SARIMA $(2,0,0)(0,1,1)_{12}$ para região SR3 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	118 mm	73,5 mm	Normal	Abaixo da Normal
Jul/2013	122,2 mm	85,6 mm	Normal	Abaixo da Normal
Ago/2013	100,6 mm	112,6 mm	Normal	Normal

Fonte: Autor.

Na Figura 62, é demonstrada a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%.

Figura 62 – Modelo SARIMA $(2,0,0)(0,1,1)_{12}$ ajustado à série observada SR3



Fonte: Autor.

Encontrou-se uma correlação de 0,31 e significativa, p -valor $< 0,0002$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.6.6 Modelo SARIMAX (JJA)

Na Tabela 83, estão expostos os três modelos com melhor desempenho nos critérios de seleção AIC e BIC, a TSM foi utilizada como variável exógena.

Tabela 83 – Modelos concorrentes SARIMAX e os respectivos critérios para SR3 (JJA)

ARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,1009$ $\phi_2 = 0,0869$ $\theta_1 = -0,9548$ TSM = 22,62	4335	4351
(1,0,0) (0,1,1) [1] ₁₂	$\phi_1 = 0,1098$ $\theta_1 = -0,9578$ TSM = 27,46	4336	4352
(1,0,0) (1,1,1) [1] ₁₂	$\phi_1 = 0,0693$ $\Phi_1 = -0,0073$ $\theta_1 = -0,9601$ TSM = 27,59	4336	4356

Fonte: Autor.

O modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂, atende a todos os pressupostos exigidos para realizar previsões futuras. As previsões para um horizonte de 3 meses a frente, estão na Tabela 84.


Tabela 84 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂, para região SR3 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	104 mm	73,5 mm	Normal	Abaixo da Normal
Jul/2013	103 mm	85,6 mm	Normal	Abaixo da Normal
Ago/2013	80,5 mm	112,6 mm	Abaixo da Normal	Normal

Fonte: Autor.

Tanto na Tabela 84 como na Figura 63, verifica-se que o modelo não capta adequadamente valores extremos.

Figura 63 – Modelo SARIMAX (2,0,0) (0,1,1) [1]₁₂ ajustado à série observada



Fonte: Autor.

A correlação entre série observada e ajustada é de 0,312 significativa, p-valor $< 0,02^{-15}$. A mesma será utilizada para o ajuste do modelo combinado.

4.2.6.7 Alisamento Exponencial Simple e de Holt-Winters (JJA)

As características da série sugerem o modelo HWM. Os resultados das previsões do modelo HWM para o período sazonal de inverno do ano de 2013, estão na Tabela 85.


Tabela 85 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo para região SR3 (SON)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
HW multiplicativo				
Jun/2013	100 mm	73,5 mm	Normal	Abaixo da Normal
Jul/2013	109 mm	85,6 mm	Normal	Abaixo da Normal
Ago/2013	105,7 mm	112,6 mm	Normal	Normal

Fonte: Autor.

Na Figura 64, temos os valores observados e previstos, onde pode-se observar que o modelo HWM consegue ajustar-se de forma mais adequada a ST em relação aos seus concorrentes.

Figura 64 – Holt-Winters multiplicativo ajustado à variável SR3



Fonte: Autor.

Encontrou-se uma correlação de 0,323 e significativa, p-valor < 0,05, para o modelo HWM. Devida a correlação não significativa o modelo AES foi descartado.

4.2.6.8 Modelos Combinados (JJA)

A previsões da combinação dos modelos estão expostos na Tabela 86. As correlações utilizadas foram: SARIMA (0,31), SARIMX (0,312) e HWM (0,3223).

Tabela 86 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR3 (JJA)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Jun/2013	100 mm	73,5 mm	Normal	Abaixo da Normal
Jul/2013	109 mm	85,6 mm	Normal	Abaixo da Normal
Ago/2013	105,6 mm	112,6 mm	Normal	Normal

Fonte: Autor.

A previsão combinada, pontualmente, não obteve melhores resultados em relação aos modelos concorrentes, principalmente devido as previsões inadequadas do modelo SARIMA. Na Tabela 87, é possível analisar o desempenho dos modelos.


Tabela 87 – Comparação dos Modelos utilizando os critérios de seleção (JJA)

Modelo	MAPE(%)	EQM	MAD	SSE
SARIMA(2,0,0) (0,1,1) ₁₂	37%	1154	31	3463
SARIMAX(2,0,0) (0,1,1) [1] ₁₂	30%	754	26	2263
HW Multiplicativo	23%	432	18,9	1297
COMBINADO	30,5%	432	18,9	1297

Fonte: Autor.

A Tabela 87, demonstra que o modelo combinado e o HWM, possuem desempenho superior a seus concorrentes e similar. Na Figura 65, observa-se que os modelos superestimam as previsões para os meses de junho e julho. Para o mês de agosto as previsões se aproximam do esperado.

Figura 65 – Desempenho dos modelos para SR3 (JJA)



Fonte: Autor.

Para testar se há diferença estatística nas previsões dos diferentes modelos, foi aplicado o teste de Diebold e Mariano A Tabela 88, trás os resultados do teste.

Tabela 88 – Teste Diebold e Mariano (1995) (JJA)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x ARIMAX	0,62	-	SARIMAX x HWM	0,9	-
SARIMA x HWM	2,16	**	SARIMAX x Combinado	0,9	-
SARIMA x Combinado	2,10	**	SARIMAX x AES	-0,48	-
SARIMA x AES	0,86	-	HWM x Combinado	-1,0	-
Combinado x AES	-1,65	*	HWM x AES	-1,65	*

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

Os resultados do teste demonstram que há diferença significativa nas previsões entre os modelos SARIMA x HWM, com capacidade preditiva superior para o HWM, entre os modelos SARIMA e Combinado a capacidade preditiva superior para o modelo Combinado e entre os modelos Combinado e HWM x AES, com capacidade preditiva melhor dos dois primeiros. A estação climática inverno, região SR3, é prevista adequadamente pelos modelos HWM e Combinado. Não havendo diferença estatística entre os dois modelos.

4.2.6.9 Modelo SARIMA (MAM)

Para o período MAM, a Tabela 89, trás alguns modelos concorrentes ajustados a série SR3.

Tabela 89 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR3 (MAM)

SARIMA (p, d, q) (P, D, Q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1443$	4317	4333
	$\phi_2 = 0,1328$		
	$\theta_1 = -0,9722$		
(1,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1663$	4322	4335
	$\theta_1 = -0,962$		
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1448$	4319	4339
	$\phi_2 = 0,1320$		
	$\Phi_1 = -0,0541$		
	$\theta_1 = -0,9641$		

Fonte: Autor.

Considerando os três melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual. O modelo SARIMA (2,0,0) (0,1,1)₁₂ atende a todos os pressupostos para realizar previsões.

Os resultados das previsões para o período sazonal março, abril e maio de 2013, estão na Tabela 90. Onde pode-se observar o excelente desempenho das previsões categóricas.


Tabela 90 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1)₁₂, para região SR3 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	115 mm	100,3 mm	Normal	Normal
Abr/2013	147 mm	129mm	Normal	Normal
Mai/2013	124,1 mm	123,2 mm	Normal	Normal

Fonte: Autor.

Na Figura 66, é possível perceber que o modelo tem dificuldade em captar valores que se afastam da média.

Figura 66 – Modelo SARIMA (2,0,0) (0,1,1)₁₂ ajustado à série observada SR3



Fonte: Autor.

A correlação entre a série observada e ajustada é de 0,31 e significativa, p -valor $< 0,02^{-10}$. A mesma será usada para o ajuste do modelo combinado.

4.2.6.10 Modelo SARIMAX (MAM)

Na Tabela 91, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC. A TSM foi utilizada como variável exógena.

Tabela 91 – Modelos concorrentes SARIMAX e os respectivos critérios para SR3 (MAM)

SARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1])	$\phi_1 = 0,1009$	4305	4325
	$\phi_2 = 0,0869$		
	$\theta_1 = -0,9598$		
	TSM = 22,60		
(1,0,0) (0,1,1) [1])	$\phi_1 = 0,1098$	4306	4326
	$\theta_1 = -0,9625$		
	TSM = 23,42		
(1,0,0) (1,1,1) [1])	$\phi_1 = 0,1045$	4306	4325
	$\Phi_1 = -0,0773$		
	$\theta_1 = -0,9670$		
	TSM = 24,84		

Fonte: Autor.

O modelo SARIMAX (1,0,0)(0,1,1) [1]₁₂ atende a todas as condições para realizar previsões futuras. Supõe-se que a inclusão do parâmetro exógeno seja uma indicação da boa previsão apresentada por este modelo.

As previsões para o modelo ajustado SARIMAX (1,0,0)(0,1,1) [1]₁₂ podem ser observadas na Tabela 92, bem como seu excelente desempenho.


Tabela 92 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1]₁₂, para região SR3 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	112,8 mm	100,3 mm	Normal	Normal
Abr/2013	142 mm	129mm	Normal	Normal
Mai/2013	117,9 mm	123,2 mm	Normal	Normal

Fonte: Autor.

A Figura 67, expõem a série observada, ajustada e prevista. Apesar da boa qualidade das previsões, o modelo possui dificuldades de ajustar-se a valores que se afastam da média.

Figura 67 – Modelo SARIMAX (1,0, 0)(0,1,1) [1]₁₂ ajustado à série observada SR3



Fonte: Autor.

A correlação encontrada de 0,35 positiva e significativa, p -valor $< 0,06^{-13}$. A mesma será utilizada para o ajuste do modelo combinado.

4.2.6.11 Alisamento Exponencial Modelo Holt-Winters (MAM)

Devido ao comportamento explosivo da ST aplicou-se o modelo HWM. Também ajustou-se o modelo de AES para fins de comparação. Os resultados das previsões do modelo HWM e AES estão na Tabela 93.


Tabela 93 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR3 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
HW multiplicativo				
Mar/2013	95 mm	100,3 mm	Normal	Normal
Abr2013	109,9 mm	129 mm	Normal	Normal
Mai/2013	99,8 mm	123,2 mm	Normal	Normal
AES				
Mar/2013	124,3 mm	100,3 mm	Normal	Normal
Abr2013	124,3 mm	129 mm	Normal	Normal
Mai/2013	124,3 mm	123,2 mm	Normal	Normal

Fonte: Autor.

O ajuste do modelo é verificado na Figura 68.

Figura 68 – Holt-Winters multiplicativo ajustado à variável SR3



Fonte: Autor.

A correlação entre ST observada e ajustado é de 0,30, significativa, $p\text{-valor} < 0,02^{-16}$, para o modelo HWM e para o modelo AES uma correlação de -0,07 $p\text{-valor} = 0,1274$ não significativa. O modelo AES não foi usado para o modelo combinado devido a correlação não ser significativa.

4.2.6.12 Modelos Combinados (MAM)

Os valores previstos para o período de março a maio de 2013, através da agregação das previsões dos modelos propostos estão expostos na Tabela 94. As correlações utilizadas para os modelos SARIMA, SARIMAX e HWM, foram, respectivamente: 0,31, 0,35, 0,30.

Tabela 94 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR3 (MAM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Mar/2013	108,6 mm	100,3 mm	Normal	Normal
Abr/2013	134,8 mm	129 mm	Normal	Normal
Mai/2013	115,6 mm	123,2 mm	Normal	Normal

Fonte: Autor.

As previsões do modelo Combinado obtiveram os melhores resultados de previsão em relação aos modelos concorrentes. Na Tabela 95, é possível verificar a comparação do desempenho dos modelos.

Tabela 95 – Comparação dos Modelos utilizando os critérios de seleção (MAM)


Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	13%	300	15,9	940
SARIMA(2,0,0) (0,1,1) ₁₂	9,8%	180	11,2	540
SARIMAX(1,0,0) (0,1,1) [1] ₁₂	8,94%	117	10,2	353
COMBINADO	6,4%	56	7,4	170
AES	9,5%	199	9,9	599

Fonte: Autor.

A Tabela 95, expõem o ótimo desempenho dos modelos propostos para a previsão da precipitação acumulada para a estação climática do outono região SR3. O modelo Combinado obteve melhores resultado de previsão, entretanto todos os modelos testados ajustaram-se adequadamente.

Na Figura 69 é possível verificar a excelente acurácia dos modelos em prever o período sazonal em análise.

Figura 69 – Desempenho dos modelos para SR3 (MAM)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos diferentes modelos, aplicou-se o teste de Diebold e Mariano.

Tabela 96 – Teste Diebold e Mariano (1995) (MAM)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	1,24	-	SARIMAX x HWM	-1,04	-
SARIMA x HWM	-0,6	-	SARIMAX x Combinado	0,84	-
SARIMA x Combinado	1,2	-	SARIMAX x AES	-0,47	-
SARIMA x AES	-0,09	-	HWM x Combinado	1,84	*
Combinado x AES	-0,74	-	HWM x AES	0,33	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

De acordo com a Tabela 96, há diferença significativa nas previsões entre os modelos HWM e Combinado, com capacidade preditiva superior para o modelo Combinado. Os resultados deixam evidente que praticamente quase todos os modelos tem a mesma capacidade de previsão. A estação climática outono, região SR3, é prevista adequadamente pelos modelos em estudo conforme resultados expressos na Tabela 95 e Figura 69.

4.2.6.13 Modelo SARIMA (DJF)

Para estação de verão da SR3, o primeiro modelo a ser ajustado é o modelo SARIMA. Na Tabela 97, estão expostos os três melhores modelos concorrentes ajustados de acordo com os valores de AIC e BIC.

Tabela 97 – Modelos concorrentes SARIMA e os respectivos critérios para a série SR3 (DJF)

SARIMA (p, d, q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1526$	4284	4300
	$\phi_2 = 0,1250$		
	$\theta_1 = -0,9929$		
(1,0,0) (0,1,1) ₁₂	$\phi_1 = 0,1748$	4288	4300
	$\theta_1 = -0,9968$		
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1528$	4285	4305
	$\phi_2 = 0,244$		
	$\Phi_1 = -0,0365$		
	$\theta_1 = -0,99$		

Fonte: Autor.

Considerando os melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual. O modelo SARIMA com dois parâmetros autorregressivo (p) na parte ordinal, uma diferença e um parâmetro de médias móveis (Q) na parte sazonal, atende a todas as etapas da escolha do modelo para realizar previsões futuras.

Nessa etapa do trabalho, foram obtidas as previsões da série SR3 para um horizonte de 3 passos à frente, expostas na Tabela 98.


Tabela 98 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (0,1,1)₁₂, para região SR3 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	103,1 mm	216 mm	Normal	Acima da Normal
Jan/2013	108,2 mm	104,8 mm	Normal	Normal
Fev/2013	136,3 mm	146,8 mm	Normal	Acima da Normal

Fonte: Autor.

A Figura 70, reflete o ajuste do modelo em relação a ST observada.

Figura 70 – Modelo SARIMA (2,0,0) (0,1,1)₁₂ ajustado à série observada SR3



Fonte: Autor.

Encontrou-se uma correlação de 0,32, significativa, $p\text{-valor} < 0,2^{-10}$, entre a série observada e ajustada. A mesma será usada para o ajuste do modelo combinado.

4.2.6.14 Modelo SARIMAX (DJF)

A TSM foi utilizada como variável exógena para o ajuste do modelo SARIMAX.

Na Tabela 99, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 99 – Modelos concorrentes SARIMAX e os respectivos critérios SR3

SARIMAX (p,q,r[])	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (0,1,1) [1]	$\phi_1 = 0,1091$ $\phi_2 = 0,0792$ $\theta_1 = -0,9927$ TSM= 22,36	4272	4292
(1,0,0) (0,1,1) [1]	$\phi_1 = 0,1182$ $\theta_1 = -0,9875$ TSM= 23,14	4272	4288
(1,0,0) (1,1,2) [1]	$\phi_1 = 0,1128$ $\Phi_1 = -0,004$ $\theta_1 = -0,921$ $\theta_2 = -0,0789$ TSM= 24,39	4274	4298

Fonte: Autor.

O modelo SARIMAX (1,0,0)(0,1,1)[1]₁₂, atende a todas as condições de erros decorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo para realizar previsões futuras.

As previsões para o modelo ajustado SARIMAX (1,0,0)(0,1,2)[1]₁₂ podem ser observadas na Tabela 100. O mês de dezembro choveu muito além do esperado para o período o que dificulta o modelo de captar essa variação específica.


Tabela 100 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [1]₁₂, para região SR3 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	106,2 mm	216 mm	Normal	Acima da Normal
Jan/2013	126 mm	104,8 mm	Normal	Normal
Fev/2013	143,4 mm	146,8 mm	Acima da Normal	Acima da Normal

Fonte: Autor.

A Figura 71, demonstra que o modelo ajustado não consegue se aproximar de valores atípicos a série, como os pontos extremos. Más no geral há um desempenho positivo do modelo.

Figura 71 – Modelo SARIMAX (1,0,0) (0,1,1) [1]₁₂ ajustado à série observada SR3



Fonte: Autor.

A correlação encontrada é de 0,36 significativa, p-valor $0,04^{-13}$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.2.6.15 Alisamento Exponencial Modelo Holt-Winters (DJF)

Para o modelo de suavização exponencial simples, foi encontrado $\alpha = 0,0001$. O pequeno valor do coeficiente determina que as variáveis mais recentes possuem um peso menor do que as passadas para a estimação do modelo. No ajuste do modelo HWM foram: $\alpha = 0,035$ (constante de suavização do nível); $\beta = 0,017$ (constante de suavização da tendência) e $\gamma = 0,171$ (constante de suavização da sazonalidade).

Os resultados das previsões do modelo HWM e AES para o período sazonal de inverno, estão na Tabela 101.


Tabela 101 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SR3 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
HW multiplicativo				
Dez/2012	91 mm	216 mm	Normal	Acima da Normal
Jan/2013	97 mm	104,8 mm	Normal	Normal
Fev/2013	121,6 mm	146,8 mm	Normal	Acima da Normal
AES				
Dez/2012	153,14 mm	216 mm	Acima da Normal	Acima da Normal
Jan013	153,14 mm	104,8 mm	Acima da Normal	Normal
mar/2013	153,14 mm	146,8 mm	Acima da Normal	Acima da Normal

Fonte: Autor.

A Figura 72 e a Tabela 101, demonstram a dificuldade de ajuste principalmente devido a variabilidade contida nos valores observados no período de verão.

Figura 72 – Holt-Winters multiplicativo ajustado à variável SR3



Fonte: Autor.

O modelo AES não foi usado para o modelo combinado devido a correlação não ser significativa entre a série observada e ajustada. Para o HWM a correlação é de 0,33 p-valor < $0,05^{-10}$, entre a série observada e ajustada

4.2.6.16 Modelos Combinados (DJF)

As correlações utilizadas para a combinação das previsões foram: SARIMA (0,32), SARIMAX (0,36) e HWM (0,33). Os valores finais previstos para a precipitação trimestral acumulada período de dezembro de 2012 a fevereiro de 2013, estão expostos na Tabela 102.

Tabela 102 – Classificação climatológica das previsões, segundo o modelo combinado, para região SR3 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Dez/2012	101 mm	216 mm	Normal	Acima da Normal
Jan/2013	112 mm	104,8 mm	Normal	Normal
Fev/2013	136 mm	146,8 mm	Normal	Acima da Normal

Fonte: Autor.

As previsões dos modelos foram prejudicadas pelo grande acúmulo de precipitação no mês de dezembro de 2012, mês esse que choveu bem Acima da Normal e foi atípico para o período observado. O modelo Combinado é um reflexo do ajuste dos demais modelos, como os mesmos apresentarem dificuldades de ajuste e previsão a agregação dos resultados também foi prejudicada. A Tabela 103, expõem uma comparação do desempenho dos modelos.

Tabela 103 – Comparação dos Modelos utilizando os critérios de seleção (DJF)

Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	27,4%	5440	52	16320
SARIMA(2,0,0) (0,1,1) ₁₂	20,8%	4289	42	12688
SARIMAX(2,0,0) (0,1,1) [1] ₁₂	24,4%	4172	44,8	12517
COMBINADO	22,9%	4465	44,8	13396
AES	26,5%	2109	39,2	6328


Fonte: Autor.

A Tabela 103, externa o desempenho dos modelos propostos para a previsão da precipitação acumulada para a estação climática do verão região SR3. O modelo SARIMA

obteve o melhor ajuste em relação aos seus concorrentes tanto na classificação climatológica quanto na avaliação pontual. Entretanto, a de se levar em consideração que o mês de dezembro possui uma variabilidade climática considerável em toda a ST. Em específico o mês de dezembro de 2012, choveu bem acima da normal e foi atípico para o período observado o que prejudica uma previsão próximo do observado.

Na Figura 73 é possível visualizar o desempenho dos modelos para o período sazonal de dezembro de 2012 a fevereiro de 2013, no geral, os modelos superestimaram a previsão de verão.

Figura 73 – Desempenhos dos modelos para SR3 (Dez a Jan)



Fonte: Autor.

A Tabela 104, expressa os resultados do teste Deibold e Mariano.

Tabela 104 – Teste Diebold e Mariano (1995) (DJF)

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	1,14	-	SARIMAX x HWM	-1,40	-
SARIMA x HWM	-1,83	*	SARIMAX x Combinado	-1,21	-
SARIMA x Combinado	0,86	-	SARIMAX x AES	0,13	-
SARIMA x AES	0,56	-	HWM x Combinado	1,65	*
Combinado x AES	0,56	-	HWM x AES	0,80	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
 Fonte: Autor.

Observando a Tabela 104, há diferença significativa nas previsões entre os modelos HWM, SARIMAX, SARIMA e Combinado, com capacidade preditiva melhor para o modelo SARIMA e SARIMAX e Combinado. Os resultados comprovam que praticamente todos os modelos tem a mesma capacidade preditiva. A estação climática verão, região SR3, possui uma variabilidade na precipitação que torna difícil ajustar os modelos de forma a produzir previsões que se aproximem do observado. As classificações categorias das previsões não foram satisfatórias por se afastarem da série real.

4.2.6.17 Síntese dos principais resultados encontrados para SR3

A Tabela 105 demonstra o resultados das previsões pontuas onde é possível verificar que o modelo SARIMA possui melhor desempenho para os períodos sazonais de (Set a Nov) e (Dez a Fev). Para o período de inverno o modelo HWM obteve melhor desempenho e para o autono o modelo Combinado.

Tabela 105 – Desempenho dos modelos para SR3 de acordo com o critério MAPE

Modelo	MAPE(%) (Set a Nov)	MAPE(%) (Jun a Ago)	MAPE(%) Mar a Maio	MAPE(%) (Dez a Fev)
Holt-Winters	20,8%	23%	13%	27,4%
SARIMA	17,5%	37%	9,8%	20,8%
SARIMAX	25,06%	30%	8,9%	24,4%
COMBINADO	19,1%	30,5%	6,4%	22,9%

Fonte: Autor.

Nas previsões categóricas, Quadro 15, o modelo SARIMA e HWM demonstraram melhor desempenho para a primavera. No inverno o mês de agosto é representado pelos modelos os demais meses não são captados pelos modelos. No outono todos os modelos prevêem adequadamente as categorias e para o verão o modelo SARIMAX obteve melhor desempenho.

Quadro 15 – Classificação categóricas das previsões para SR3

Período	Observado	SARIMA	SARIMAX	HWM	Combinado
		Previsto	Previsto	Previsto	Previsto
Primavera					
Set/2013	Normal	Normal	Normal	Normal	Normal
Out/2013	Acima da Normal	Acima da Normal	Normal	Acima da Normal	Normal
Nov/2013	Acima da Normal	Normal	Normal	Normal	Normal
Inverno					
Jun/2013	Abaixo da Normal	Normal	Normal	Normal	Normal
Jul/2013	Abaixo da Normal	Normal	Normal	Normal	Normal
Ago/2013	Normal	Normal	Abaixo da Normal	Normal	Normal
Outono					
Mar/2013	Normal	Normal	Normal	Normal	Normal
Abr/2013	Normal	Normal	Normal	Normal	Normal
Mai/2013	Normal	Normal	Normal	Normal	Normal
Verão					
Dez/2012	Acima da Normal	Normal	Normal	Normal	Normal
Jan/2013	Normal	Normal	Normal	Normal	Normal
Fev/2013	Acima da Normal	Normal	Acima da Normal	Normal	Normal

Fonte: Autor.

A próxima etapa do trabalho foi analisar partes da região Sudeste/Centro Oeste.

4.3 SUB-REGIÕES SUDESTE/CENTRO OESTE COM CARACTERÍSTICAS SIMILARES DE PRECIPITAÇÃO

A segunda região a ser analisada foi partes da região Sudeste/Centro Oeste que está compreendida na faixa de latitude (20,625° a 23,625°) e longitude (42,625° a 54,625°), num total de 50 séries históricas completas observadas no período de 1980 a 2013.

Para melhor visualização gráfica as séries de dados foram renomeadas de acordo com o Quadro 16.

Quadro 16 – Nomenclatura das séries de dados da região Sudeste/Centro Oeste do Brasil


Série	Lat, e Long,	Série	Lat, e Long,	Série	Lat, e Long,
B1	20,62S e 42,62W	B18	21,62S e 45,62W	B35	22,62S e 49,62W
B2	20,62S e 43,62W	B19	21,62S e 46,62W	B36	22,62S e 50,62W
B3	20,62S e 44,62W	B20	21,62S e 47,62W	B37	22,62S e 51,62W
B4	20,62S e 45,62W	B21	21,62S e 48,62W	B38	22,62S e 52,62W
B5	20,62S e 46,62W	B22	21,62S e 49,62W	B39	22,62S e 53,62W
B6	20,62S e 47,62W	B23	21,62S e 50,62W	B40	22,62S e 54,62W
B7	20,62S e 48,62W	B24	21,62S e 51,62W	B41	23,62S e 45,62W
B8	20,62S e 49,62W	B25	21,62S e 52,62W	B42	23,62S e 46,62W
B9	20,62S e 50,62W	B26	21,62S e 53,62W	B43	23,62S e 47,62W
B10	20,62S e 51,62W	B27	21,62S e 54,62W	B44	23,62S e 48,62W
B11	20,62S e 52,62W	B28	22,62S e 42,62W	B45	23,62S e 49,62W
B12	20,62S e 53,62W	B29	22,62S e 43,62W	B46	23,62S e 50,62W
B13	20,62S e 54,62W	B30	22,62S e 44,62W	B47	23,62S e 51,62W
B14	21,62S e 41,62W	B31	22,62S e 45,62W	B48	23,62S e 52,62W
B15	21,62S e 42,62W	B32	22,62S e 46,62W	B49	23,62S e 53,62W
B16	21,62S e 43,62W	B33	22,62S e 47,62W	B50	23,62S e 54,62W
B17	21,62S e 44,62W	B34	22,62S e 48,62W		

Fonte: Autor.

Com a finalidade de agrupar séries históricas com comportamentos similares de precipitação e definir sub-regiões dentro da região em estudo, realizou-se, então, a Análise de Agrupamentos. Como processo de aglomeração hierárquica utilizou-se o método de ligação completo, sendo a métrica de similaridade a distância Euclidiana.

Na Figura 74, observa-se o comportamento do dendrograma com todas as variáveis (ST), na qual se pode identificar a formação de dois grupos bem definidos, os quais possuem as variáveis de maior relevância dentro do conjunto em estudo.

Figura 74 – Dendrograma das séries históricas na região Sudeste/Centro Oeste



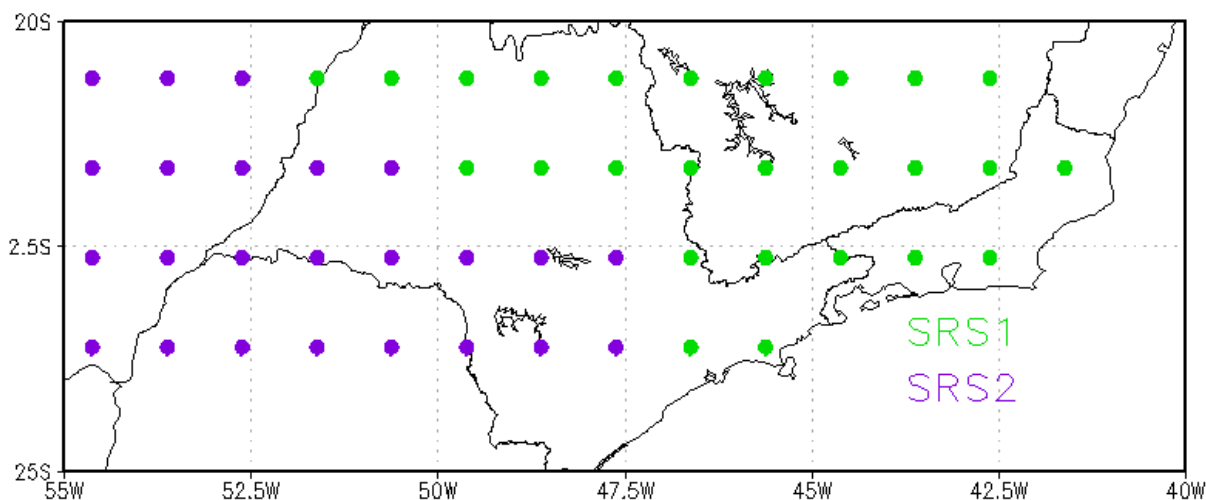
Realizou-se um corte gráfico vertical (“linha de Fenon”) na altura 2100, onde é possível verificar o maior salto entre os grupos. A técnica de corte gráfico é descrita detalhadamente em Vicini et al. (2018). O corte gráfico (linha pontilhada vermelha) definiu dois grupos que são heterogêneos entre si. O grupo 1 com 26 séries de dados e o grupo 2 com 24 séries de dados. O Quadro 17 expõem os grupos formados com homogeneidade dentro dos grupos e maior heterogeneidade entre os grupos.

Quadro 17 – Sub-regiões da região Sudeste/Centro Oeste com Similaridades nas séries históricas de precipitação acumulada mensal

Cluster 1 (Sub-região 1)		Cluster 2 (Sub-região 2)	
Série	Lat, e Long,	Série	Lat, e Long,
B1	-20,625_-42,625	B11	-20,625_-52,625
B2	-20,625_-43,625	B12	-20,625_-53,625
B3	-20,625_-44,625	B13	-20,625_-54,625
B4	-20,625_-45,625	B23	-21,625_-50,625
B5	-20,625_-46,625	B24	-21,625_-51,625
B6	-20,625_-47,625	B25	-21,625_-52,625
B7	-20,625_-48,625	B26	-21,625_-53,625
B8	-20,625_-49,625	B27	-21,625_-54,625
B9	-20,625_-50,625	B33	-22,625_-47,625
B10	-20,625_-51,625	B34	-22,625_-48,625
B14	-21,625_-41,625	B35	-22,625_-49,625
B15	-21,625_-42,625	B36	-22,625_-50,625
B16	-21,625_-43,625	B37	-22,625_-51,625
B17	-21,625_-44,625	B38	-22,625_-52,625
B18	-21,625_-45,625	B39	-22,625_-53,625
B19	-21,625_-46,625	B40	-22,625_-54,625
B20	-21,625_-47,625	B43	-23,625_-47,625
B21	-21,625_-48,625	B44	-23,625_-48,625
B22	-21,625_-49,625	B45	-23,625_-49,625
B28	-22,625_-42,625	B46	-23,625_-50,625
B29	-22,625_-43,625	B47	-23,625_-51,625
B30	-22,625_-44,625	B48	-23,625_-52,625
B31	-22,625_-45,625	B49	-23,625_-53,625
B32	-22,625_-46,625	B50	-23,625_-54,625
B41	-23,625_-45,625	-	-
B42	-23,625_-46,625	-	-

A Figura 75, facilita a visualização da distribuição da precipitação acumulada mensal das partes estudadas das regiões Sudeste/Centro-Oeste.

Figura 75 – Sub-regiões da região Sudeste/Centro Oeste com similaridades nas séries históricas de precipitação acumulada mensal



Fonte: Autor.

Observa-se duas sub-regiões bem definidas dentro da região em estudo, com as similaridades de precipitação acumulada mensal. A Sub-Região Sudeste 1 (SRS1), representa a grupo 1, e a Sub-Região Sudeste 2 (SRS2), representa a grupo 2.

4.4 CORRELAÇÃO ENTRE AS SUB-REGIÕES SRS1 E SRS2 COM A TSM

Só serão consideradas as correlações de Pearson significativas (p -valor $< 0,05$) e as maiores correlações (r). As séries de precipitação de cada sub-região, foram comparadas com a TSM até seis defasagens. As ST que não atingiram o índice pretendido foram excluídas.

A Tabela 106, expõem as correlações (r) de acordo com suas respectivas coordenadas para a região SRS1 com defasagens que variam de 0 até 6 meses.

As ST de precipitação acumulada mensal com defasagens (0, 1, 4, 5, e 6) são em sua grande maioria fortemente correlacionadas com as séries TSM. Para poder rodar os modelos de previsão de ST para a precipitação, devido a grande quantidade de dados (deficiência computacional), optou-se por adotar somente as doze séries com maior correlação positiva e significativa de cada defasagem.

Tabela 106 – Correlações entre a região SRS1 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

(Continua)

Defasagem 0									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
20S	15S	140E	145E	0,768	30S	25S	15E	20E	0,732
20S	15S	145E	150E	0,753	25S	20S	155E	160E	0,725
25S	20S	150E	155E	0,735	25S	20S	145E	150E	0,754
20S	15S	150E	155E	0,725	15S	10S	135E	140E	0,747
20S	15S	135E	140E	0,768	15S	10S	130E	135E	0,725
15S	10S	140E	145E	0,750	25S	20S	40E	45E	0,713
Defasagem 1									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
50S	45S	65W	60W	0,860	35S	30S	15E	20E	0,847
35S	30S	20E	25E	0,856	30S	25S	30E	35E	0,842
45S	40S	75W	70W	0,850	45S	40S	60W	55W	0,857
55S	50S	55W	50W	0,843	50S	45S	70W	65W	0,851
45S	40S	65W	60W	0,857	30S	25S	35E	40E	0,844
50S	45S	60W	55W	0,852	55S	50S	60W	55W	0,840
Defasagem 2									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
40S	35S	35W	30W	0,862	45S	40S	35W	30E	0,857
40S	35S	30W	25W	0,859	55S	50S	65E	70E	0,855
55S	50S	60E	65E	0,857	60S	55S	55E	60E	0,860
55S	50S	70E	75E	0,856	55S	50S	75E	80E	0,858
60S	55S	40E	45E	0,860	40S	35S	40W	35W	0,856
60S	55S	50E	55E	0,858	60S	55S	45E	50E	0,860

Tabela 106 – Correlações entre a região SRS1 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

(Continuação)

Defasagem 3									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
15S	10S	15W	10W	0,841	15S	10S	5W	0E	0,820
10S	5S	20W	15W	0,830	10S	5S	5W	0E	0,810
15S	10S	100W	95W	0,824	15S	10S	95W	90W	0,836
15S	10S	90W	85W	0,816	15S	10S	20W	15W	0,825
15S	10S	10W	5W	0,837	10S	5S	25W	20W	0,818
10S	5S	10W	5W	0,830	20S	15S	10W	5W	0,806
Defasagem 4									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
5N	10N	105W	100W	0,736	5N	10N	90E	95E	0,707
5N	10N	110W	105W	0,725	15S	10S	105W	100W	0,700
0N	5N	85E	90E	0,709	10S	5S	25W	20W	0,725
10S	5S	30W	25W	0,700	10S	5S	20W	15W	0,717
5N	10N	100W	95W	0,731	15S	10S	100W	95W	0,704
0N	5N	90E	95E	0,724	5N	10N	115W	110W	0,694
Defasagem 5									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
10N	15N	100W	95W	0,720	10N	15N	80E	85E	0,677
5N	10N	95E	100E	0,694	5N	10N	95W	90W	0,669
10N	15N	100E	105E	0,681	5N	10N	100W	95W	0,705
5N	10N	115W	110W	0,669	5N	10N	100E	105E	0,684
5N	10N	105W	100W	0,706	10N	15N	95W	90W	0,674
5N	10N	110W	105W	0,685	15N	20N	80E	85E	0,665

Tabela 106 – Correlações entre a região SRS1 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

(Conclusão)

Defasagem 6									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
45N	50N	45E	50E	0,787	40N	45N	45E	50E	0,764
10N	15N	45E	50E	0,777	30N	35N	90W	85W	0,759
30N	35N	95W	90W	0,767	45N	50N	35E	40E	0,778
25N	30N	60E	65E	0,763	15N	20N	110E	115E	0,773
50N	55N	125W	120W	0,784	15N	20N	115E	120E	0,763
20N	25N	115E	120E	0,773	20N	25N	110E	115E	0,759

Fonte: Autor.

A SRS2, está em menor grau correlacionada com as séries de precipitação acumulada mensal se comparada a SRS1. Mesmo assim, na grande maioria, as séries de precipitação acumulada com defasagens (0, 1, 4, 5, e 6) possuem correlação moderada ou forte com a TSM

Na Tabela 107, pode-se verificar as correlações (r) de acordo com suas respectivas coordenadas para a SRS2 e defasagens que variam de 0 até 6 meses.

Tabela 107 – Correlações entre a região SRS2 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

(Continua)

Defasagem 0									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
20S	15S	135E	140E	0,628	30S	25S	15E	20E	0,599
15S	10S	140E	145E	0,611	20S	15S	150E	155E	0,589
25S	20S	150E	155E	0,602	25S	20S	145E	150E	0,617
15S	10S	130E	135E	0,592	15S	10S	135E	140E	0,610
20S	15S	140E	145E	0,627	35S	30S	15E	20E	0,593
20S	15S	145E	150E	0,610	25S	20S	40E	45E	0,586

Tabela 107 – Correlações entre a região SRS2 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

(Continuação)

Defasagem 1									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
25S	20S	70W	65W	0,681	30S	25S	30E	35E	0,674
25S	20S	40E	45E	0,678	25S	20S	150E	155E	0,671
30S	25S	155E	160E	0,676	25S	20S	35E	40E	0,678
35S	30S	15E	20E	0,671	35S	30S	155E	160E	0,677
35S	30S	20E	25E	0,679	25S	20S	155E	160E	0,674
30S	25S	150E	155E	0,677	30S	25S	35E	40E	0,675
Defasagem 2									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
55S	50S	50E	55E	0,692	60S	55S	30E	35E	0,688
55S	50S	45E	50E	0,689	60S	55S	25E	30E	0,686
60S	55S	45E	50E	0,688	55S	50S	60E	65E	0,689
60S	55S	50E	55E	0,687	55S	50S	40E	45E	0,688
55S	50S	55E	60E	0,692	60S	55S	55E	60E	0,687
60S	55S	40E	45E	0,689	55S	50S	65E	70E	0,686
Defasagem 3									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
15S	10S	95W	90W	0,677	15S	10S	20W	15W	0,640
15S	10S	105W	100W	0,652	20S	15S	90W	85W	0,636
10S	5S	20W	15W	0,643	15S	10S	90W	85W	0,657
10S	5S	10W	5W	0,638	15S	10S	10W	5W	0,647
15S	10S	100W	95W	0,667	10S	5S	25W	20W	0,639
15S	10S	15W	10W	0,652	15S	10S	110W	105W	0,634

Tabela 107 – Correlações entre a região SRS2 e as respectivas coordenadas de TSM (1ª coluna representa a latitude inicial e a 2ª a final, a 3ª a longitude inicial e a 4ª a final) de acordo com as defasagens

(Conclusão)

Defasagem 4									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
5N	10N	105W	100W	0,604	5N	10N	95E	100E	0,565
0N	5N	95E	100E	0,594	15S	10S	105W	100W	0,559
5N	10N	95W	90W	0,566	5N	10N	100W	95W	0,602
15S	10S	100W	95W	0,561	5N	10N	115W	110W	0,568
0N	5N	90E	95E	0,602	0N	5N	85E	90E	0,561
5N	10N	110W	105W	0,592	10S	5S	125W	120W	0,558
Defasagem 5									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
5N	10N	100E	105E	0,578	5N	10N	105W	100W	0,563
10N	15N	100E	105E	0,570	0N	5N	100E	105E	0,552
15N	20N	80E	85E	0,564	10N	15N	100W	95W	0,571
10N	15N	95W	90W	0,552	5N	10N	100W	95W	0,564
5N	10N	95E	100E	0,577	5N	10N	95W	90W	0,555
10N	15N	80E	85E	0,565	10N	15N	105E	110E	0,552
Defasagem 6									
Coordenadas				r	Coordenada				r
Lat	Lat	Lon	Lon		Lat	Lat	Lon	Lon	
15N	20N	110E	115E	0,645	20N	25N	110E	115E	0,628
50N	55N	125W	120W	0,637	25N	30N	60E	65E	0,622
45N	50N	45E	50E	0,632	20N	25N	115E	120E	0,641
45N	50N	35E	40E	0,626	20N	25N	120E	125E	0,633
15N	20N	115E	120E	0,642	15N	20N	105E	110E	0,627
15N	20N	120E	125E	0,635	10N	15N	105E	110E	0,620

Fonte: Autor.

A precipitação acumulada mensal das SRS1 e SRS2, estão fortemente correlacionadas com TSM. Sendo um índice de influência da TSM na precipitação das sub-regiões, de acordo com os resultados expressos nas Tabela 106 e Tabela 107.

4.4.1 Análise da Sub-Região Sudeste/Centro Oeste 1 (SRS1)

A série histórica que compõe a SRS1 é obtida através da média das 26 séries históricas com maiores similaridades, definidas pela análise de agrupamentos da seção anterior. As coordenadas que compõe a série estão descritas no Quadro 17 (Sub-regiões da região Sudeste/Centro Oeste com similaridades nas séries históricas de precipitação acumulada mensal).

Os valores quantílicos da SRS1 período verão, auxiliam a determinar e classificar a climatologia do local. De acordo com características do clima da região em estudo, de haver duas estações bem definidas ao longo do ano, verão chuvoso e inverno seco. O Quadro 18, demonstra a classificação climatológica para o período de verão (Nov, Dez, Jan, Fev, Mar), meses que serão efetuadas as previsões. Os meses de inverno (Abr, Maio, Jun, Jul, Ago, Set, Out) foram excluídos da série histórica para fins de obtenção da distribuição quantílica do período de verão.

Para encontrar os valores do Quadro 18, utilizou-se a metodologia proposta no item 2.6 e servem para comparações/classificação das previsões futuras nas categorias, muito seco, seco, normal, chuvoso e muito chuvoso.


Quadro 18 – Classificação climatológica SRS1, período de verão

Classificação	Classes de Precipitação	
Muito Seco	$X_i \leq 137,4$	Abaixo da Normal
Seco	$137,4 < X_i \leq 181,3$	
Normal	$181,3 < X_i < 233,7$	Normal
Chuvoso	$233,7 \leq X_i < 291,6$	Acima da Normal
Muito Chuvoso	$X_i \geq 291,6$	
Sendo: X_i valores mensais Observadas de precipitação acumulada.		

Fonte: Autor.

A Figura 76, busca auxiliar na visualização da categorização de toda a série em estudo SRS1 período do verão e corroborar com o entendimento do Quadro 18.

Figura 76 – Classificação climatológica SRS1 período de verão



Fonte: Autor.

Após a categorização da série histórica período verão meses de novembro a março Quadro 18 e Figura 76, faz-se necessário verificar as principais medidas descritivas da precipitação mensal acumulada da região em estudo SRS1.

Os valores das médias e desvios padrões das variáveis, coeficiente de variação e valor máximo e mínimo, utilizados neste estudo, estão expostos na Tabela 108. A média aritmética é maior que a mediana, desta forma, temos uma distribuição assimétrica positiva a direita quando os valores se concentram na extremidade inferior da escala e se distribuem gradativamente em direção à extremidade superior, em suma, o terceiro quartil se afasta da mediana, enquanto que o primeiro quartil se aproxima da mesma, ou seja, tendência de precipitação normal ou abaixo da normal. O grau de concentração de valores, em torno de um valor médio, grandeza de afastamento enaltece que a série em estudo é heterogênea. O grau de achatamento da distribuição, em relação a distribuição normal, a curtose evidencia que a distribuição é mais achatada que a distribuição normal. A assimetria positiva indica uma cauda mais longa a direita, média maior que a mediana.


Tabela 108 – Medidas descritivas da precipitação acumulada mensal da SRS1, 1980 a 2013

Medida Descritiva	Resultado
Média	213,5
Mediana	204,9
Desvio Padrão	71,7
Coefficiente de variação	33,6%
Valor máximo	451,8
Valor mínimo	62,8
Curtose	0,36
Assimetria	0,54

Fonte: Autor.

Inicialmente, pode-se observar, na Figura 77, que a série possui indícios de sazonalidade e ou ciclos, não demonstrando de forma explícita a presença de tendências crescentes ou decrescentes. Entretanto, como a série é extensa (precipitação acumulada mensal de 1980 a 2013) a inspeção gráfica propicia o levantamento de hipótese, mas pode apresentar distorções em sua avaliação. Desta forma, se faz necessário aplicar testes estatísticos para verificar as condições de estacionariedade e sazonalidade.


Figura 77 – Série Original da precipitação acumulada mensal da SRS1, 1980 a 2013



Fonte: Autor.

Na Figura 78, observa-se que a série tem um comportamento definido ao longo do tempo e, portanto, pode ser ajustada num modelo de previsão de série temporal. Também há de se considerar a presença de sazonalidade.

Figura 78 – Decomposição da série temporal SRS1 em componentes tendência, sazonalidade e aleatoriedade




Fonte: Autor.

O gráfico das médias mensais, Figura 79, contribui com a hipótese visual de presença sazonal na ST. O gráfico evidencia maior incidência de precipitação para os meses de verão: novembro, dezembro, janeiro, fevereiro e março. Os menores acúmulos de precipitação para os meses de inverno: abril, maio, junho julho, agosto, setembro e outubro. Com menores índices de precipitação acumulada para os meses de junho, julho e agosto. Já os maiores acúmulos de precipitação concentram-se nos meses de dezembro e janeiro.

Foi possível também verificar que a ST possui indícios de não estacionariedade na parte sazonal, ou seja, a média e variância não são constantes ao longo do tempo.

Figura 79 – Médias mensais de precipitação acumulada SRS1



Fonte: Autor.

Após a etapa inicial de análise descritiva e gráfica, foram realizados testes estatísticos para confirmar as hipóteses levantadas de estacionariedade e sazonalidade.

Para testar a presença ou não de estacionariedade foi utilizado o teste Dickey-Fuller, com as seguintes hipóteses do teste: $H_0 = \phi_1 = 1$: série não estacionária e $H_1 = \phi_1 < 1$: a série é estacionária. Para o nível de significância $\alpha = 5\%$, encontrou-se as seguintes estatísticas de teste, $\hat{\tau} = -16,2$ (valor calculado) e $\tau = -2,88$ (valor tabelado), $p\text{-valor} = 0,01$. Rejeita-se da hipótese nula H_0 (não estacionária), se $\hat{\tau} < \tau$, aceitando a hipótese alternativa H_1 de estacionariedade dos dados.

Para avaliar a sazonalidade foi realizado o teste Kruskal-Wallis, sendo considerado as hipóteses: H_0 : não existe sazonalidade; e H_1 : existe sazonalidade. Como resultado do teste foi encontrado um $p\text{-valor} < 2,2^{-16}$, rejeitando-se a hipótese nula H_0 (e aceita a hipótese alternativa H_1 de presença de efeito sazonal na série, ao nível de significância $\alpha = 5\%$. Como observada na Figura 79, a ST apresenta indícios de não estacionariedade na parte sazonal, sendo necessários aplicar diferenciações a fins de estabilizar a sazonalidade.

Para dar início a modelagem de ajuste e previsão de séries temporais foram reservados os cinco últimos meses do ano de 2012 e 2013 para fins de comparação das previsões. Os valores reservados foram: novembro de 2012 com precipitação acumulada 173,9 mm (precipitação abaixo da normal/seco), dezembro de 2012 com precipitação acumulada de 195,4 mm (precipitação normal), janeiro de 2013 com precipitação acumulada de 300 mm (precipitação Acima da Normal/chuvoso), fevereiro 2013 com precipitação acumulada de 167 mm (precipitação abaixo da normal/seco) e março de 2013 com precipitação acumulada de 219,2 mm (precipitação normal).

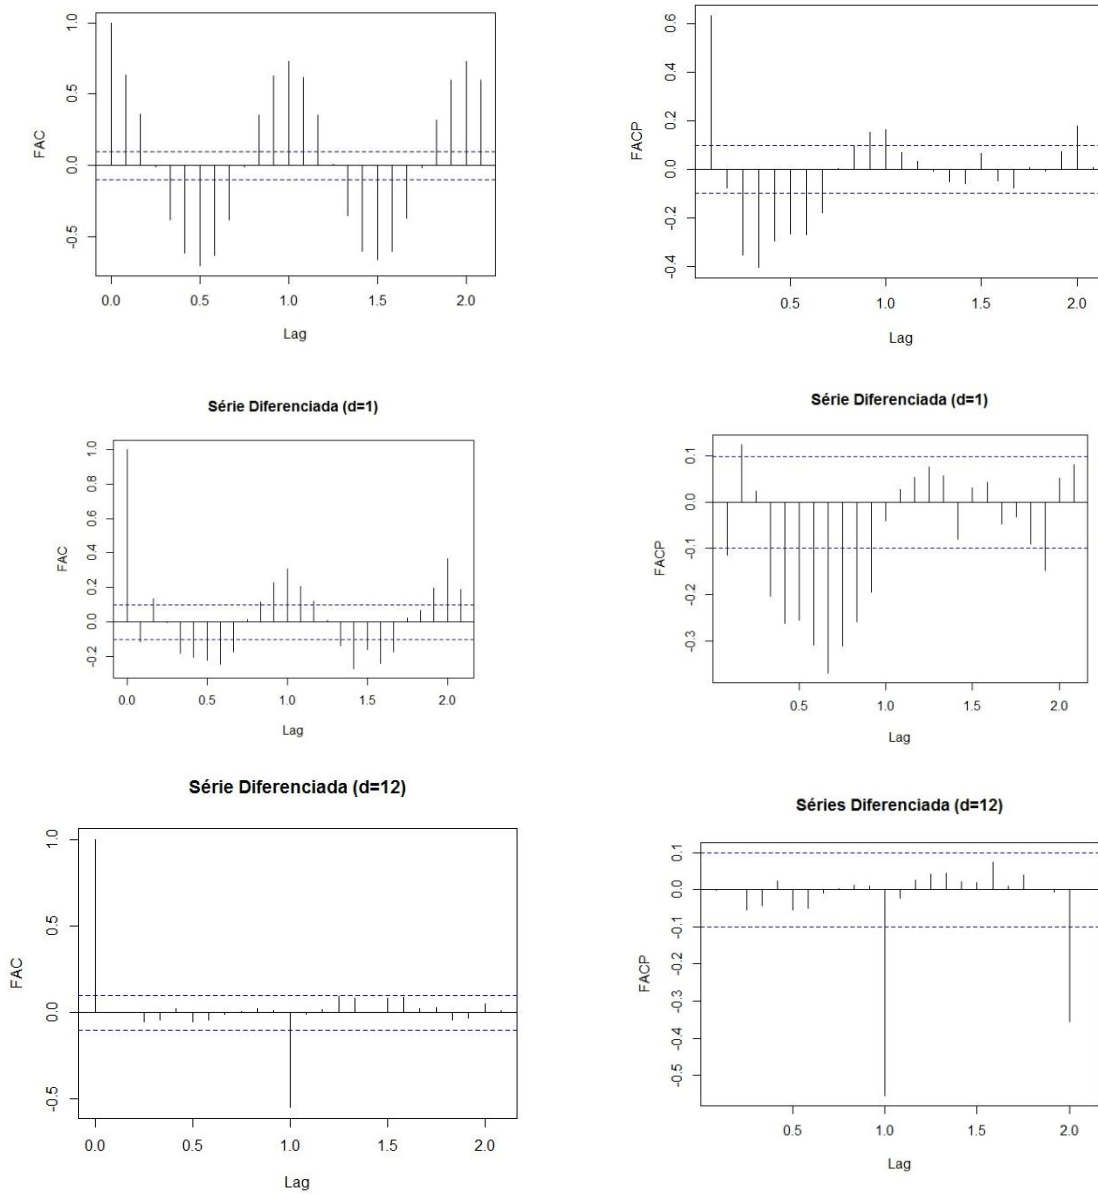
4.4.2 Modelos de Séries Temporais para Sub-Região Sudeste/Centro Oeste 1

4.4.2.1 Modelo SARIMA (NDJFM)

Para a previsão da estação chuvosa (novembro 2012, dezembro 2012, janeiro 2013, fevereiro 2013 e março 2013 - NDJFM) da SRS1, o primeiro modelo a ser ajustado é o modelo SARIMA.

Os gráficos das funções de autocorrelação (FAC) e de autocorrelação parcial (FACP), expressos na Figura 80, exibem os correlogramas da ST, sem diferença, com diferença de ordem 1 e ordem 12.

Figura 80 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) SRS1



Fonte: Autor.

Avaliando os FAC e FACP em nível e com diferença de ordem 12, percebe-se evidências de um modelo com sazonalidade bem definida e não estacionária. O FAC e FACP com uma diferença, deixa evidências de um modelo autorregressivo de ordem 1 a 5 e de médias móveis de ordem 1 a 4, sendo necessário levar em consideração a necessidade de aplicar diferenciações na ST. Os testes estatísticos e a análise gráfica indicam que um modelo do tipo SARIMA deve ser considerado. Essa análise é sumária e serve para dar início ao processo de modelagem, vários modelos de ordens diferentes serão considerados e testados.

Na Tabela 109, estão expostos alguns modelos concorrentes ajustados para a série SRS1, com os respectivos valores de AIC e BIC, e os parâmetros dos modelos.

Tabela 109 – Modelos concorrentes SARIMA e os respectivos critérios para a série SRS1 (NDJFM)

SARIMA (p, d, q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,0150$	4032	4052
	$\phi_2 = 0,0087$		
	$\Phi_1 = -0,1542$		
	$\Theta_1 = -0,9249$		
(1,0,0) (1,1,1) ₁₂	$\phi_1 = 0,0151$	4030	4046
	$\Phi_1 = -0,1537$		
	$\Theta_1 = -0,9255$		
(1,0,1) (1,1,1) ₁₂	$\phi_1 = 0,9546$	4031	4051
	$\theta_1 = -0,9436$		
	$\Phi_1 = -0,1597$		
	$\Theta_1 = -0,9267$		

Fonte: Autor.

Considerando os três melhores modelos significativos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual, o modelo SARIMA (1,0,0)(0,1,1)₁₂, atende a todos os pressupostos exigidos para realizar previsões. Os resultados das previsões do modelo SARIMA (1,0,0)(0,1,1)₁₂, estão expressos na Tabela 110 onde pode se verificar que há uma aproximação entre série observada e prevista.


Tabela 110 – Classificação climatológica das previsões, segundo o modelo SARIMA (1,0,0)(1,1,1)₁₂, para região SRS1 (NDJFM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	178 mm	173,9 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	259 mm	195,4 mm	Acima da Normal	Normal
Jan/2013	280,9 mm	300 mm	Acima da Normal	Acima da Normal
Fev/2013	194,8 mm	167 mm	Normal	Abaixo da Normal
Mar/2013	186,4 mm	219,2 mm	Normal	Normal

Fonte: Autor.

Na Figura 81, é possível analisar que o modelo consegue captar o comportamento da ST em estudo, demonstrado o excelente ajuste do modelo proposto.

Figura 81 – Modelo SARIMA (1,0,0) (0,1,1)₁₂ ajustado à série observada SRS1



Fonte: Autor.

O ajuste entre a ST observada e ajustada foi quase perfeito, encontrou-se uma correlação de 0,885 (forte), $p\text{-valor} < 0,2^{-16}$.

4.4.2.2 Modelo SARIMAX (NDJFM)

Para o ajuste do modelo SARIMAX, utilizou-se a TSM como variável explicativa. Utilizou-se a TSM com zero defasagem (TSM0), uma defasagem (TSM1) e três defasagens (TSM3). A escolha das séries de TSM se deu pelo coeficiente de correlação e não utilizou-se todas as séries de diferentes defasagens tendo em vista que o software R/notbook não suportam rodar a quantidade enorme de dados salvos na memória (deficiência computacional).

Entre os diversos modelos testados, a Tabela 111 expõem os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 111 – Modelos concorrentes SARIMAX e os respectivos critérios para SRS1

SARIMAX (p, d, q) [r]	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (0,1,2) [3] ₁₂	$\phi_1 = 0,0023$	4031	4059
	$\theta_1 = -0,733$		
	$\theta_1 = -0,1634$		
	TSM0 = 6,78		
	TSM1 = 9,46		
(1,0,0) (0,1,1) ₁₂	TSM3 = 8,34	4036	4059
	$\phi_1 = -0,0002$		
	$\theta_1 = -0,998$		
	TSM0 = 7,54		
	TSM1 = 11,63		
(2,0,0) (0,1,1) ₁₂	TSM3 = 5,44	4038	4065
	$\phi_1 = -0,0003$		
	$\phi_1 = 0,0063$		
	$\theta_1 = -0,999$		
	TSM0 = 7,6		
	TSM1 = 11,2		
	TSM3 = 5,4		

Fonte: Autor.

O modelo SARIMAX (1,0,0)(0,1,1)[3]₁₂, atende a todas as condições de erros decorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo para realizar previsões futuras.

As previsões para o modelo ajustado SARIMAX (1,0,0)(0,1,1)[3]₁₂ podem ser observadas na Tabela 112. Possivelmente a previsão seria melhor se todas as ST de TSM apresentadas na Tabela 106 tivessem sido incluídas no modelo.


Tabela 112 – Classificação climatológica das previsões, segundo o modelo SARIMAX (1,0,0) (0,1,1) [3]₁₂, para região SRS1 (DJF)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	170,5 mm	173,9 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	258 mm	195,4 mm	Acima da Normal	Normal
Jan/2013	283 mm	300 mm	Acima da Normal	Acima da Normal
Fev/2013	188 mm	167 mm	Normal	Abaixo da Normal
Mar/2013	152 mm	219,2 mm	Abaixo da Normal	Normal

Fonte: Autor.

A Figura 82, expressa a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%. Onde é possível analisar o ótimo ajuste do modelo, que consegue captar as informações dos pontos mais extremos.

Figura 82 – Modelo SARIMAX (1,0,0) (0,1,1) [3]₁₂ ajustado à série observada SRS1



Fonte: Autor.

Achou-se uma correlação de 0,889 e significativa, $p\text{-valor} < 0,02^{-16}$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.4.2.3 Alisamento Exponencial Modelo Holt-Winters (NDJFM) SRS1

As características da série sugerem o modelo HWM, entretanto foi testado também o modelo aditivo. Dessa classe de modelos, também se ajustou o modelo de AES para fins de comparação.

O modelo HWA obteve desempenho inferior ao modelo HWM. Os resultados das previsões do modelo HWM e AES estão na Tabela 113. O modelo HWM demonstra um comportamento satisfatório, atingindo a maioria dos meses na categorização das previsões.

Tabela 113 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e AES, para região SRS1 (NDJFM)


Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	188 mm	173,9 mm	Normal	Abaixo da Normal
Dez/2012	278 mm	195,4 mm	Acima da Normal	Normal
Jan/2013	311 mm	300 mm	Acima da Normal	Acima da Normal
Fev/2013	166,2 mm	167 mm	Abaixo da Normal	Abaixo da Normal
Mar/2013	185 mm	219,2 mm	Normal	Normal
AES				
Nov/2012	70,13	173,9 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	70,13	195,4 mm	Abaixo da Normal	Normal
Jan/2013	70,13	300 mm	Abaixo da Normal	Acima da Normal
Fev/2013	70,13	167 mm	Abaixo da Normal	Abaixo da Normal
Mar/2013	70,13	219,2 mm	Abaixo da Normal	Normal

Fonte: Autor.

Os resultados das previsões do modelo AES evidenciam que o mesmo não deve ser utilizado para a SRS1. Principalmente devido a sazonalidade existente na ST.

A Figura 83, expressa a ST observada, ajusta além do intervalo de previsão ($h=5$) do modelo HWM.

Figura 83 – Holt-Winters multiplicativo ajustado à variável SRS1



Fonte: Autor.

Para o modelo HWM a correlação entre observado e previsto é de 0,87 significativa, p-valor $< 0,05^{-16}$. Para o modelo AES simples uma correlação de 0,63 p-valor $< 0,02^{-16}$. O modelo AES não foi utilizado para o modelo agregado.

4.4.2.4 Modelos Combinados (NDJFM)

Os valores finais previstos para a precipitação acumulada período de verão da SRS1 novembro de 2012 a março de 2013, através da combinação das previsões dos modelos propostos estão expostos na Tabela 114. As correlações utilizadas no ajuste do modelo foram: SARIMA (0,885), SARIMAX (0,889) e HWM (0,87).

Tabela 114 – Classificação climatológica das previsões, segundo o modelo combinado, para região SRS1 (NDJFM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	178 mm	173,9 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	264 mm	195,4 mm	Acima da Normal	Normal
Jan/2013	291,4 mm	300 mm	Acima da Normal	Acima da Normal
Fev/2013	183 mm	167 mm	Normal	Abaixo da Normal
Mar/2013	174,3 mm	219,2 mm	Abaixo da Normal	Normal

Fonte: Autor.

Os modelos Combinado e HWM obtiveram os melhores resultados de previsão em relação aos modelos concorrentes, os modelos SARIMA e SARIMAX também ajustaram-se adequadamente a ST. A Tabela 115, expõem a comparação do desempenho dos modelos utilizando as técnicas de acurácia descritas na metodologia.

Tabela 115 – Comparação dos Modelos utilizando os critérios de seleção (Nov a Dez) SRS1


Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	14%	1662	28,5	8312
SARIMA(1,0,0) (1,1,1) ₁₂	14,5%	1255	29,5	6279
SARIMAX(1,0,0) (0,1,1) [3]	16,5%	1835	34,2	9176
COMBINADO	14,2%	1439	28,8	7199
AES	65%	22181	141	110096

Fonte: Autor.

A Tabela 115, demonstra o excelente desempenho dos modelos propostos para a previsão da precipitação acumulada para a estação climática do verão SRS1. Apesar do MAPE estar em torno de 14% para a maioria dos modelos, a forte correlação entre série observada e ajustada, o que evidencia o pontencial positivo dos modelos para as previsões da precipitação acumulada mensal da SRS1. O modelo AES não foi utilizado para a confecção do modelo Combinado, também não se recomenda o uso do modelo AES para a SRS1.

Observa-se na Figura 84, o excelente desempenho das previsões dos modelos propostos para praticamente todos os meses. Para o mês de dezembro os modelos estão superestimando as previsões.

Figura 84 – Desempenho dos modelos para SRS1 (Dez a Mar)



Fonte: Autor.

Para testar a significância estatística da diferença das previsões dos diferentes modelos, foi aplicado o teste de Diebold e Mariano A Tabela 116, expressa os resultados do teste.

Tabela 116 – Teste Diebold e Mariano (1995) (NDJFM) SRS1

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	-0,8	-	SARIMAX x HWM	0,17	-
SARIMA x HWM	-0,6	-	SARIMAX x Combinado	0,76	-
SARIMA x Combinado	-0,56	-	SARIMAX x AES	-2,48	*
SARIMA x AES	-2,56	*	HWM x Combinado	0,5	-
Combinado x AES	-2,52	*	HWM x AES	-2,46	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%

Fonte: Autor.

De acordo com a Tabela 116, não há diferença significativa nas previsões entre os modelos HWM, SARIMAX, SARIMA e Combinado, portanto, qualquer um dos modelos citados pode ser utilizado para representar a ST SRS1. O AES não tem capacidade preditiva para a região em estudo.

As classificações categorias das previsões foram satisfatórias por se aproximarem da série observada. Os modelos HWM e SARIMA alcançaram 3 dos 5 meses em estudo e aproxima-se muito bem dos demais meses, com um erro pontual de previsão em torno de 14%.

4.4.2.5 Síntese dos principais resultados encontrados para SRS1

Na Tabela 117, verifica-se que o modelo HWM obteve melhor desempenho de previsão em relação a seus concorrentes, não havendo diferença estatística significativa nas previsões entre os modelos propostos de acordo com o teste Deibold-Mariano (1995). Portanto qualquer modelo pode ser utilizado para representar a séries de precipitação acumulada da SRS1.

Tabela 117 – Desempenho dos modelos para SRS1 de acordo com o critério MAPE

Modelo	MAPE(%) (Nov a Mar)
Holt-Winters	14%
SARIMA	14,5%
SARIMAX	16,5%
COMBINADO	14,2%

Fonte: Autor.

Na Classificação climatológica, Quadro 19, destaca-se os modelos SARIMA, HWM e Combinado. Cabe ressaltar que não há diferença estatística significativa entre as previsões dos modelos.

Quadro 19 – Classificação categóricas das previsões para SRS1

(Continua)

Período	Observado	SARIMA	SARIMAX	HWM	Combinado
		Previsto	Previsto	Previsto	Previsto
Nov/2012	Abaixo da Normal	Abaixo da Normal	Abaixo da Normal	Normal	Abaixo da Normal
Dez/2012	Normal	Acima da Normal	Acima da Normal	Acima da Normal	Acima da Normal
Jan/2013	Acima da Normal	Acima da Normal	Acima da Normal	Acima da Normal	Acima da Normal
Fev/2013	Abaixo da Normal	Normal	Normal	Abaixo da Normal	Normal

Quadro 19 – Classificação categóricas das previsões para SRS1

Período	Observado	(Conclusão)			
		SARIMA	SARIMAX	HWM	Combinado
		Previsto	Previsto	Previsto	Previsto
Mar/2013	Normal	Normal	Abaixo da Normal	Normal	Abaixo da Normal

Fonte: Autor.

A próxima etapa do trabalho foi analisar a Sub-região Sudeste/Centro Oeste 2 (SRS2).

4.4.3 Análise da Sub-Região Sudeste/Centro Oeste 2 (SRS2)

A série histórica que compõe a SRS2 é obtida através da média das 24 séries históricas com maior similaridade, definidas pela análise de agrupamentos. As coordenadas que compõe a série estão descritas no Quadro 17.

Os valores quantílicos da região SRS2, período verão, auxiliam a determinar e classificar a climatologia do local. De acordo com características do clima da região em estudo, com duas estações bem definidas, verão chuvoso e inverno seco. O Quadro 20, demonstra a classificação climatológica para o período de verão (Nov, Dez, Jan, Fev, Mar), meses que serão efetuadas as previsões. Os meses de inverno (Abr, Maio, Jun, Jul, Ago, Set, Out) foram excluídos da série histórica para fins de obtenção da distribuição quantílica do período de verão.

Para encontrar os valores do Quadro 16, utilizou-se a metodologia proposta no item 2.6.


Quadro 20 – Classificação climatológica SRS2, período de verão

Classificação	Classes de Precipitação	
Muito Seco	$X_i \leq 107$	Abaixo da Normal
Seco	$107 < X_i \leq 139$	
Normal	$139 < X_i < 183,7$	Normal
Chuvoso	$183,7 \leq X_i < 226,9$	Acima da Normal
Muito Chuvoso	$X_i \geq 226,9$	
Sendo: X_i valores mensais observadas de precipitação acumulada mensal em milímetros.		

Fonte: Autor.

A Figura 85, busca corroborar na visualização da categorização de toda a série em estudo SRS2 período do verão e auxiliar no entendimento do Quadro 20.

Figura 85 – Classificação climatológica SRS2 período de verão



Fonte: Autor.

Após a categorização da série histórica período de novembro a março Quadro 20 e Figura 85, faz-se necessário verificar as principais medidas descritivas da precipitação mensal acumulada da SRS2.

Os valores das médias e desvios padrões das variáveis, coeficiente de variação e valor máximo e mínimo, utilizados neste estudo, estão expostos na Tabela 118. Verifica-se que a média aritmética é maior que a mediana, desta forma, temos uma distribuição assimétrica positiva a direita quando os valores se concentram na extremidade inferior da escala e se distribuem gradativamente em direção à extremidade superior, em suma, o terceiro quartil se afasta da mediana, enquanto que o primeiro quartil se aproxima da mesma, o que indica tendência de precipitação normal ou abaixo da normal. O grau de concentração de valores, em torno de um valor médio, grandeza de afastamento demonstra que ST é heterogênea. A distribuição é platicúrtica, evidenciando que a distribuição é mais achatada em relação a distribuição normal. A assimetria positiva indica uma cauda mais longa a direita, média maior que a mediana.


Tabela 118 – Medidas descritivas da precipitação acumulada mensal da SRS2, 1980 a 2013

Medida Descritiva	Resultado
Média	117,93
Mediana	110
Desvio Padrão	71,6
Coefficiente de variação	60,7%
Valor máximo	352
Valor mínimo	0,6
Curtose	0,39
Assimetria	0,44

Fonte: Autor.

Inicialmente, pode-se observar, na Figura 86, indícios de sazonalidade, não demonstrando de forma explícita a presença de tendências crescentes ou decrescentes. Como a série é extensa a inspeção gráfica pode apresentar distorções em sua avaliação. Desta forma, testes estatísticos foram aplicados para verificar as condições de estacionariedade e sazonalidade.


Figura 86 – Série Original da precipitação acumulada mensal da SRS2, 1980 a 2013



Fonte: Autor.

Na Figura 87, observa-se que a série tem um comportamento definido ao longo do tempo e, portanto, pode ser ajustada num modelo de previsão de série temporal. Também há de se considerar a presença de sazonalidade.

Figura 87 – Decomposição da série temporal SRS2 em componentes tendência, sazonalidade e aleatoriedade




Fonte: Autor.

O gráfico das médias mensais, Figura 88, ajuda a detectar visualmente a presença de sazonalidade na ST. Pode-se verificar ainda uma maior incidência de precipitação para os meses de verão novembro, dezembro, janeiro, fevereiro e março e menores acúmulos de precipitação para os meses de inverno abril, maio, junho, julho, agosto, setembro e outubro. Com menores índices de precipitação acumulada para os meses de junho, julho e agosto. Já os maiores valores concentram-se nos meses de dezembro e janeiro.

Verifica-se também que a ST possui indícios de não estacionariedade na parte sazonal, o que indica que a média e variância não são constantes ao longo do tempo.

Figura 88 – Médias mensais de precipitação acumulada SRS2



Fonte: Autor.

Após a etapa inicial de análise descritiva e gráfica dos dados foram realizados testes estatísticos para confirmar as hipóteses de estacionariedade e sazonalidade.

Para testar a presença ou não de estacionariedade foi utilizado o teste Dickey-Fuller. O teste, rejeita a hipótese nula H_0 (não estacionária), aceitando a hipótese alternativa H_1 de estacionariedade dos dados.

Para avaliar a sazonalidade foi realizado o teste Kruskal-Wallis, o teste indica a presença de efeito sazonal ao nível de significância $\alpha = 5\%$. Como Observada na Figura 72, a ST possui indícios de não estacionariedade da parte sazonal, sendo necessários aplicar diferenciações na parte sazonal a fins de estabilizar essa importante componente.

Para dar início a modelagem de ajuste e previsão foram reservados os cinco últimos meses do ano de 2012 e 2013 para fins de comparação das previsões. Os valores preservados foram: novembro de 2012 com precipitação acumulada 116 mm (precipitação abaixo da normal/seco), dezembro de 2012 com precipitação acumulada de 186,9 mm (precipitação Acima da Normal/chuvoso), janeiro de 2013 com precipitação acumulada de 168,4 mm (precipitação normal), fevereiro 2013 com precipitação acumulada de 211 mm (precipitação Acima da Normal/chuvoso) e março de 2013 com precipitação acumulada de 199 mm (precipitação Acima da Normal/chuvoso).

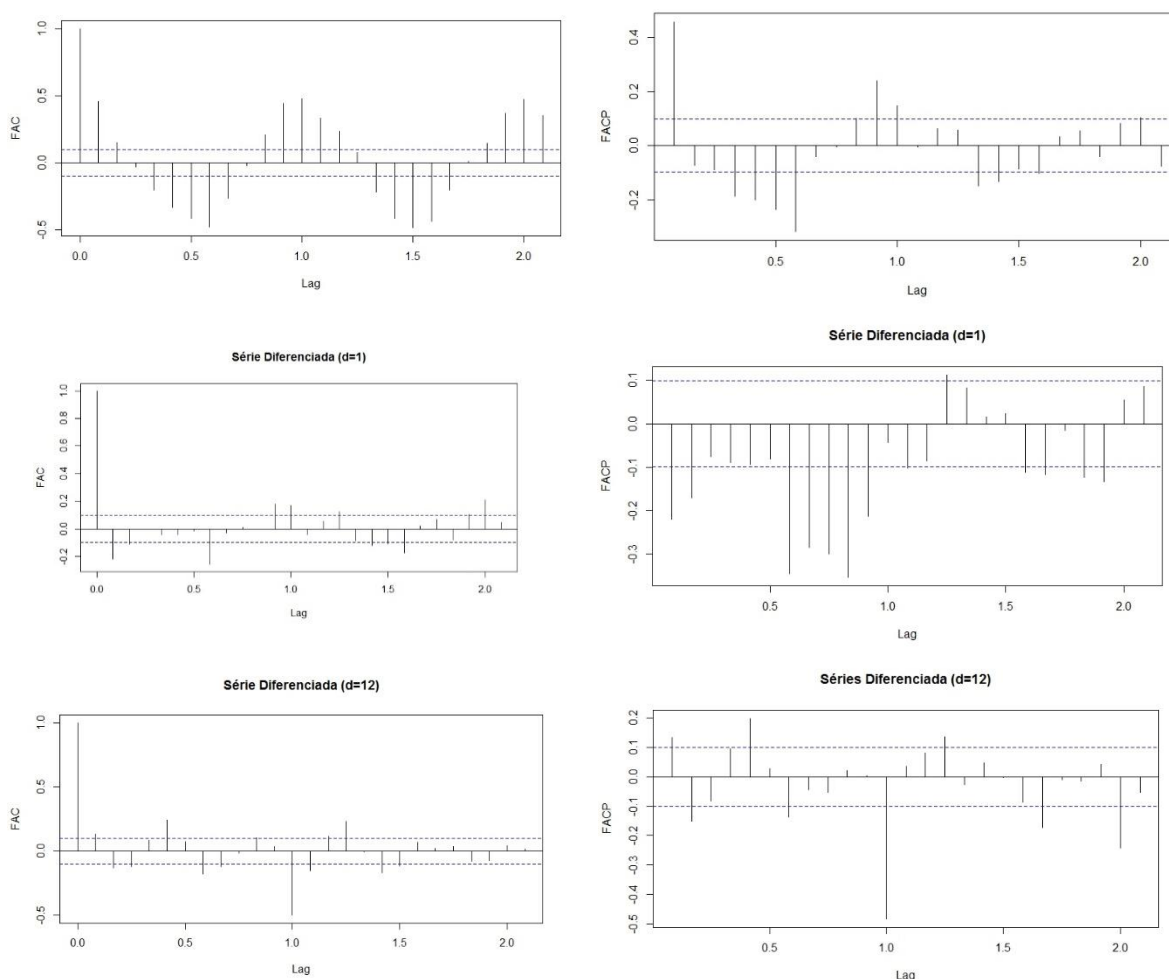
4.4.4 Modelos de Séries Temporais para Sub-Região Sudeste/Centro Oeste 2

4.4.4.1 Modelo SARIMA (NDJFM)

Para o período de novembro 2012 a março 2013 da SRS2, o primeiro modelo a ser testado é o modelo SARIMA.

Os gráficos das funções de autocorrelação (FAC) e de autocorrelação parcial (FACP), expressos na Figura 89, demonstram os correlogramas da série, sem diferença e com diferença de ordem 1 e ordem 12.

Figura 89 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) SRS2



Fonte: Autor.

Ao se analisar os FAC e FACP em nível e com diferença de ordem 12, constata-se evidências de um modelo com sazonalidade bem definida e não estacionária. O FAC e FACP com uma diferença, deixa evidências de um modelo autorregressivo de ordem 1 a 5 e de médias

móveis de ordem 1 a 2, sendo necessário levar em consideração a necessidade de aplicar diferenciações na ST, principalmente na parte sazonal. Os testes estatísticos e a análise gráfica indicam que um modelo do tipo SARIMA deve ser considerado. Essa análise é sumária e serve para dar início ao processo de modelagem, embora vários modelos de ordens diferentes serão considerados e testados.

Na Tabela 119, estão expostos alguns modelos concorrentes ajustados para a série SRS2, com os respectivos valores de AIC e BIC, e os parâmetros do modelo.

Tabela 119 – Modelos concorrentes SARIMA e os respectivos critérios para a série SRS2 (NDJFM)

SARIMA (p, d, q)	Parâmetros	Critérios de seleção	
		AIC	BIC
(2,0,0) (1,1,1) ₁₂	$\phi_1 = 0,1116$	4125	4144
	$\phi_2 = -0,1183$		
	$\Phi_1 = -0,0279$		
	$\Theta_1 = -0,9786$		
(0,0,0) (1,1,1) ₁₂	$\Phi_1 = -0,0446$	4030	4042
	$\Theta_1 = -0,9666$		
(0,0,1) (1,1,1) ₁₂	$\theta_1 = 0,1248$	4127	4143
	$\Phi_1 = -0,0372$		
	$\Theta_1 = -0,9664$		

Fonte: Autor.

O modelo SARIMA (2,0,0)(1,1,1)₁₂ atende a todas as condições de erros decorrelacionados, ruído branco e normalidade dos resíduos e concluem a última etapa da escolha do modelo para realizar previsões futuras.

Nessa etapa do trabalho, foram obtidas as previsões da série SRS2 para um horizonte de 5 meses à frente. Os resultados das previsões do modelo SARIMA (2,0,0)(1,1,1)₁₂, estão expressos na Tabela 120. O modelo se mostra eficaz para os primeiros meses da série observada.


Tabela 120 – Classificação climatológica das previsões, segundo o modelo SARIMA (2,0,0) (1,1,1)₁₂, para região SRS2 (NDJFM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	134 mm	116 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	186 mm	186,9 mm	Acima da Normal	Acima da Normal
Jan/2013	218 mm	168,4 mm	Acima da Normal	Normal
Fev/2013	173 mm	211 mm	Normal	Acima da Normal
Mar/2013	139,6 mm	199 mm	Normal	Acima da Normal

Fonte: Autor.

Na Figura 90, verifica-se que o modelo consegue captar os pontos extremos da ST observada SRS2. Onde pode-se analisar o bom ajuste do modelo.

Figura 90 – Modelo SARIMA (2,0,0) (1,1,1)₁₂ ajustado à série observada SRS2



Fonte: Autor.

A correlação encontrada entre série observada e ajusta foi de 0,73, p-valor $< 0,2^{-16}$. A mesma será usada para o ajuste do modelo combinado.

4.4.4.2 Modelo SARIMAX (NDJFM)

Para o ajuste do modelo SARIMAX, utilizou-se a TSM como variável explicativa, com zero defasagem (TSM0) e uma defasagem (TSM1). A escolha das séries de TSM se deu pelo coeficiente de correlação e não utilizou-se outras séries de diferentes defasagens tendo em vista que o software R/notbook não suportam rodar a quantidade enorme de dados salvos na memória.

A Tabela 121 estão expostos os três modelos testados com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 121 – Modelos concorrentes SARIMAX e os respectivos critérios SRS2

SARIMAX (p, d, q) [r]	Parâmetros	Critérios de seleção	
		AIC	BIC
(1,0,0) (0,1,2) [2] ₁₂	$\phi_1 = 0,0023$	4129	4149
	$\theta_1 = -0,733$		
	$\theta_1 = -0,1634$		
	TSM0 = -4,31		
	TSM1 = 21,32		
(1,0,0) (0,1,1) [2] ₁₂	$\phi_1 = -0,0885$	4128	4147
	$\theta_1 = -0,9688$		
	TSM0 = -4,80		
	TSM1 = 21,04		
(2,0,0) (0,1,1) [2] ₁₂	$\phi_1 = 0,099$	4123	4146
	$\phi_1 = -0,1355$		
	$\theta_1 = -0,9716$		
	TSM0 = -6,14		
	TSM1 = 24,75		

Fonte: Autor.

Considerando os melhores modelos ajustados, de acordo com os critérios de seleção AIC e BIC e análise residual. O modelo SARIMAX com dois parâmetros autorregressivo (p), um parâmetro de diferenças (D) na parte sazonal e um parâmetro de médias móveis (Q) na parte sazonal, dois parâmetros exógeno de TSM (zero defasagem TSM0, uma defasagem TSM1), atende a todas as condições para realizar previsões futuras. As previsões para o modelo ajustado SARIMAX (2,0,0)(0,1,1)[2]₁₂ podem ser observadas na Tabela 122. Como observado no modelo anterior, há uma maior facilidade nas previsões dos modelos para os primeiros meses do período observado.


Tabela 122 – Classificação climatológica das previsões, segundo o modelo SARIMAX (2,0,0) (0,1,1) [2]₁₂, para região SRS2 (NDJFM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	128 mm	116 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	181 mm	186,9 mm	Normal	Acima da Normal
Jan/2013	216 mm	168,4 mm	Acima da Normal	Normal
Fev/2013	164 mm	211 mm	Normal	Acima da Normal
Mar/2013	140 mm	199 mm	Normal	Acima da Normal

Fonte: Autor.

A Figura 91, expõem a série observada, ajustada, e prevista para os limites de previsão com intervalo de confiança de 95%. O bom ajuste do modelo não se converteu em previsões categóricas eficientes, principalmente para os meses de JFM.

Figura 91 – Modelo SARIMAX (2,0,0) (0,1,1) [2]₁₂ ajustado à série observada SRS2



Fonte: Autor.

A correlação é de 0,73, significativa, p-valor $< 0,02^{-16}$, entre a série observada e ajustada. A mesma será utilizada para o ajuste do modelo combinado.

4.4.4.3 Alisamento Exponencial Modelo Holt-Winters (NDJFM) SRS2

Devido ao comportamento explosivo dos dados principalmente na componente sazonal onde a média e a variância não são constantes, a ST sugere o modelo HWM. Entretanto foi testado também o modelo HWA que obteve resultados inferiores ao HWM.

Os resultados das previsões do modelo HWM para o período sazonal de verão SRS2, estão na Tabela 123, assim como os respectivos valores da série observada correspondente a cada período e classificação climatológica.


Tabela 123 – Classificação climatológica das previsões, segundo o modelo HW multiplicativo e HWA, para região SRS2 (NDJFM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	142 mm	116 mm	Normal	Abaixo da Normal
Dez/2012	180 mm	186,9 mm	Normal	Acima da Normal
Jan/2013	248 mm	168,4 mm	Acima da Normal	Normal
Fev/2013	178 mm	211 mm	Normal	Acima da Normal
Mar/2013	130 mm	199 mm	Abaixo da Normal	Acima da Normal
HWA				
Nov/2012	125 mm	116 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	174 mm	186,9 mm	Normal	Acima da Normal
Jan/2013	241 mm	168,4 mm	Acima da Normal	Normal
Fev/2013	172 mm	211 mm	Normal	Acima da Normal
Mar/2013	126 mm	199 mm	Abaixo da Normal	Acima da Normal

Fonte: Autor.

Os resultados das previsões dos modelos sugerem a utilização do modelo HWM em relação a seu concorrente HWA. Na Figura 92, temos os valores observados e previstos, além do intervalo de previsão ($h=5$) do modelo HWM. Observa-se o ótimo ajuste entre as ST observadas e ajustadas, o que não refletiu em previsões categóricas dentro do esperado.

Figura 92 – Holt-Winters multiplicativo ajustado à variável SRS2



Fonte: Autor.

A correlação positiva de 0,70 (forte) e significativa, $p\text{-valor} < 0,05^{-16}$, entre a série observada e ajustada para o modelo HWM, foi utilizada para agregação das previsões.

4.4.4.4 Modelos Combinados (NDJFM)

Os valores finais previstos para a precipitação acumulada período de verão da SRS2 novembro de 2012 a março de 2013, através da combinação das previsões dos modelos propostos estão expostos na Tabela 124. As correlações utilizadas para o ajuste forma: SARIMA (0,73), SARIMAX (0,73) e HWM (0,70).

Tabela 124 – Classificação climatológica das previsões, segundo o modelo Combinado, para região SRS2 (NDJFM)

Período	Precipitação Sazonal		Classificação Sazonal	
	Prevista	Observada	Prevista	Observada
Nov/2012	134,1 mm	116 mm	Abaixo da Normal	Abaixo da Normal
Dez/2012	182,1 mm	186,9 mm	Normal	Acima da Normal
Jan/2013	225 mm	168,4 mm	Acima da Normal	Normal
Fev/2013	172 mm	211 mm	Normal	Acima da Normal
Mar/2013	137,1 mm	199 mm	Normal	Acima da Normal

Fonte: Autor.

Através das técnicas de acurácia verifica-se que os modelos SARIMA e SARIMAX obtiveram resultados superiores de previsão em relação aos modelos concorrentes. Os modelos Combinado e HWM também ajustaram-se adequadamente a ST. A Tabela 125, demonstra uma comparação do desempenho dos modelos.

Tabela 125 – Comparação dos Modelos utilizando os critérios de seleção (Nov a Dez) SRS2


Modelo	MAPE(%)	EQM	MAD	SSE
HW Multiplicativo	24,7%	2580	42,9	12909
SARIMA(2,0,0) (1,1,1) ₁₂	18,6%	1551	33,1	7757
SARIMAX(2,0,0) (0,1,1) [2]	18,7%	1626	34,3	8134
COMBINADO	20,4%	1813	36,3	9068

Fonte: Autor.

Na Tabela 125, observa-se um desempenho superior do modelo SARIMA, que é o modelo proposto para a previsão da precipitação acumulada para a estação climática do verão SRS2. Os demais modelos também demonstram ajustes satisfatórios com correlações fortes e significativas entre séries observada e ajustada o que indica que previsões para outros períodos da série podem alcançar melhores resultados.

A Figura 93, demonstra o desempenho dos modelos propostos para SRS2 período de dezembro de 2012 a março de 2013. Onde percebe-se uma maior facilidade de previsão para os meses iniciais do período em análise. Para o mês de janeiro os modelos superestimam os valores previstos e para os meses finais as previsões subestimam a série observada.

Figura 93 – Desempenho dos modelos para SRS2 (Dez a Mar)



Fonte: Autor.

A Tabela 126, expressa os resultados do teste Diebold e Mariano.

Tabela 126 – Teste Diebold e Mariano (1995) (NDJFM) SRS2

Comparação	DM	Teste	Comparação	DM	Teste
SARIMA x SARIMAX	-0,42	-	SARIMAX x HWM	-1,1	-
SARIMA x HWM	-1,36	-	SARIMAX x Combinado	-0,70	-
SARIMA x Combinado	-1,46	-	HWM x Combinado	1,31	-

* teste significativo ao nível de significância de 10%, ** teste significativos ao nível de significância de 5%
Fonte: Autor.

De acordo com os resultados do teste Diebold-Mariano, expressos na Tabela 126, não há diferença significativa nas previsões entre os modelos HWM, SARIMAX, SARIMA e Combinado. Portanto, qualquer um dos modelos citados pode representar a ST SRS2.

Na classificação categorica das previsões o modelo SARIMA obteve melhor aproximação em relação aos seus concorrentes. No mês de janeiro identifica-se uma variabilidade considerável e um valor fora da curva para o ano de 2013, fato que aumenta os

erros tanto na classificação categórica quanto na classificação pontual. Os modelos SARIMAX e SARIMA tiveram um erro percentual médio em torno de 18% que pode ser considerado adequado pela variabilidade contida na ST em estudo para o período observado.

4.4.4.5 Síntese dos principais resultados encontrados para SRS2

A Tabela 127 trás o desempenho dos modelos de acordo com o critério MAPE. Destaca-se o modelo SARIMA não havendo diferença estatística significativa nas previsões para o modelo SARIMAX.

Tabela 127 – Desempenho dos modelos para SRS2 de acordo com o critério MAPE

Modelo	MAPE(%) (Nov a Mar)
Holt-Winters	24,7%
SARIMA	18,6%
SARIMAX	18,7%
COMBINADO	20,4%

Fonte: Autor.

De acordo com Quadro 21 o modelo SARIMA consegue captar os dois primeiros meses em observação. Os modelos SARIMAX e Combinado acertam o mês de novembro somente. O bom ajuste entre série observada e prevista não se refletiu nas previsões categóricas principalmente devido a variabilidade contida nos dados dos meses de Jan, Fev e Mar de 2013, meses em análise.

Quadro 21 – Classificação categóricas das previsões para SRS2

(Continua)

Período	Observado	SARIMA	SARIMAX	HWM	Combinado
		Previsto	Previsto	Previsto	Previsto
Nov/2012	Abaixo da Normal	Abaixo da Normal	Abaixo da Normal	Normal	Abaixo da Normal
Dez/2012	Acima da Normal	Acima da Normal	Normal	Normal	Normal
Jan/2013	Normal	Acima da Normal	Acima da Normal	Acima da Normal	Acima da Normal

Quadro 21 – Classificação categóricas das previsões para SRS2

Período	Observado	(Conclusão)			
		SARIMA	SARIMAX	HWM	Combinado
		Previsto	Previsto	Previsto	Previsto
Fev/2013	Acima da Normal	Normal	Normal	Normal	Normal
Mar/2013	Acima da Normal	Normal	Normal	Abaixo da Normal	Normal

Fonte: Autor.

Sintetizando os resultados categóricos encontrados no Capítulo 4, análise dos resultados, o Quadro 22 demonstra um resumo do desempenho dos modelos propostos para as previsões categóricas em todas as sub-regiões em análise.

Quadro 22 – Síntese das previsões categóricas para todas as sub-regiões em análise

Região	Modelo			
	SARIMA	SARIMAX	HWM	Combinado
SR1	6* de 12**	6* de 12**	4* de 12**	4* de 12**
SR2	6* de 12**	7* de 12**	6* de 12**	6* de 12**
SR3	7* de 12**	6* de 12**	7* de 12**	6* de 12**
SRS1	3* de 5**	2* de 5**	3* de 5**	3* de 5**
SRS2	2* de 5**	1* de 5**	0* de 5**	1* de 5**

Fonte: Autor.

Nas cinco sub-regiões em análise o modelo SARIMA se destaca em quatro delas (SR1, SR3, SRS1 e SRS2), sendo o modelo com melhor desempenho em comparação com os seus concorrentes. O modelo SARIMAX destacou-se para as SR1 e SR2, já o modelo HWM destacou-se para SR3 e SRS1 e o modelo combinado para SRS1.

5 CONCLUSÃO

Este trabalho objetivou verificar se modelos de ST das classes ARIMA, ARIMAX, Alisamento Exponencial e Combinados poderiam ser usados como ferramenta de apoio aos modelos dinâmicos na previsão da precipitação acumulada mensal.

A fim de contribuir com o aprimoramento de modelos estatísticos de previsão de ST, estudou-se a variável "precipitação acumulada mensal", considerando as características das séries históricas de uma região ou microrregião. Assim, buscou-se promover uma maior eficiência na previsão da precipitação sazonal das regiões em estudo.

Os resultados encontrados apontaram que os modelos de ST utilizados neste trabalho podem ser utilizados como uma ferramenta de apoio aos modelos numéricos de previsão, com destaque para o modelo SARIMA, "que permitiu maior previsibilidade para a variável "precipitação" nas regiões em estudo". Entretanto se faz necessário que sejam seguidos todos os pressupostos de validação dos modelos especificadas nesta pesquisa ou escritas detalhadamente em Morretin e Tolo (2004).

Restrições de desempenho dos modelos foram encontradas para os períodos de inverno das sub-regiões Sul, principalmente para SR2, onde não se recomenda o uso dos mesmos. As dificuldades de previsão destes períodos sazonais estão relacionadas com a alta variabilidade contida nas ST que faz com que os modelos propostos não consigam captar informações suficientes existentes nas próprias séries históricas para uma melhora no ajuste e previsão.

O uso da TSM como variável exógena ao modelo SARIMAX não surtiu efeitos significativos em melhores resultados de previsões em relação aos seus concorrentes de acordo com o teste estatístico Deibold-Mariano. Há de considerar que por deficiência computacional se utilizou apenas algumas séries de TSM, conforme descrito no texto. Fato que prejudica inferir sobre o uso da TSM como variável exógena no modelo SARIMAX.

Os modelos univariados testados possuem a vantagem de dependerem unicamente da série histórica em estudo o que facilita a aplicação dos mesmos. Entretanto, existem algumas dificuldades ao emprego, uma delas está associada ao grande número de tentativas até que se valide o modelo e se encontre o ajuste satisfatório.

A proposta do uso de modelos Combinados é uma prática a ser considerada para a melhoria nas previsões tanto categóricas quanto pontuais da precipitação acumulada mensal por ser uma prática simples e eficiente.

Para estudos futuros, pretende-se de utilizar um número maior de modelos de previsão ST, com intuito de melhorar a qualidade das previsões do modelo combinado.

REFERÊNCIAS BIBLIOGRÁFICAS

- AKAIKE, H. A Bayesian analysis of the minimum AIC procedure. **Annals of the Institute of Statistical Mathematics**, v. 30, p. 9-14, 1978.
- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, p. 716-723, 1974.
- ALBUQUERQUE, J. C. S.; SERRA, C. M. V. Utilização de modelos de Holt-Winters para a previsão de séries temporais de consumo de refrigerantes no Brasil. In: ENEGEP, 26., 2006, Fortaleza. **Anais...** Fortaleza, CE: Abepro, 2006.
- ALBUQUERQUE, P. H. M.; SILVA, L. C.; MALUF, Y. S. Estimação da influência de variáveis macroeconômicas sobre o faturamento de organizações siderúrgicas usando o ARMAX. **Gest. Prod.**, São Carlos, v. 21, n. 3, p. 648-659, 2014.
- ALVES, L. M. Clima da Região Centro-Oeste 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.
- ANDRADE, W. L. S. **Estimação de Modelos ARIMA/ARIMAX e Aplicação em Inferência de Propano**. 2009. 127f. Dissertação (Mestrado em Engenharia Elétrica e Computação), Universidade Federal do Rio Grande do Norte, Natal, 2009.
- ANDREOLI, R. V.; KAYANO, M. T. A importância relativa do atlântico tropical sul e pacífico leste na variabilidade de precipitação do nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 22, n. 1, p. 63-74, 2007.
- ANTONINI, J. C. A.; SILVA, E. M.; OLIVEIRA, L. F. C.; SANO, E. E. Modelo Matemático para a Temperatura média diária do ar do Estado de Goiás. **Pesquisa Agropecuária Brasileira**, Brasília, v. 44, n. 3, p. 333-338, 2009.
- ARSEGO, D. A. **Modelo Estatístico de Previsão de Produtividade de Soja e Arroz para o Rio Grande do Sul**. 2017. 120f. Tese de Doutorado (Doutorado em Meteorologia) – Universidade Federal de Santa Maria, Santa Maria, 2017.
- BARBIERO, C. C. M. **Séries Temporais: Um Estudo de previsão para a receita operacional da ECT – Empresa Brasileira de Correios e Telégrafos**. 2003. 108f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 2003.
- BARBOSA, C. M.; CHAVES, C. A. Um estudo sobre gerenciamento da demanda nos sistemas de planejamento e controle da engenharia de produção. In: CONGRESSO NACIONAL DE EXCELÊNCIA EM GESTÃO, 8., 2012, Rio de Janeiro. **Anais...** Rio de Janeiro, CNEG, 2012.
- BARNETT, T. P.; PREISENDORFER, R. Origins and Levels of Monthly and Seasonal Forecast Skill for United States Surface Air Temperatures Determined by Canonical Correlation Analysis. **MWR**, sep. 1987. DOI: [http://dx.doi.org/10.1175/1520-0493\(1987\)115<1825:OALOMA>2.0.CO;2](http://dx.doi.org/10.1175/1520-0493(1987)115<1825:OALOMA>2.0.CO;2).

- BARNSTON, A. G.; MASON, S. J.; GODDARD, L.; DEWITT, D. G.; ZEBIAK, S. E. Multimodel Ensembling in Seasonal Climate Forecasting at IRI. **Bull. Amer. Met. Soc.**, v. 84, n. 12, p. 1783-1796, 2003.
- BATISTA, A. L. F. **Modelos de séries temporais e redes neurais na previsão de vazão**. 2009. 79 f. Dissertação (Mestrado em Engenharia de Sistemas) – Universidade Federal de Lavras, Lavras, 2009.
- BATISTA, R. J. R. **Climatologia e Previsão Climatológica, via modelos RegCM3, de índices de conforto térmico para a região metropolitana de São Paulo**. 2012. 115 f. Dissertação (Mestrado em Ciências) – Universidade de São Paulo, São Paulo, 2012.
- BISCARO, G. A. **Meteorologia Agrícola Básica**. 1. ed. Cassilândia, MS: Editora União, 2007. p. 1-83.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 3. ed. Prentice Hall: New Jersey, 1994. 589 p.
- BRESSAN, A. A.; LIMA, J. E. Modelos de previsão de preços aplicados aos contratos futuros de boi gordo da BM&F. **Nova Economia**, Belo Horizonte, v. 12, n. 1, p. 117-140, 2002.
- BROCKWELL, P. J.; DAVIS, R. A. **Introduction to Time Series and Forecasting**. 2. ed. New York: Springer, 2002. 429 p.
- BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 2008. 299 p.
- CAMELO, H. N.; LUCIO, P. S.; LEAL JUNIOR, J. B. V.; CARVALHO, P. C. M. Métodos de Previsão de Séries Temporais e Modelagem Híbrida ambos Aplicados em Médias Mensais de Velocidade do Vento para Regiões do Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 32, n. 4, p. 565-574, 2017.
- CARVALHO, L. R. **Previsão de Demanda de Material de Saúde na Marinha do Brasil**. 2018. 105 p. Dissertação (Mestrado em Engenharia de Produção) – Pontífice Universidade Católica, Rio de Janeiro, 2018.
- CAS, C. G. Aplicação do modelo ARIMA para previsão do preço da commodity milho. **GEPROS: Gestão da Produção, Operações e Sistemas**, v. 13, n. 1, p. 263-279, 2018.
- CATALDI, M.; ASSAD, L. P. F.; TORRES JUNIOR, A. R.; ALVES, J. L. D. Estudo da influência das anomalias da TSM do Atlântico Sul extratropical na região da confluência Brasil Malvinas no regime hidrometeorológico de verão do sul e sudeste do Brasil. **Revista Brasileira de Meteorologia**, v. 25, n. 4, p. 513-524, 2010.
- CAVALCANTE, J. C. **Mortalidade em menores de um ano: utilização de novos indicadores para avaliação**. 2003. Dissertação (Mestrado em Saúde da criança) – Centro de Ciências da Saúde, Departamento de Tocoginecologia, Universidade Federal de Alagoas, Maceió, 2003.
- 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.

CERA, J. C.; FERRAZ, S. E. T. Variações Climáticas na precipitação no sul do Brasil no clima presente e futuro. **Revista Brasileira de Meteorologia**, v. 30, n. 1, p. 81-88, 2015.

CHECHI, L.; BAYER, F. M. Modelos univariados de séries temporais para previsão das temperaturas médias mensais de Erechim, RS. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 12, p. 1321-1329, 2012.

CHECHI, L.; SANCHES, F. O. Análise de uma série temporal de precipitação para Erechim (RS) e um possível método de previsão climática. **Ambiência**, Guarapuava, v. 9, n. 1, p. 43-45, jan./abr. 2013.

CONTI, J. B. A questão climática do nordeste brasileiro e os processos de desertificação. **Revista Brasileira de Climatologia**, v. 1 n. 1, p. 7-14, 2005.

DANFÁ, S. **Distribuição espacial da precipitação pluvial e sua erosividade para Guiné-Bissau**. 2009. 104 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Lavras do Sul, Lavras, 2009.

DETZEL, D. H. M. **Modelagem de séries hidrológicas: uma abordagem de múltiplas escalas temporais**. 2015. 214f. Tese (Doutorado em Engenharia de Recursos Hídricos e Ambiental) – Universidade Federal do Paraná, Curitiba, 2015.

DICKEY, D. A.; FULLER, W. A. Likelihood ratio statistics for autoregressive time series with a unit root. **Econométrica**, v. 49, n. 4, p. 1057-1072, 1981.

DIEBOLD, F. X.; MARIANO, R. Comparing Predictive Accuracy. **Journal of Business and Economic Statistics**, 13, p. 253-265, 1995.

DUCHON, C.; HALE, R. **Time Series Analysis in Meteorology and Climatology: An Introduction**. Chichester, UK: John Wiley & Sons, 2012. 257 p.

ESQUIVEL, R. M.; SENNA, V.; GOMES, G. S. S. Análise espectral singular: comparação de previsão em séries temporais. **Revista do Mestrado em Administração e Desenvolvimento Empresarial**, v. 16, n. 2, p. 87-101, 2012.

FELICIANO, R. A. **Uma proposta de gerenciamento integrado de demanda e distribuição, utilizando sistemas de apoio à decisão (SAD) com Business Intelligence (BI)**. 2009. 179f. Dissertação (Mestrado em Engenharia) – Politécnica Universidade de São Paulo, São Paulo, 2009.

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, 2009.

FREITAS, M. A. V.; SOITO, J. L. S. Energia e recursos hídricos. **Parcerias Estratégicas**, Brasília, v. 13, n. 27, p. 177-215, 2008.

GERHARDT, E. J.; FINGER, C. A. G.; LONGHI, S. J.; SCHUMACHER, M. V. Contribuição da análise multivariada na classificação de sítios em povoamentos de araucária angustifolia (bert.) o. ktze., baseada nos fatores físicos e morfológicos do solo e no conteúdo de nutrientes da serapilheira. **Ciência Florestal**, Santa Maria, v. 11, n. 2, p. 41-57, 2001.

GERLITZ, L.; VOROGUSHYN, S.; APEL, H.; GAFUROV, A.; UNGER-SHAYESTEH, K.; MERZ, B. A statistically based seasonal precipitation forecast model with automatic predictor selection and its application to central and south Asia. **Hydrol. Earth Syst. Sci.**, v. 20, p. 4605-4623, 2016.

GIL, A. C. **Como Elaborar Projetos de Pesquisa**. 4. ed. São Paulo: Atlas, 2002. p. 41-56.

GOUVEA, R. L.; CAMPOS, C. C.; MENEZES, J. T.; MOREIRA, G. F. Análise de frequência de precipitação e caracterização de anos secos e chuvosos para a bacia do rio Itajaí. **Revista Brasileira de Climatologia**, ano 14, v. 22, p. 309-323, jan./jun. 2018.

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.

HARVEY, D.; LEYBOURNE, S.; NEWBOLD, P. (1997). Testing the equality of prediction mean squared errors. **International Journal of forecasting**, v. 13, n. 2, p. 281-291, 1997.

HUANG, B.; THORNE P. W.; BAZON, V. F.; BOYER, T.; CHEPURIN, G.; LAWRIMORE, J. H.; MENNE, M. J., SMITH T. M.; RUSSELL S. **Vose, and Huai-Min Zhang (2017): NOAA Extended Reconstructed Sea Surface Temperatura (ERSST), Version 5 {indicate subset}. NOAA National Centers for Environmental Information DOI:10.7289/V5T72FNM.**

JORGETTI, T. **A Zona de Convergência do Atlântico Sul e os Processos Oceânicos do Atlântico e do Pacífico**. 2008. 193f. Tese (Doutorado em Ciências) – Universidade de São Paulo, São Paulo, 2008.

KAYANO, M. T.; ANDREOLI, R. V. Clima da Região Nordeste 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.

KEIEL, G.; BENDER, F. A. Modelagem de séries temporais financeiras: uma abordagem estatística para a identificação de modelos de média condicional. **Scientia cum Industria**, v. 6, n. 1, p. 22-28, 2018.

KHAN, V. M.; KIM, I. S.; SARAIVA, J. M. A relação entre as anomalias de TSM no Hemisfério Sul com as anomalias de precipitação no Sul do Brasil. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 10., 1998. Brasília. **Anais...** Brasília, DF: SBMET, 1998.

KUBRUSLY, L. S.; SABOIA, J. Uma análise multivariada da população ocupada nas regiões metropolitanas brasileiras. **Ensaio FEE**, Porto Alegre, v. 27, n. 2, p. 411-436, 2006.

LIZZI, E. A. S. **Predição do número de casos mensal dos casos de dengue por modelos de séries temporais**. 2012. 131 f. Dissertação (Mestrado em Saúde na Comunidade) – Universidade de São Paulo, Ribeirão Preto, 2012.

LOPES, M. N. G.; DE SOUZA, E. B.; FERREIRA, D. B. S. Climatologia regional da precipitação no estado do Pará. **Revista Brasileira de Climatologia**, ano 9, v. 12, p. 84-102, jan./jul. 2013.

LÚCIO, P. S. et al. Um modelo estocástico combinado de previsão sazonal para a precipitação no Brasil. **Revista Brasileira de Meteorologia**, v. 25, n. 1, p. 70-87, 2010.

LUZ, G. **Oceano Atlântico Sul e a Precipitação no Estado de São Paulo**. 2010. 180f. Dissertação (Mestrado em Geografia) – Universidade de São Paulo, São Paulo, 2010.

MANCUSO, A. C. B.; WERNER, L. Estudo dos métodos de previsão de demanda aplicado em uma empresa de auditorias médicas. **Revista Ingeniería Industrial**, v. 13, n. 1, p. 99-111, 2014.

MARCHESAN, T. M.; SOUZA, A. M.; MENEZES, R. Avaliação do processo de ensino: uma abordagem multivariada. **Revista Produção**, v. 21, n. 2, p. 271-283, 2011.

MARENGO, J. A. **Mudanças climáticas globais e seus efeitos sobre a biodiversidade: caracterização do clima atual e definição das alterações climáticas para o território brasileiro ao longo do século XXI**. Brasília: MMA, 2006. 212 p. (Série Biodiversidade, v. 26).

MARENGO, J. A.; NOBRE, C. A. Clima da Região Amazônica. 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.

MARTÍNEZ, R. O.; ZAMPROGNO, B. Comparação de algumas técnicas de previsão em análise de séries temporais. **Revista Colombiana de Estatística**, v. 26, n. 2, p. 129-157, 2003.

MEDEIROS, E. S.; BICALHO, C. C.; SÁFADI, T.; LIMA, K. P. Modelo SARIMAX aplicado aos casos de notificações de dengue em Recife, PE. **Revista Eletrônica Matemática e Estatística em Foco**, v. 6, n. 1, p. 01-11, 2018.

MELLO, C. R.; SILVA, A. M. Modelagem estatística da precipitação mensal e anual e no período seco para o estado de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 1, p. 68-74, 2009.

MITTERSTEIN, M. R.; SEVERO, D. L. Análise de variabilidade intrasazonal e interanual da precipitação no vale do Itajaí com a transformada de ondaletas. **Dynamis revista tecnológica**, v.13, n. 1, p. 1-10, 2007.

MOÇO, J. R. C. **Estimação de um modelo de previsão do ICMS do Estado do Rio de Janeiro**. 2017. 88 p. Dissertação (Mestrado em Economia) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2017.

MOITA NETO, J. M. Estatística multivariada: Uma visão didática-metodológica. **Revista de Filosofia e Ensino**, p. 1-13, maio, 2004.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Edgard Blucher, 2004. 535 p.

MORETTIN, P. A.; TOLOI, C. M. C. **Previsão de Séries Temporais**. 2. ed. São Paulo: Atual Editora, 1987. 436p.

NASCIMENTO, H. H. S. **Planejamento de mercado de energia elétrica no novo modelo do setor elétrico brasileiro pela aplicação de análise de componentes principal como métodos de combinação de previsão.** 2013, 100f, Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Mato Grosso do Sul, Campo Grande, 2013.

NUNES, L. H.; VICENTE, A. K.; CANDIDO, D. H. Clima da Região Sudeste 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.

OLIVEIRA, A. G. **A questão do valor do clima:** reflexões em torno de um valor conceitual para a precipitação pluviométrica na produção agrícola. 2010. 150 f. Tese (Doutorado em Geografia) – Universidade Federal de Uberlândia, Uberlândia, 2010.

OZAKI, V. A.; ADAMI, A. C. O. Modelagem estatística dos prêmios do seguro rural. **Revista Política Agrícola**, v. 21, n. 1, p. 60-75, 2012.

PALMIERI, A. M. **Desenvolvimento de Sistemas automatizado de baixo custo para a coleta e armazenamento de dados das variáveis climáticas:** aplicações no ambiente agrícola. 2009. 101 f. Dissertação (Mestrado em Ciências) – Escola Superior de Agricultura, Universidade de São Paulo, São Paulo, 2009.

PAMPUCH, L. A. **Características sinóticas e dinâmicas de períodos extremos secos sobre o sudeste do Brasil e sua relação com a TSM do Atlântico Sul.** 2014. 224f. Tese (Doutorado em Ciências) – Universidade de São Paulo, São Paulo, 2014.

PEREIRA, A. R.; COSTA, A. S.; OLIVEIRA, V. G.; BORGES, P. F.; ISMAEL FILHO, A. Análise do comportamento das médias anuais da precipitação pluvial e temperatura da cidade de Areia, Paraíba. **Gaia Scientia**, v. 9, n. 1, p. 67-73, 2015.

QUEIROZ, R.; GRASSI, P.; LAZZARE, K.; KOPPE E.; TARTAS, B. R.; KEMERICH, P. D. C. Geração de energia elétrica através da energia hidráulica e seus impactos ambientais. **Revista Eletronica em Gestão, Educação e Tecnologia Ambiental – REGET**, v. 13 n. 13, p. 2774-2784, ago. 2013.

REBOITA, M. S.; GAN, M. A.; ROCHA, R. P.; AMBRIZZI, T. Regimes de precipitação na América do Sul: uma revisão bibliográfica. **Revista Brasileira de Meteorologia**, v. 25, n. 2, p. 185-204, 2010.

REISEN, V. A.; MOLINARES, F. A. A.; TEIXEIRA, E. C. Modelagem de séries temporais sazonais na presença de outliers estudo de caso da vazão máxima mensal do rio Jucu, ES, Brasil. **Revista Brasileira de Recursos Hídricos**, v. 13, n. 2, 2008.

RINALDI, J. G. S.; MORABITO, S.; TACHIBANA, V. M. A importância da rapidez de atendimento em supermercados: um estudo de caso. **Revista Gestão e Produção**, v. 16, n. 1, p. 1-14, 2009.

ROSSI, D. J. **Previsão da velocidade dos ventos por redes neurais artificiais e arima de box & jenkins.** 2014. 76 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual Paulista Júlio de Mesquita Filho, Ilha Solteira, 2014.

- SAAD, D. S. **Aplicação de técnicas estatísticas multivariadas em dados de cerâmica vermelha produzidas na região central do Rio Grande do Sul**. 2009. 166f. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal de Santa Maria, Santa Maria, 2009.
- SANTOS, A. P. P.; ARAGÃO, M. R. S.; CORREIA, M. F.; SANTOS, S. R. Q.; SILVA, F. D. S.; ARAÚJO, H. A. Precipitação na Cidade de Salvador: Variabilidade Temporal e Classificação em Quantis. **Revista Brasileira de Meteorologia**, v. 31, n. 4, p. 454-467, 2016.
- SANTOS, A. V.; COSTA, J. H. F. Análise de modelos de séries temporárias para a previsão mensal do ICMS do Estado do Maranhão. **Cadernos IMESC**, v. 6, p. 5-10, 2008.
- SANTOS, D. C. **Padrões atmosféricos associados a extremos de precipitação na primavera do Rio Grande Do Sul**. 2012. 97 f, Dissertação (Mestrado em Meteorologia) – Universidade Federal de Santa Maria, Santa Maria, 2012.
- SANTOS, D. C. **Padrões comparação entre abordagem multi-física em mesoescala e determinística em alta resolução na simulação numérica de sistemas convectivos de mesoescala na Bacia do Prata**. 2017. 145 f. Tese (Mestrado em Meteorologia) – Universidade Federal de Santa Maria, Santa Maria, 2017.
- SANTOS, D. D.; TOLEDO FILHO, M. R. Estudo sobre a influência de variáveis meteorológicas em internações hospitalares em Maceió-AL, durante o período 1998 a 2006. **Revista Brasileira de Meteorologia**, v. 29, n. 3, p. 457-467, 2014.
- SANTOS, E. F. N.; SOUZA, I. F.; PINTO, J. E. S. S.; DUARTE NETO, P. J. Validade da estatística na compreensão do clima para diagnóstico e previsão. **Revista Brasileira de Geografia Física**, v. 10, n. 5, p. 1346-1354, 2017.
- SILVA, D. A.; COSTA, D. F.; SANTOS, M. E. A Utilização do Modelo Holt-Winters na Elaboração de um Orçamento de Resultado de uma Cooperativa de Crédito Rural. **Revista de Contabilidade do Mestrado em Ciências Contábeis da UERJ (online)**, Rio de Janeiro, v. 21, n. 1, p. 39-56, 2016.
- SILVA, K. O.; MORAES, S. O.; MIRANDA, J. H.; PALMIERI, A. M. Sistema automatizado para aquisição de dados de umidade relativa do ar. **Engenharia. Agrícola**, Jaboticabal, v. 27, n. 3, p. 630-638, 2007.
- SILVA, M. I. S.; GUIMARÃES, E. C.; TAVARES, M. Previsão da temperatura média mensal de Uberlândia, MG, com modelos de séries temporais. **Revista Brasileira de Engenharia agrícola e Ambiental**, v. 12, p. 480-485, 2008.
- SOUZA, A. M.; GEORGEN, R.; FERRAZ, S. E. T. Previsão de precipitação e temperatura em Santa Maria por meio de um modelo estatístico. **Ciência e Natura UFSM**, v. 31, n. 1, p. 49-64, 2009.
- SOUZA, A. M.; SCHIMIDT, A. S.; TURCATO, C. R. S. O aprendizado em organizações certificadas pela NBR ISO 9001:2000. **Revista Produção Online**, v. 11, n. 2, p. 289-318, 2011.
- SOUZA, A. M.; SILVA, F. M. Perfil dos alunos e dos Colégios Militares: um enfoque multivariado. **Revista Ciência e Natura**, v. 31, n. 2, p. 7-24, 2009.

SOUZA, R. C.; CAMARGO, M. E. **Análise de séries temporais: os modelos ARIMA**. [S.l.]: Ed. SEDIGRAF, 1996. 242 p.

STERN, P. C.; EASTERLING, W. E. **Making Climate Forecasts Matter**. Washington, D.C.: National Academy Press, 1999. 192 p.

TIBULO, C. **Modelos de Séries Temporais aplicados a dados de umidade relativa do ar**. 2014. 99 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Maria, Santa Maria, 2014.

TIBULO, C.; ZANINI, R. R.; FERRAZ, S. E. T.; BOIASKI, N. T.; TIBULO, V. C. A RELAÇÃO ENTRE A POLUIÇÃO DO AR E AS PRINCIPAIS VARIÁVEIS CLIMATOLÓGICAS NO MUNICÍPIO DE CANOAS – RS. **Revista Brasileira de Climatologia**, v 26, 2020.

TIDRE, P. V.; BIASE, N. G.; SILVA, M. I. S. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil. **Revista Eletrônica Matemática e Estatística em Foco**, v. 1, n. 1, p. 57-63, 2013.

TROCCOLI, A. Review Seasonal climate forecasting. **Meteorological Applications**, v. 17, p. 251–268, 2010.

VALER, L. A. **Modelo matemático ARIMAX de um propulsor eletromecânico utilizado em naves do tipo multirrotor**. 2016. 94 f. Dissertação (Mestrado em Modelagem Matemática) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2016.

VASCONCELOS JÚNIOR, F. C. **Pré-estação chuvosa e a estação chuvosa do norte do nordeste brasileiro: aspectos interanuais, intrasazonais e extremos**. 2014. 123 f. Tese (Doutorado em Ciências) – Universidade de São Paulo, São Paulo, 2014.

VERÍSSIMO, A. J.; ALVES, C. C.; HENNING, E.; AMARAL, C. E.; CRUZ, A. C.; Métodos estatísticos de suavização exponencial Holt-Winters para a previsão da demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, v. 8, n. 4, p. 154-171, 2012.

VICINI, L. **Análise multivariada da teoria à prática**. 2005. 215 p. Monografia (Especialização em Estatística e Métodos Quantitativos) – Universidade Federal de Santa Maria, Santa Maria, 2005.

VICINI, L.; SOUZA, A. M.; MORALES, F. E. C.; SOUZA, F. M. **Técnicas Multivariadas Exploratórias: teorias e aplicações no Software Statistica**. Santa Maria, RS: Ed. UFSM, 2018. 240p.

WILKS, D. S. Realizations of Daily Weather in Forecast Seasonal Climate. **Journal of Hydrometeorology**, p. 195-207, apr. 2002. DOI: [http://dx.doi.org/10.1175/1525-7541\(2002\)003<0195:RODWIF>2.0.CO;2](http://dx.doi.org/10.1175/1525-7541(2002)003<0195:RODWIF>2.0.CO;2).

WILKS, D. S. **Statistical Methods in the Atmospheric Sciences**. 2. ed. [S.l.: s.n.], 2006.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980-2013). **International Journal of Climatology**, v. 36, p. 2644-2659, 2015.

XAVIER, T. M. B. S. **Tempo de Chuva:** estudos climáticos e de previsão para o Ceará e Nordeste setentrional. Fortaleza: ABC Editora, 2001. 478 p.

XAVIER, T. M. B. S.; SILVA, J. F.; REBELLO, E. R. G. **A Técnica dos quantis e suas aplicações em Meteorologia, Climatologia e Hidrologia, com ênfase para as regiões brasileiras.** Brasília: Thesaurus Editora, 2002. 141 p.

XAVIER, T. M. B. S.; XAVIER, A. F. S. Caracterização de períodos secos ou excessivamente chuvosos no estado do Ceará através de técnicas dos quantis: 1964-1998. **Revista Brasileira de Meteorologia**, v. 14, n. 2, p. 63-78, 1999.

APÊNDICE A – Script R (Parcial)

```
#####
###ANÁLISE DE SÉRIES TEMPORAIS NO R
###ALUNO: CLEITON TIBULO
###ORIENTADORA: PROF. SIMONE
###PREVISÃO DA PRECIPITAÇÃO ACUMULADA MENSAL.
###DATA DE INÍCIO: 06/2019
#####
library(forecast)           #carrega o pacote;
library(stats)             #carrega pacote;
library(tseries)          #carrega pacote;
ls ()                      #verificar o que está salvo na memória;
rm (list=ls ())            #deleta arquivos salvos na memória;
#####
###Entrada de dados Região Sul (latitude (24,625° a 33,625°) e longitude (47,625° a 57,625°)
###Entre com a série de interesse na forma de um vetor qualquer.
###Lendo de um arquivo (deve ter uma coluna chamada a1, a2, a3, ....)
###h=T é necessário quando a primeira linha contenha informações de cabeçalho
###colocar o nome do arquivo entre aspas;
#####
data1<-read.table ("prec_-24.625_-48.625.asc", h=T)           #anexar dados
a1                                                            #conferir vetor
.
.
.
#####
#####Transformar o vetor numa série temporal (01/1980-12/2013)
#####Inicia em janeiro de 1980 e tem frequência mensal
A1<-ts (a1, start=c (1980,1), frequency=12)
A1
.
.
.
#####
#####Análise Agrupamentos (AA)
rm(dados)
dados<-cbind (A1,A2,...,A56)           #transformar em tabela
dados<-data.frame(dados)             #formato ideal para dados estatísticos
is.data.frame (dados)                #verificar se os dados são data.frame
rm(C)
C<-t(dados)                          #transposta (inverter linhas em colunas)
C
head(C)                               #mostrar as primeiras 6 linhas
tail(C)                               #mostra as últimas 6 linhas
dim(C)                               #número de linhas e colunas
names(C)                             #nome das colunas (variáveis)
str(C)                               #estrutura data.frame
rm(mun.hc.complete)                  #deleta memória
rm(mun.hc.average)                  #deleta memória
rm(mun.hc.single)                   #deleta memória
```

```

#####
####Distância Euclidiana e os três métodos de ligação
mun.hc.complete <- hclust(dist(C), method="complete")
mun.hc.average <- hclust(dist(C), method="average")
mun.hc.single <- hclust(dist(C), method="single")
#par(mfrow=c(1,3))
#####plota os três gráficos juntos
plot (mun.hc.complete, main="Complete Linkage",hang = -1, xlab="",sub="",cex=.9)
plot (mun.hc.average, main="Average Linkage",hang = -1, xlab="", sub="",cex=.9)
plot (mun.hc.single, main="Single Linkage",hang = -1, xlab="", sub="",cex=.9)
groups<-cutree(mun.hc.complete,k=3)          #identifica o grupo de cada variável
groups
#####Corte
#par (mfrow=c (1,3))
plot (mun.hc.complete, main="Complete Linkage", xlab="", sub="", cex=.9, hang=-1)
abline(h=2200, lty=2, lwd=2, col = 10)          #define a altura do corte
plot (mun.hc.complete, main="HC - Corte em 3 Clusters", xlab="", sub="", cex=.9, hang=-1)
abline (h=2200, lty=2, lwd=2, col = 10)
plot (mun.hc.complete, main="HC - Corte em 4 Clusters", xlab="", sub="", cex=.9, hang=-1)
abline(h=200, lty=2, lwd=2, col = 10)
#####Sumário dos Grupos
summary(A1, ...,A27)          #cluster1
.
.
#####Box Plot dos Cluster
#par(mfrow=c(1,3))
boxplot(A1, ...,A27,main="Cluster 1")          #cluster1
.
.
#####
#####Sub-regiões da região sul
SRI<-(A1+...+A27)/16          #média de precipitação da região sul 1
SRI          #print SRI
.
.
#####
#####Temperatura da Superfície do MAR (entrada de dados 5°X5°)
dados1<-read.table("TSM_+000_+005_+000_+005.asc")#colocar o nome do arquivo;
dados1TSM<-ts(dados1,start=c(1980,1),frequency=12)#
.
.
#####
#####Correlação/grupamento entre TSM e SRI,SR2,SR3
write.table(SRI, file='SRI.1.txt')          #salvando um novo arquivo(para correlações)
.
.
#####Séries da região Sul com 1 defasagem (lag) – Repetir para todos os lags
SRI.1<-read.table("SRI.1.txt", h=T)          #colocar o nome do arquivo entre aspas;
attach(SRI.1)          #anexar dados

```

```

SR1.1                                     #conferir vetor nova série com 1 lag
A57<-ts(SR1.1,start=c(1980,1),frequency=12) #série temporal com 1 lag
.
.
.
precipitacao1<-cbind(A57,A58,A59)
precipitacao1                             # SR1 com 1 lag
.
.
.
#####Correlação de Pearson (cor)
correla1<-cor(dadosmatrix1TSM,precipitacao1)
correla1                                   #defasagem 1
View(correla1)                             #matriz de correlação
.
.
.
#####Testes estatísticos das séries com r>0,40 região Sul (SR1)
#####Duas defasagens
cor.test(A60, dados803TSM,method="pearson",alternative="two.sided")
.
.
.
#####Gráficos de correlação
m<-cbind(A60,A63,dados803TSM,dados804TSM,dados860TSM,dados861TSM)
n<-cor(m)
library(corrplot)
corrplot(correla3,type = "upper", method = "number") #gráfico de correlação
corrplot(n,method = "number")#gráfico de correlação
.
.
.
#####Matrix TSM
rm(dadosmatrix1TSM)
dadosmatrix1TSM<cbind(dados1TSM,...,dados1367TSM) #matriz 1 de TSM
#####
#####Categorização da precipitação (ordens quantílicas)
#####Quartis
Quantile (SR1)                             #Distrib. quartil
quantile(SR1, prob = c(0.15, 0.35, 0.65, 0.85)) #quantil
#####gráfico
plot(SR1, xlab="Ano", ylab=" acumulada", main="", las=1, yaxt="n",col="blue")
axis(side=1, at=seq(1975, 2013, 5))          #limites eixo x
axis(side=2, at=seq(0, 400, 20), las=1)      #limites eixo y
#abline(mean(SR1), 0, col="red")             #linha para média
#abline(median(SR1), 0, col="blue")          #linha para
mediana
#abline(max(SR1), 0, col="purple")           #linha valor máximo
#abline(min(SR1), 0, col="purple3")          #linha valor mínimo
abline(quantile(SR1, prob = c(0.15)), 0, col="red",lwd=2) #linha quantil 0.15
abline(quantile(SR1, prob = c(0.35)), 0, col="black",lwd=2) #linha quantil 0.35
abline(quantile(SR1, prob = c(0.65)), 0, col="Green",lwd=2) #linha quantil 0.65
abline(quantile(SR1, prob = c(0.85)), 0, col="red",lwd=2) #linha quantil 0.85

```

```

#####legenda categoria
legend( 1977,70,legend=c("Muito Seco"), col="red", bty="n")
legend( 1977,110,legend=c("Seco"), col="red", bty="n")
legend( 1977,150,legend=c("Normal"), col="blue", bty="n")
legend( 1977,200,legend=c("Chuvoso"), col="red", bty="n")
legend( 1977,250,legend=c("Muito Chuvoso"), col="red", bty="n")
#####
#####Estatística descritiva
library(moments)
mean(SR1)           #média;
median(SR1)         #mediana;
moda(SR1)           #moda;
var(SR1)            #variância;
sd(SR1)             #Desvio-Padrão;
range(SR1)          #valor máximo e mínimo;
sd(SR1)/mean(SR1)*100 #coeficiente de variação em %;
kurtosis(SR1)       #curtose;
skewness(SR1)       #assimetria.
#####
#####Modelos de previsão
library(forecast)   #carrega o pacote;
library(stats)      #carrega pacote;
library(tseries)    #carrega pacote;
#####Gráfico da Série Original
plot(SR1)           #plota a serie temporal
plot(SR1,xlab="Período",ylab=" acumulada") #nome dos eixos
title("")           #Título dos gráficos entre " "
#####Gráfico de decomposição nas componentes de sazonalidade, tendência e aleatório
plot(decompose(SR1,type="multiplicative"))
plot(decompose(SR1,type="additive"))
#####Teste de estacionariedade
adf.test(SR1)       #teste Dickey-Fuller, verificar há estacionariedade da série
kpss.test(SR1)     #teste Kpss, verificar há estacionariedade
#####Teste de sazonalidade
#####Cria um vetor com 12 meses e repetir 34 vezes (190 a 2013 =34anos) para ficar igual
ao número de observações de R
g<-rep(1:12,34)
kruskal.test(SR1,g) #teste Kruskal-Wallis
#####Reservando as três últimas observações para comparação das previsões
tail(SR1)           #observar as seis últimas observações da série em estudo
#####salvando um novo arquivo, excluir as três últimas observações
write.table(SR1, file='prec_sr1.txt')
prec_sr1<-read.table("prec_sr1.txt", h=T) #colocar o nome do arquivo entre aspas;
attach(prec_sr1)    #anexar dados
#####conferir vetor nova série de dados sem as três últimas observações
prec_sr1
#####Transformar o vetor prec_sr1 numa série temporal (01/1980 – 09/2013).
#####Inicia em janeiro de 1980 e tem frequência mensal;
#####exclui as três últimas observações da série original para comparação de previsão
prec_sr1<-ts(prec_sr1,start=c(1980,1),frequency=12)

```

```

prec_sr1#conferir a série
#####
#####Modelos SARIMA
#####Função de Auto Correlação e Auto Correlação parcial
acf(prec_sr1, main="",ylab="FAC") #função de autocorrelação
pacf(prec_sr1, main="",ylab="FACP") #função de autocorrelação parcial
#####função de autocorrelação com d=1
acf(diff(prec_sr1,1),main="Série Diferenciada (d=1)", ylab="FAC")
#####função de autocorrelação parcial com d=1
pacf(diff(prec_sr1,1),main="Série Diferenciada (d=1)", ylab="FACP")
#####função de autocorrelação com d=1
acf(diff(prec_sr1,12),main="Série Diferenciada (d=12)",ylab="FAC" )
#####função de autocorrelação parcial com d=12
pacf(diff(prec_sr1,12), main="Séries Diferenciada (d=12)",ylab="FACP" )
#####Modelo SARIMA(p, d, q) (P, D, Q)
#####Seleção automática (base para início da modelagem)
best.sarima<-auto.arima(prec_sr1) #seleciona o modelo automaticamente
summary(best.sarima) #verificar se realmente é o melhor modelo
rm(sarima) #deleta memória salvos em SARIMA
rm(resid1) #deleta memória resid1
sarima<-Arima(prec_sr1,order = c(1, 0, 0), seasonal = list(order = c(0, 1, 2), period = 12))
summary(sarima) #verifica o modelo ajustado
resid1<- resid(sarima)
#####teste diagnóstico do modelo SARMA(1, 0, 0) (0, 1, 2)
tsdiag(sarima)
plot(resid1, xlab="Período", ylab="Resíduos") #plota o gráfico dos resíduos
#qqnorm(resid1,main="", xlab="Resíduos",ylab="Normalidade")
#qqline(resid1)
mean(resid1) #média dos resíduos;
var(resid1) #variância dos resíduos;
sd(resid1)
par(mfrow=c(1,1))
plot(resid1, xlab="Período", ylab="Resíduos", type="p")
#####teste Jarque e Bera e Shapiro-Wilk, normalidade dos resíduos
jarque.bera.test(resid1) #teste (Jarque e Bera) de normalidade dos resíduos;
shapiro.test(resid1) #teste (Shapiro-Wilk) de normalidade dos resíduos
hist(resid1) #histograma dos resíduos
#####Teste Ljung-Box, teste de ruído branco dos resíduos
Box.test(resid1,type="Ljung-Box") #teste de ruído branco
Box.test(resid1,type="Box-Pierce") #teste de ruído branco
#####histograma dos resíduos
hist(resid1,xlab="Resíduos",ylab="Frequência",main="") #Histograma dos resíduos
#####Modelo Ajustado
#####valores ajustados dentro do intervalo Observada
fit.sarima<-fitted(sarima)
#fit.sarima<-fitted.Arima(sarima)
#####plota os valores ajustados dentro do intervalo Observada
plot(fit.sarima,xlab="Período",ylab=" Acum.",type="l",lty=15,col=10, ylim=c(0,400))
lines(prec_sr1,col=1,type="l")
fit.sarima

```

```

#####Previsão h passos a frente
rm(pred.sarima)
pred.sarima<-forecast(sarima, h=3, nível=c(95))           #previsão com 95% de confiança
summary(pred.sarima)                                     #sumário das previsões
#####plota a série com as previsões e intervalo de previsão determinado em nível=c(95)
plot(pred.sarima,main="",xlab="Período",ylab=" acumulada",ylim=c(-50,450))
lines(fit.sarima, col=10, lty=1, type="l")
legend( 1978,30,legend=c("Série obser."),lty=c(1), col=c(1), bty="n")
legend( 1987,30,legend=c("Série ajustada"),lty=c(1), col=c(2), bty="n")
legend( 1999,30,legend=c("Valores Previstas"),lty=c(1), col=c(4), bty="n")
#####Função de Autocorrelação e Autocorrelação parcial dos resíduos
acf(resid1, main="", ylab="FAC")                         #fac resíduos
pacf(resid1, main="", ylab="FACP")                       #facp resíduos
#####Correlação entre série ajustada e observada
correlação<-cor.test(prec_sr1,fit.sarima,method="pearson",alternative="two.sided")
correlação                                              #imprime coeficiente de correlação
#####
#####Modelo Holt-Winters
rm(hwa)
rm(hwm)
hwa<-HoltWinters(PREC_SR2, seasonal="additive")         #Holt-Winters aditivo.
Hwa                                                    #valores Previstas aditivo
#####valores da série ajustada do modelo aditivo
ajuste_hwa<-fitted(hwa)
coef(hwa)                                              #coeficientes do modelo aditivo
#####previsão h=3
prev_aditivo
prev_aditivo<-predict(hwa,n.ahead=3, prediction.interval = T, level=0.95)
#####Holt-Winters multiplicativo hwm
#####valores Previstas multiplicativo
hwm<-HoltWinters(PREC_SR2, seasonal="multiplicative")
ajuste_hwm<-fitted(hwm)                               #valores da série ajustada do modelo aditivo
ajuste_hwm                                             #imprime os valores
coef(hwm)                                              #coeficientes do modelo aditivo
#####previsão h=3
prev_multiplicativo<-predict(hwm,n.ahead=3, prediction.interval = T, level=0.95)
prev_multiplicativo
#####plotar as séries ajustadas e valores Previstas dos modelos de Holt-Winters aditivo
hwa<-HoltWinters(prec_sr1, seasonal="additive")         #ajuste das séries modelo aditivo
summary(hwa)
hwa                                                    #parâmetros
#####previsão h=4
prev_aditivo<- predict(hwa,n.ahead=4, prediction.interval = T, level=0.95)
#####plota a série ajustada e previsões
plot(hwa,prev_aditivo,xlab="Período",ylab=" acumulada",main="", type="l",lty=15,
col=10, ylim=c(-50,450))
lines(prec_sr1,col=1,type="l")                         #plota a série observada;
legend(1980,00,legend=c("Série obser."),lty=c(1), col=c(1,9), bty="n")
legend(1989,00,legend=c("Série ajustada"),lty=c(1), col=c(2), bty="n")
legend(1999,00,legend=c("Limite de previsão"),lty=c(1), col=c(4), bty="n")

```

```

title(" ") #Título do gráfico;
#####imprime os valores Previstas modelo aditivo
prev_aditivo
#####plotar as séries ajustadas e valores previstos modelo multiplicativo
#####Holt-Winters multiplicativo. h o número de previsões passos à frente que desejamos
hwm<-HoltWinters(prec_sr1,seasonal="multiplicative")
hwm
summary(hwm) #verifica os valores ajustados
#####previsão h=4
prev_multiplicativo<- predict(hwm,n.ahead=4, prediction.interval = T, level=0.95)
plot(hwa,prev_multiplicativo,xlab="Período",ylab=" acumulada",main="", type="l",
lty=15,col=10, ylim=c(-50,450)) #plota a série ajustada e previsões;
lines(prec_sr1,col=1,type="l") #plota a série observada
legend(1978,30,legend=c("Série obser."),lty=c(1), col=c(1), bty="n")
legend(1987,30,legend=c("Série ajustada"),lty=c(1), col=c(2), bty="n")
legend(1999,30,legend=c("Valores Previstas"),lty=c(1), col=c(4), bty="n")
title(" ") #Título do gráfico
#####imprime os valores Previstas modelo multiplicativo
prev_multiplicativo
correlação1<-cor.test(prec_sr1,ajuste_hwa,method="pearson",alternative="two.sided")
correlação1 #imprime coeficiente de correlação
correlação2<-cor.test(prec_sr1,ajuste_hwm,method="pearson",alternative="two.sided")
correlação2 #imprime coeficiente de correlação
#####
#####Modelo SARIMAX
#####TSM
#####Média de TSM com 2 defasagens e correlação significativa para SR1
TSM_M2<-(dados803TSM+...+dados1176TSM)/13
#####imprime Média de TSM com 2 defasagens e correlação significativa para SR1
TSM_M2
#####Média de TSM com 3 defasagens e correlação significativa para SR1
TSM_M3<-dados750TSM
#####imprime Média de TSM com 3 defasagens e correlação significativa para SR1
TSM_M3
#####Reservando as 4 últimas observações para comparação das previsões
#####Arrumar a série a ser prevista SR1 com as defasagens
#####salvando um novo arquivo TSM com 2 defasagem
write.table(TSM_M2, file='sr1TSMtxt')
rm(sr1TSM2)
sr1TSM2<-read.table("sr1TSMtxt", h=T) #colocar o nome do arquivo entre aspas;
#####conferir vetor nova série de dados sem as três últimas observações
sr1TSM2
#####Transformar o vetor prec_sr1 numa série temporal (01/1980 – 09/2013).
#####Inicia em janeiro de 1980 e tem frequência mensal;
#####excluídas as 4 últimas observações da série original para comparação de previsão
rm(SR1_TSM2)
SR1_TSM2<-ts(sr1TSM2,start=c(1980,1),frequency=12)
SR1_TSM2 #conferir a série
#####salvando um novo arquivo TSM 3 defasagens
write.table(TSM_M3, file='sr1TSM3.txt')

```

```

srITSM3<-read.table("srITSM3.txt", h=T)      #colocar o nome do arquivo entre aspas;
#####conferir vetor nova série de dados sem as três últimas observações
srITSM3
#####Transformar o vetor prec_sr1 numa série temporal (01/1980 – 09/2013).
#####Inicia em janeiro de 1980 e tem frequência mensal;
#####excluídas as 4 últimas observações da série original para comparação de previsão
SR1_TSM3<-ts(srITSM2,start=c(1980,1),frequency=12)
SR1_TSM3      #conferir a série
z<-cbind(SR1_TSM2,SR1_TSM3)#criar a matriz conjunta z;
z      #matriz da TSM
rm(srITSM2)
#####duas defasagens
w1<c(14.3230769230769,14.5153846153846,15.3230769230769,16.2307692307692)
w2<-c(19.1,19,19.6,21.3)      #três defasagens
W1<-cbind(w1)
#####três defasagens SRI
cor.test(A63,method="pearson",alternative="two.sided")
prec_sr1
z
#####SARIMAX
rm(k)      #deleta memorias salvas em k
k
k<-Arima(prec_sr1,order=c(1, 0, 0),seasonal=list(order=c(0, 1, 2),period=12),xreg= SR1_
TSM2)
summary(k)      #verifica o modelo ajustado
rm(resid2)
resid2<- resid(k)
resid2
#####teste diagnóstico do modelo SARMA(3,0,0) (1,0,1)
tsdiag(k)
plot(resid2, xlab="Período", ylab="Resíduos")      #plota o gráfico dos resíduos
#qqnorm(resid1,main="", xlab="Resíduos",ylab="Normalidade")
#qqline(resid1)
mean(resid2)      #média dos resíduos;
var(resid2)      #variância dos resíduos;
par(mfrow=c(1,1))
plot(k, xlab="Período", ylab="Resíduos", type="p")
#####teste Jarque e Bera e Shapiro-Wilk, normalidade dos resíduos
#####teste (Jarque e Bera) de normalidade dos resíduos;
jarque.bera.test(resid2)
#####teste (Shapiro-Wilk) de normalidade dos resíduos
shapiro.test(resid2)
hist(resid2)      #histograma dos resíduos
#####Teste Ljung-Box, teste de ruído branco dos resíduos
Box.test(resid2,type="Ljung-Box")      #teste de ruído branco
Box.test(resid2,type="Box-Pierce")      #teste de ruído branco
#####histograma dos resíduos
hist(resid2,xlab="Resíduos",ylab="Frequência",main="") #Histograma dos resíduos
#####Fuação de Autocorrelação e Autocorrelação parcial dos resíduos
acf(resid2, main="", ylab="FAC")      #fac resíduos

```



```

pacf(resid2, main="", ylab="FACP")           #facp resíduos
#####Modelo ajustado
rm(fit1)
#####valores ajustados dentro do intervalo Observada
fit1<-fitted(k)
#####plota os valores ajustados dentro do intervalo Observada
plot(fit1,xlab="Período",ylab=" acumulada",type="l",lty=15,col=10, ylim=c(0,400))
lines(prec_sr1,col=1,type="l")
fit1
#####Previsão h passos à frente
rm(pred.sarimax)
pred.sarimax
w           #valores Previstas da temmax e tempmim
#####previsão com 95% de confiança xreg=regressores
pred.sarimax<-forecast(k,h=4,xreg=W1,nível=c(95))
pred.sarimax
summary(pred.sarimax)           #sumário das previsões
#####plota a série com as previsões e intervalo de previsão determinado em nível=c(95)
plot(pred.sarimax,main="",xlab="Período",ylab=" acumulada",ylim=c(-50,450))
lines(fit1, col=10, lty=1, type="l")
legend( 1978,30,legend=c("Série obser."),lty=c(1), col=c(1), bty="n")
legend( 1987,30,legend=c("Série ajustada"),lty=c(1), col=c(2), bty="n")
legend( 1999,30,legend=c("Valores Previstas"),lty=c(1), col=c(4), bty="n")
#####Correlação entre série ajustada e observada
rm(correlação)
correlação<-cor.test(prec_sr1,fit1,method="pearson",alternative="two.sided")
correlação           #imprime coeficiente de correlação
#####Deibolt-Mariano Teste
library(forecast)
rm(e1,e2,e3,e4, e5)
e1<-c( )           #erros de previsão SARIMA
e2<-c( )           #erros de previsão SARIMAX
e3<-c( )           #erros de previsão HW
e4<-c( )           #erros de previsão modelo combinado
e5<-c( )           #erros de previsão modelo AES
dm.test(e3,e4,alternative = c("two.sided", "less", "greater"),h=1,power=2)
#####h=horizonte de previsão,
#####hipótese H0 (p-valor>5%) não há diferença significativa,
#####Obs: A hipótese nula é que as duas previsões tenham a mesma precisão.
#####hipótese alternativa H1: (p-valor<5%)
#####A hipótese alternativa é que as duas previsões têm diferentes níveis de precisão;
#####two.siled (o método 1 e o método 2 têm diferentes níveis de precisão);
#####less=método 2 seja menos preciso que o método 1;
#####greater=método 2 seja mais preciso que o método 1.
#####A hipótese nula (não há diferença significativa entre as previsões), se a estatística de
DM computada estiver no intervalo de -1,96 a 1,96 (alfa = 5%) ou -1,66 a 1,66 (alfa 10%).
#####Repete mesmos procedimentos adotados para todas as regiões

```