



Universidade Estadual da Paraíba
Centro de Ciências e Tecnologia
Departamento de Estatística

Rosendo Chagas de Albuquerque

Modelagem em séries temporais aplicados a dados climatológicos no sertão paraibano

Campina Grande - PB

Junho de 2015

Rosendo Chagas de Albuquerque

Modelagem em séries temporais aplicados a dados climatológicos no sertão paraibano

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba em cumprimento às exigências legais para obtenção do título de Bacharel em Estatística.

Orientador:

Dr. Ricardo Alves de Olinda

Campina Grande - PB

Junho de 2015

É expressamente proibida a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano da dissertação.

A345m Albuquerque, Rosendo Chagas de.

Modelagem em séries temporais aplicados a dados climatológicos no Sertão Paraibano [manuscrito] / Rosendo Chagas de Albuquerque. - 2015.

34 p. : il. color.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Estatística) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2015.

"Orientação: Prof. Dr. Ricardo Alves de Olinda, Departamento de Estatística".

1. Modelos RMA. 2. Dados climáticos. 3. Modelos de previsão. I. Título.

21. ed. CDD 519.5

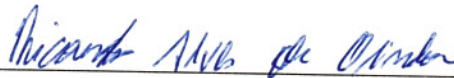
Rosendo Chagas de Albuquerque

Modelagem em séries temporais aplicados a dados climatológicos no sertão paraibano

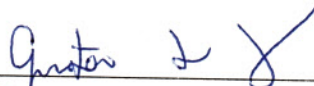
Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba em cumprimento às exigências legais para obtenção do título de Bacharel em Estatística.

Aprovado em: 30/06/2015

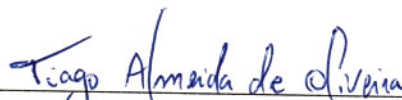
Banca Examinadora:



Prof. Dr. Ricardo Alves de Olinda
Orientador



Prof. Gustavo Henrique Esteves
Universidade Estadual da Paraíba - UEPB



Prof. Dr. Tiago Almeida de Oliveira
Universidade Estadual da Paraíba - UEPB

Dedicatória

Dedico este trabalho, aos meus pais José de Oliveira e Maria de Fátima, a quem devo toda esta caminhada, a eles o meu reconhecimento e carinho.

A minha esposa e a minha filha Poliana Azevedo e Sophie Chagas, que ao lado da minha mãe são as mulheres mais importantes da minha vida.

Aos professores, pelo estímulo, experiência e ensinamentos.

Aos meus amigos e colegas de estudos, pela compreensão e força nos momentos mais necessários.

Agradecimentos

Ao Prof. Dr. Ricardo Alves de Olinda, pela orientação segura e disponibilidade para realização deste trabalho.

Aos professores do Departamento de Estatística - UEPB e aos colegas de aula, pessoas com quem sempre pude contar.

Aos familiares pelo incentivo e apoio, que se fizeram sempre presentes.

De forma especial, Poliana, Sophie, Sônia, Leomir, Fábio, Abraão, Diego, Josy, Adriano, Alcione, Regina, Anderson, Junior, Rafa, Marciana, Marcicleide, Branca, Renan, José e Fátima, um muito obrigado a todos.

Resumo

Nos últimos anos, grandes quantidades de dados climáticos, em particular dados de precipitação, provenientes de estações meteorológicas, têm sido coletados e armazenados por diversos órgãos governamentais. A análise desses dados tornou-se uma tarefa importante devido as mudanças climáticas e seus efeitos sócio-econômicos. Sendo assim, é importante utilizar uma metodologia capaz de analisar dados distribuídos ao longo do tempo/espaço, isto é, análise de séries temporais. Neste trabalho pretende-se utilizar algumas técnicas da análise de séries temporais, bem como seus respectivos modelos, com objetivo de verificar possíveis comportamentos anômalos das séries de precipitação dos municípios de Imaculada, Conceição e Teixeira, localizados na Região do Sertão paraibano. Com isto, modelos auto-regressivos de médias móveis (ARMA) mostraram-se eficientes. A estratégia para construção deste modelo é baseada em um ciclo iterativo, no qual a escolha da estrutura dos modelos baseiam-se nos próprios dados. Por fim, após a escolha do modelo que melhor representou os dados em estudo, adotando-se alguns critérios de escolha de modelos, procedeu-se com a previsão para os próximos anos.

Palavras-chave: Modelos ARMA, dados climáticos, modelo de previsão.

Abstract

In the last years, a large amount of climate data, in particular precipitation data from meteorological stations, have been collected and stored by various governmental agencies. The data analysis of has become an important task considering the climate change and its socio-economic effects. Therefore, it is important to use a methodology to analyze the data distributed over the time and space, in other words, the analysis of time series. In this work we intend to use some techniques from the analysis of time series as well as their formats, in order to verify a possible anomalous behavior of the precipitation series from the cities of Imaculada, Conceição and Teixeira, both located in the Region backlands of Paraíba. With this, autoregressive moving-average models (ARMA) were effective. The strategy for building this model is based on an iterative cycle, in which the choice of structure of models is based on the data itself. Finally, after the model choice that best represented the data in the study, adopting some requirements for choosing models; it proceeded with the forecast for the next years.

key-words: ARMA models, weather data, forecasting model.

Lista de Figuras

- 1 Precipitação acumulada anual (mm) no período de 1935 a 2013 para os municípios de Conceição (a), Imaculada (b) e Teixeira (c). p. 21
- 2 Funções de autocorrelação (FAC)(a,c,e) e funções de autocorrelações parciais (FACP)(b,d,f) para os municípios de Conceição, Imaculada e Teixeira, respectivamente. p. 25
- 3 Funções de autocorrelação dos resíduos(FAC)(a,c,e) e Estatística de Ljung-Box(b,d,f) para os municípios de Conceição, Imaculada e Teixeira. p. 26
- 4 Previsão da precipitação acumulada anual(mm) para os próximos dez anos, nos municípios de Conceição, Imaculada e Teixeira. p. 28

Lista de Tabelas

- 1 Resultados obtidos com a aplicação dos respectivos testes, Dickey-Fuller(estacionariedade) e Mann-Kendall(tendência), para as localidades de Conceição, Imaculada e Teixeira. p. 22
- 2 Seleção dos modelos Auto-regressivos e de médias móveis ajustados para o município de Conceição, seguido dos respectivos critérios de avaliação. p. 22
- 3 Seleção dos modelos Auto-regressivos e de médias móveis ajustados para o município de Imaculada, seguido dos respectivos critérios de avaliação. p. 23
- 4 Seleção dos modelos Auto-regressivos e de médias móveis ajustados para o município de Teixeira, seguido dos respectivos critérios de avaliação. . p. 23
- 5 Estimativas dos parâmetros dos modelos selecionados. p. 23

Sumário

1	Introdução	p. 10
2	Material e Métodos	p. 11
2.1	Processos Estocásticos	p. 11
2.2	Estacionariedade	p. 12
2.3	Tendência	p. 14
2.4	Sazonalidade	p. 15
2.5	Modelos Auto-regressivos (AR)	p. 16
2.6	Modelos de Médias Móveis (MA)	p. 17
2.7	Modelos Auto-regressivos e de Médias Móveis (ARMA)	p. 17
2.8	Identificação de modelos	p. 18
2.9	Estimação de Modelos de Séries Temporais	p. 18
2.10	Análise de Resíduos	p. 19
2.11	Previsão em Séries temporais	p. 19
3	Resultados e Discussão	p. 20
4	Considerações Finais	p. 29
	Referências	p. 30
	Apêndice	p. 32

1 Introdução

A região do Sertão paraibano apresenta uma subunidade espacial de natureza individualizada na paisagem, situada na porção ocidental da Paraíba, à retaguarda da Borborema Central e estendendo-se pelo pediplano sertanejo, alcança os alinhamentos de serras que fazem fronteiras com os Estados de Pernambuco, Ceará e Rio Grande do Norte. Que segundo Gonçalves (2012) ela é composta por 7 Microrregiões (Patos, Serra do Teixeira, Piancó, Sousa, Catolé do Rocha, Itaporanga e Cajazeiras) que abrangem 22.466Km^2 representando 39,8% do território paraibano. Esta região é fortemente afetada pelas irregularidades no período chuvoso.

Atualmente, modelos estatísticos aplicados a dados climatológicos tem atraído um especial interesse entre vários pesquisadores, uma vez que o clima interfere diretamente em muitas atividades econômicas, determinando o sucesso ou fracasso de vários empreendimentos, sobretudo os ligados a produção agrícola. Uma modelagem estatística capaz de quantificar e prever um determinado atributo ao longo do tempo é a Análise de Séries Temporais. Sendo assim, é possível se construir modelos de previsão que necessitam basicamente de um vetor de valores observados ao longo do tempo.

O objetivo da análise de séries temporais consiste em elaborar um modelo estatístico que descreva adequadamente o comportamento de um determinado atributo ao longo do tempo, de maneira que as implicações teóricas do modelo sejam compatíveis com as amostras observadas nas séries temporais. A partir do modelo ajustado à série temporal é possível prever a evolução futura da série ou explicar a relação entre os distintos componentes do modelo.

Diante do exposto, o objetivo deste trabalho consiste em aplicar modelos de séries temporais aos totais anuais de precipitação dos municípios de Conceição, Imaculada e Teixeira, no período de 1935 a 2013 a fim de encontrar o modelo que melhor representa seu caráter preditivo.

2 Material e Métodos

No início desta seção serão apresentados os resultados das tendências climáticas para os municípios de Conceição, Imaculada e Teixeira, localizados no Estado da Paraíba, os dados utilizados para realização deste trabalho foram obtidos na Agência Executiva de Gestão das Águas do Estado da Paraíba (AESAs), relativos ao período de 1935 a 2013. Na avaliação da precipitação foram considerados os totais anuais dos municípios estudados, em que foram ajustados modelos de séries temporais, com o objetivo de identificar um modelo capaz de realizar uma previsão climática confiável. As análises foram realizadas com o auxílio do software estatístico R.¹

O primeiro procedimento que deve-se realizar ao analisar um conjunto de dados medidos ao longo do tempo é a parte gráfica. Este procedimento simples costuma ser bastante esclarecedor, permitindo identificar como evolui a tendência da série, se existe ou não sazonalidade e se ocorrem observações aberrantes. Tendo em vista essa primeira análise, segue-se o estudo com a verificação dos pressupostos da série temporal.

2.1 Processos Estocásticos

Conforme Bressan (2004), os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas. Seja T um conjunto arbitrário, um processo estocástico é uma família $Z = \{Z_{(t)}, t \in T\}$, tal que para cada $t \in T$, $Z_{(t)}$ é uma variável aleatória.

O conjunto T é, normalmente, considerado como o conjunto dos inteiros Z , ou conjunto dos números reais (R), e o conjunto de variáveis aleatórias, distribuídas equiespaçadamente no tempo, definidas num mesmo espaço de probabilidades (Ω, A, P) , (MORETTIN; TOLOI, 1987), em que Ω , é o espaço amostral; A são os eventos associados ao espaço amostral e P é uma medida de probabilidade.

Para dizer que um processo estocástico está especificado necessita-se de certas condições,

¹www.r-projet.org

isto é, pressupostos. Sejam t_1, t_2, \dots, t_n elementos quaisquer de T e considerando-se

$$F(z_{(1)}, \dots, z_{(n)}; t_1, \dots, t_n) = P[Z_{(t_1)} \leq z_1, \dots, Z_{(t_n)} \leq z_n].$$

Então, o processo estocástico $Z = \{Z_{(t)}, t \in T\}$ estará especificado se conhecermos as distribuições finito-dimensionais, para todo $n > 1$.

2.2 Estacionariedade

Diniz *et al.* (1998), afirmam que uma série temporal é estacionária se o processo aleatório oscilar em torno de um nível médio constante. Uma série pode ser estacionária durante um período muito longo, mas pode ser estacionária apenas em períodos curtos, mudando de nível ou inclinação. Na prática, a maioria das séries temporais apresentam algum tipo de não estacionariedade, por exemplo, tendência.

A maioria dos procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias, portanto, será necessário transformar os dados originais se estes não formam uma série estacionária. A transformação mais comum consiste em tomar diferenças sucessivas da série original, até se obter uma série estacionária. A primeira diferença $Z_{(t)}$ é definida por

$$\Delta Z_{(t)} = Z_{(t)} - Z_{(t-1)}$$

então, a segunda diferença é

$$\Delta^2 Z_{(t)} = \Delta[\Delta Z_{(t)}] = \Delta[Z_{(t)} - Z_{(t-1)}]; \Delta^2 Z_{(t)} = Z_{(t)} - 2Z_{(t-1)} + Z_{(t-2)}.$$

De modo geral, a n -ésima diferença de $Z_{(t)}$ é dada por

$$\Delta^n Z_{(t)} = \Delta[\Delta^{n-1} Z_{(t-1)}].$$

Normalmente, será suficiente tomar uma ou duas diferenças para que a série se torne estacionária.

Segundo Morettin e Tolo (2006), processos estacionários caracterizam-se pelo comportamento não alterado ao longo do tempo, o processo se desenvolve no tempo em torno de uma média constante ao longo de t . Logo um processo estocástico $Z = Z_{(t)}, t \in T$

é dito estritamente estacionário se todas as distribuições finito-dimensionais permanecem as mesmas sob translações no tempo, ou seja, $F(z_1, \dots, z_n; t_1 + \tau, \dots, t_n + \tau) = F(z_1, \dots, z_n; t_1, \dots, t_n)$, para quaisquer $t_1, \dots, t_n, \tau \in T$. Isto significa que todas as distribuições unidimensionais são invariantes sob translações ao longo do tempo, logo a média e a variância são constantes, isto é: $\mu_{(t)} = \mu$ e $var_{(t)} = var$, para todo $t \in T$.

Segundo Morettin e Tolo (2006), será necessário introduzir suposições simplificadoras, que nos conduza a analisar determinadas classes de processos estocásticos. Assim pode-se ter:

- (a) processos estacionários ou não-estacionários, de acordo com a independência ou não relativamente à origem dos tempos;
- (b) processos normais ou não-normais, de acordo com a função densidade de probabilidade (*f.d.p.*) que caracterizam os processos;
- (c) processos Markovianos ou não-Markovianos, de acordo com a independência dos valores do processo, em dado instante, de seus valores em instantes precedentes.

Testes de Estacionariedade

Segundo Arêdes e Pereira (2008), o teste mais simples para analisar a estacionariedade em séries temporais é dado pela obtenção dos coeficientes de autocorrelação e autocorrelação parcial, a partir dos quais são construídos os respectivos correlogramas: FAC (Função de Autocorrelação) e FACP (Função de Autocorrelação Parcial), que por sua vez representam as inspeções gráficas das defasagens. Este correlograma delimita um intervalo de confiança para os coeficientes no qual as estatísticas da FAC e FACP devem variar entre:

$$IC(95\%) = 0 \pm 1,96 \times \left(\frac{1}{\sqrt{n}}\right),$$

em que n é o tamanho da amostra, 1,96 é o quantil (0,025) da normal padrão.

Souza *et al.* (2006), concluíram que os coeficientes de autocorrelação e autocorrelação parcial fora desse intervalo, exceto para a defasagem um, parecem ser estatisticamente diferentes de zero, sugerindo não estacionariedade da série. Outro tipo de teste amplamente utilizado para a verificação da estacionariedade é o teste de Dickey-Fuller (DF), que testa a hipótese nula da existência de raiz unitária na série. Caso esta hipótese não seja rejeitada, a série possuirá raiz unitária, portanto, não será estacionária.

Em estatística, o teste de Dickey-Fuller foi criado para verificar se um modelo autor-

regressivo tem ou não raiz unitária, para que a série temporal z_t seja estacionária tem-se que obter ϕ que atenda a restrição $|\phi_1, \dots, \phi_n| < 1$. Logo, as hipóteses do teste são

$$H_0 : \phi = 1, z_t \text{ não é estacionária}$$

$$H_1 : |\phi| < 1, z_t \text{ é estacionária}$$

O teste de raiz unitária Dickey-Fuller (DF) estima a seguinte auto-regressão:

$$\Delta z_t = (\rho - 1)z_{t-1} + \varepsilon_t,$$

em que $\Delta = (z_t - z_{t-1})$, ou seja é um operador diferença. Nesse caso, a hipótese nula H_0 é de que exista pelo menos uma raiz unitária, logo a variável não é estacionária. Por sua vez, a hipótese alternativa H_1 é que a variável seja francamente estacionária, nesse caso não há nenhuma raiz unitária. (MARGARIDO; JUNIOR, 2006).

2.3 Tendência

Segundo Berlato *et al.* (1995), a tendência representa o movimento geral de um longo prazo da série, refletindo a evolução global no sentido do crescimento ou decrescimento do nível da série. Para identificar este componente é necessário retirar da série todas as flutuações. Uma série com tendência caracteriza-se por revelar, ao longo do tempo, um comportamento que pode ser linear, não linear, crescente, decrescente ou constante. Pode-se representar esse tipo de série da seguinte forma: $Y_t = \mu_t + \alpha_t; t = 1, 2, \dots, n$ em que o nível $\mu_t = \mu_{t-1} + \tau_{t-1}$, (onde τ_{t-1} é a taxa de crescimento da série no instante t) varia de acordo com a tendência e α_t são observações de um ruído branco.

Teste para Tendência

Para testar a hipótese de tendência na série temporal, sejam as observações y_1, y_2, \dots, y_n componentes de uma série temporal. Pelo teste de Mann-Kendall, então, tem-se interesse em verificar se as observações da série são independentes e identicamente distribuídas, (MORETTIN; TOLOI, 1987), testando-se a seguinte hipótese,

$$H_0 = \text{“As observações da série são independentes e identicamente distribuídas”}$$

$$H_1 = \text{“As observações da série possuem tendência monótona ao longo do tempo”}.$$

Sendo assim, sob H_0 a estatística do teste é dada por:

$$S = \sum_{k=1}^{n-1} \sum_{j=k+1}^n \sigma(y_j - y_k)$$

em que

$$\sigma(y) = \begin{cases} 1, & \text{se } y > 0 \\ 0, & \text{se } y = 0 \\ -1, & \text{se } y < 0 \end{cases}$$

2.4 Sazonalidade

Figueredo (2008), define sazonalidade como o conjunto dos movimentos ou flutuações com período igual ou inferior a um ano, “sistemático, mas não necessariamente regulares”, que ocorrem em uma série temporal. Para Figueredo (2008), tais movimentos decorrem normalmente das variações climáticas relacionadas às estações do ano, ou a fatores culturais relacionados a efeitos de calendário.

Essas flutuações são consideradas por muitos autores como ruídos de curto prazo que devem ser eliminados por meio do ajuste sazonal, Silva e Arthr (2007). O ajuste sazonal é o processo que estima e remove os efeitos sazonais de uma série, usualmente, pela decomposição da série em tendência, ou ciclo tendência, componente sazonal e resíduos ou componentes irregulares (FIGUEREDO, 2008). A série resultante de tal processo é denominada de série dessazonalizada ou série ajustada sazonalmente.

É importante reconhecer a presença do componente sazonal, estimá-lo e removê-lo (tal processo é conhecido como ajustamento sazonal), para então analisar o comportamento da tendência de longo prazo da série. De forma geral, os estudos tradicionais sobre sazonalidade tentam decompor o fenômeno em três partes, através de:

$$y_t = \text{tendência} + \text{sazonalidade} + \text{irregularidade}$$

Na qual o componente de tendência representa o movimento de longo prazo. O movimento irregular reflete movimentos não-sistemáticos e residuais. Isolando-se os efeitos da tendência e dos erros não-sistemáticos, pode-se então captar os efeitos sazonais.

Teste para Sazonalidade

Conforme Morettin e Toloí (1987), dois enfoques devem ser observados antes da realização do teste para sazonalidade, paramétrico e não-paramétrico, e antes de usar qualquer um deles é conveniente eliminar tendência ou sazonalidade, se ela estiver presente na série.

No caso dos testes não-paramétricos, uma possibilidade é usar o teste de Kruskal-

Wallis, o qual toma em H_0 a não existência de sazonalidade, que é testada através da seguinte estatística

$$T_1 = \frac{12}{N(N+1)} \sum_{j=1}^k \frac{R_j^2}{n_j} - 3(N+1). \quad (2.1)$$

Rejeita-se H_0 quando essa estatística for maior ou igual ao valor crítico T_{1c} , onde T_{1c} é tal que $P_H(T_1 > T_{1c}) = \alpha$, α é o nível de significância do teste.

Na situação dos testes paramétricos, pode-se utilizar um teste F rotineiro a uma análise de variância. O modelo subjacente é

$$Y_{ij} = S_j + e_{ij}, i = 1, \dots, n_j, j = 1, \dots, k,$$

supondo-se que $e_{ij} \sim N(0, \sigma^2)$, independentes. Sob a hipótese nula $H_0 : S_1 = \dots = S_k$, a estatística

$$T = \frac{N - k}{k - 1} \frac{\sum_{j=1}^k n_j (\hat{Y}_j - \hat{Y})^2}{\sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ij} - \hat{Y}_j)^2}$$

tem distribuição $F_{(k-1, N-k)}$.

Os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas. Qualquer que seja a classificação que se realize para os modelos de séries temporais, pode-se ajustar um número considerável de diferentes modelos para descrever o comportamento de uma série particular.

2.5 Modelos Auto-regressivos (AR)

Segundo Padilha *et al.* (2013), Os modelos Auto-Regressivos (AR) foram criados com a ideia de que a presente observação de série Z_t pode ser explicada como uma função das p observações passadas, $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$, onde p determina o número de passos entre as observações passadas e a previsão da próxima observação. A estrutura auto-regressiva geral é expressa por:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$$

em que ϕ_i são os parâmetros da estrutura auto-regressiva, $i = 1, \dots, p$ (ordem da estrutura); a_t é o ruído branco com média zero e variância σ_a^2 .

2.6 Modelos de Médias Móveis (MA)

Segundo Souza *et al.* (2006), os modelos de médias móveis são formados por combinações lineares de ruído branco, a_t , ocorridos no período corrente e nos períodos passados. A estrutura de médias móveis geral é expressa por

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}, \dots - \theta_q a_{t-q}$$

em que, θ_i são os parâmetros da estrutura médias móveis, $i = 1, \dots, q$ (a ordem da estrutura); a_t é o ruído branco com média zero e variância σ_a^2 .

2.7 Modelos Auto-regressivos e de Médias Móveis (ARMA)

Werner e Ribeiro (2003) formalizam a teoria da utilização de componentes auto-regressivos e de médias móveis na modelagem de séries temporais utilizando-se de duas ideias básicas na criação de sua metodologia de construção de modelos: a parcimônia que é a utilização do menor número possível de parâmetros para se obter uma representação adequada do fenômeno em estudo e a interatividade, ou seja, a informação empírica é analisada teoricamente e o resultado deste estágio é confrontado com a prática sucessivas vezes, até que o modelo obtido seja satisfatório.

Segundo Figueredo (2008) o modelo ARMA é formado por uma combinação do modelo AR com o modelo MA, onde Z_t é descrito por seus valores passados e pelo ruído branco corrente e passados.

A estrutura geral do modelo ARMA(p,q) é expressa por:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - \theta_1 Z_{t-1} - \theta_2 Z_{t-2} - \dots - \theta_q Z_{t-q} + a_t$$

em que, ϕ_i são os parâmetros da estrutura auto-regressiva, $i = 1, \dots, p$; θ_i são os parâmetros da estrutura médias móveis, $i = 1, \dots, q$; a_t é o ruído branco.

Segundo Morettin e Tolo (1987), modelos com essa característica são bastante utilizados em algumas áreas, como em Economia, onde é natural o valor de alguma variável no instante t como função de valores defasados da mesma variável. Em outras áreas, como em ciências, física e geografia, o interesse em modelos auto-regressivos reside em outro aspecto que não seja o da previsão: deseja-se estimar o espectro do processo e os

estimadores auto-regressivos são utilizados para tal fim.

2.8 Identificação de modelos

Segundo Souza e Mendonça (1991), construir um modelo de intervenção significa usar a função de transferência para inserir a um modelo os efeitos das mudanças ocorridas na série causadas pelas variáveis exógenas, representadas de eventos externos ao fenômeno em estudo.

A escolha do modelo a ser utilizado é a parte mais difícil, feita principalmente com base nas auto correlações e auto-correlações parciais estimadas, utilizadas para comparar as quantidades teóricas e identificar um possível modelo para os dados.

Primeiramente faz-se a preparação dos dados para atingir a estacionaridade, Morettin e Tolo (1987) sugerem a utilização dos seguintes procedimentos: projeção dos dados em gráficos para verificar a existência de algum padrão; ajustes como deflacionar ou logaritimizá-los, estabilizando a variância; usar a função de auto-correlação (FAC) e a função de autocorrelação parcial (FACP) para verificar a existência de algum padrão nos dados da série; examinar os FAC e FACP para identificar potenciais modelos.

2.9 Estimação de Modelos de Séries Temporais

A partir do trabalho de Luna Ivette e Ballini (2006) alguns critérios para seleção de modelos foram desenvolvidos, reduzindo significativamente a necessidade do julgamento do analista e ao mesmo tempo podendo ser automatizados facilmente em computadores.

Os parâmetros auto-regressivos são lineares, sendo mais simples de se estimar. Pode-se utilizar o método dos mínimos quadrados ordinários que consiste na obtenção dos parâmetros que minimize a soma das diferenças entre os pontos observados na amostra e os pontos estimados pela equação de regressão com os respectivos parâmetros ao quadrado. Já os parâmetros de médias móveis não são lineares, tornando a sua estimação mais difícil. Utiliza-se nesse caso o método da máxima verossimilhança que consiste em encontrar estimadores que gerem valores que mais se assemelhem aos valores da amostra.

2.10 Análise de Resíduos

A escolha do melhor modelo consiste em ajustar consecutivos modelos, em ordem crescente, e selecionar o modelo que fornece o menor valor do critério (AIC, BIC, EQM). Este critério é uma estatística que consiste de um termo da penalidade e outro da soma de quadrado dos resíduos, onde a penalidade do número de observações é uma função crescente do número de parâmetros do modelo.

2.11 Previsão em Séries temporais

A última etapa a ser executada na modelagem em séries temporais, consiste em realizar a previsão. Ou seja, testa-se o potencial do modelo em prever os potenciais valores futuros para a série estudada. A previsão a ser realizada pode assumir dois aspectos. Num momento ela pode ser usada para prever valores futuros, que ainda não existem. Em outro momento pode haver também a realização de previsões acerca dos valores já existentes dentro da série estudada. O modelo selecionado na etapa de identificação poderá ser corrigido na etapa de estimação, quando a significância dos parâmetros for analisada, com vistas à obtenção das previsões (MORAES *et al.*, 2011).

O método de previsão em séries temporais têm sido aplicado por décadas nas áreas de economia, processamento digital de sinais, como também na previsão de precipitação (meteorologia) (MORETTIN; TOLOI, 1987). Em particular, ARMA, ARIMA, SARIMA, ARIMAX são métodos clássicos mais usados em séries temporais.

3 Resultados e Discussão

O presente capítulo tem por finalidade apresentar análise acerca das tendências climáticas para os municípios de Conceição, Imaculada e Teixeira localizadas no estado da Paraíba, relativos ao período de 1935 a 2013.

A distribuição da precipitação e tendência obtida pelo teste de Mann-Kendall (Tabela 1) para a localidade de Conceição (Figura 1a), Imaculada (Figura 1b) e Teixeira (Figura 1c) no período de janeiro de 1935 a dezembro de 2013 ratificarão os parâmetros que serão obtidos nos testes subsequentes. Todavia as tendências de crescimento visualizadas, principalmente em Imaculada (Figura 1b) e Teixeira (Figura 1c), não necessariamente farão parte da composição da previsão para períodos próximos, pois se torna importante a análise das séries temporais observando a sucessão de períodos de acréscimo/decréscimo e tendência de valores próximos à média.

Todavia é importante ressaltar a grande contribuição nas análises apresentadas, principalmente no tocante do conhecimento da magnitude, distribuição e sazonalidade da precipitação, nas localidades de estudo. Pois foram verificados padrões distintos, no que se refere a períodos que antecederam os picos de ocorrências das precipitações. Observa-se para Conceição (Figura 1a) uma possível tendência de aumento significativa.

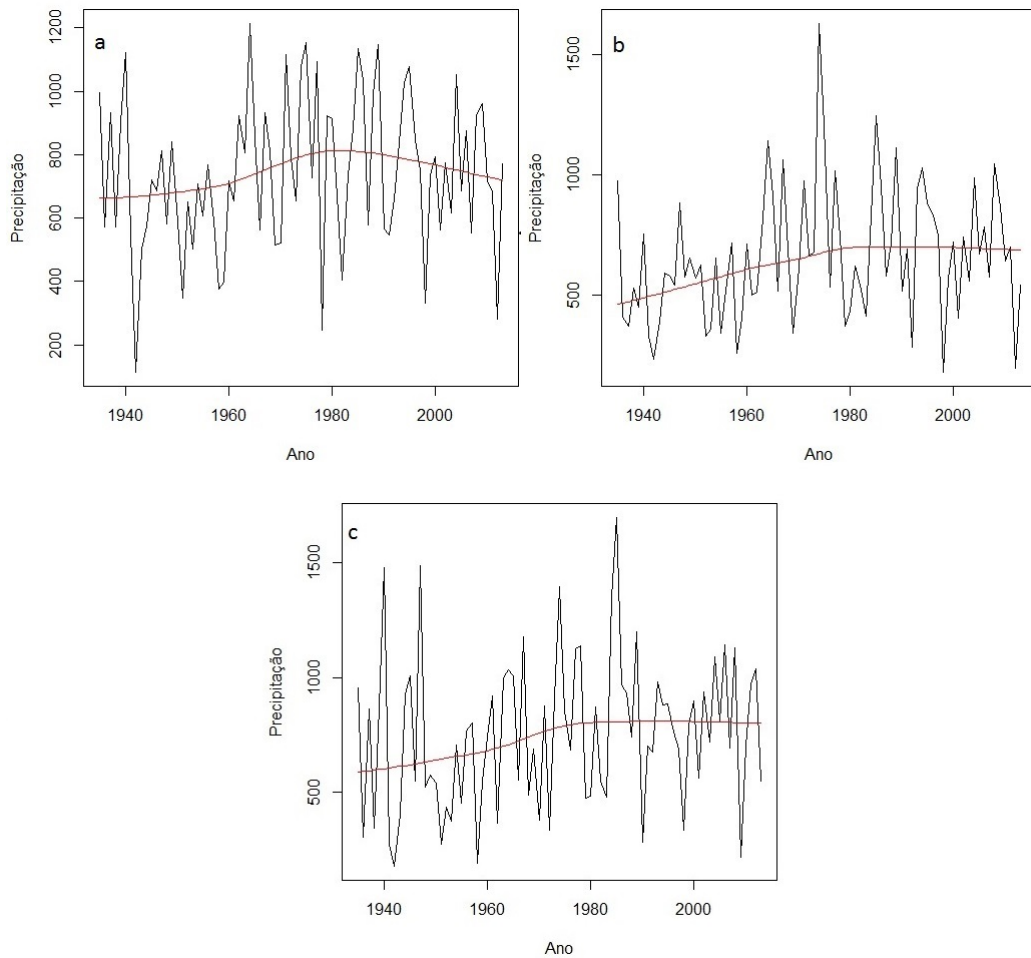


Figura 1: Precipitação acumulada anual (mm) no período de 1935 a 2013 para os municípios de Conceição (a), Imaculada (b) e Teixeira (c).

A Tabela 1 apresenta os resultados das análises de tendência das séries temporais das precipitações para as localidades de Conceição, Imaculada e Teixeira utilizando-se o teste de Mann-Kendall, com nível de significância adotado de 0,05, bem como os resultados de estacionariedade das séries temporais obtidos pelo teste de Dickey-Fuller. A partir dos resultados do teste de Mann-Kendall pode-se verificar que a única localidade que não apresenta tendência significativa é Conceição (p -valor $> 0,05$). Entretanto, pelo teste da raiz unitária de Dickey-Fuller, que verifica a hipótese da série temporal de precipitação ser não estacionária (H_0), observa-se que a hipótese foi rejeitada para todas as localidades. Sendo assim, admite-se que todas as séries temporais são estacionárias.

Tabela 1: Resultados obtidos com a aplicação dos respectivos testes, Dickey-Fuller(estacionariedade) e Mann-Kendall(tendência), para as localidades de Conceição, Imaculada e Teixeira.

Cidades	<i>Dickey – Fuller</i>	<i>p – valor</i>	<i>Mann – Kendall</i>	<i>p – valor</i>
Conceição	-4,032	0,013	0,097	0,201
Imaculada	-4,186	0,010	0,171	0,026
Teixeira	-4,962	0,010	0,156	0,042

Dando sequência as análises, segue-se com o ajuste dos modelos aos dados para os três municípios, os quais pode-se observar nas Tabelas 2, 3 e 4. Podendo concluir que os modelos auto-regressivos e de médias móveis, ARMA(p,q), foram os que melhor se ajustaram aos dados de precipitação.

Tais composições tomam como base o critério de análise dos índices penalizadores Critério de Informação Akaike (AIC), Critério de Informação Bayesiana (BIC) e Erro Quadrático Médio (EQM), sendo assim procuram os menores valores de tais índices para escolha do modelo de previsão da série temporal de precipitação. Observa-se, que, o município de Conceição (Tabela 2), apresentou um ARMA (2,2) com menores valores dos critérios de seleção AIC, BIC e EQM, por parcimônia.

Outra característica dos modelos ARMA(p,q) é a presença do intercepto ($\hat{\beta}_0$), que representa o deslocamento da origem do eixo Y, tanto para efeitos de tendência positiva quanto negativa, os valores do intercepto de cada município em estudo são os seguintes; Conceição (740,53), Imaculada (662,90) e Teixeira (756,08) . Observa-se que a localidade de Imaculada (Tabela 3) apresentou um ARMA (3,2) com valores dos critérios de seleção AIC =1.106,94 e BIC = 1.121,53. Para o município de Teixeira (Tabela 4), apresentou um ARMA (3,3) com valores dos critérios de seleção AIC = 1.143,78 e BIC = 1.142,73.

Tabela 2: Seleção dos modelos Auto-regressivos e de médias móveis ajustados para o município de Conceição, seguido dos respectivos critérios de avaliação.

Modelo	$\hat{\sigma}^2$	$\hat{\beta}_0$	EQM	AIC	BIC
ARMA(2, 2)	48830	740,53	220,97	1092,52	1106,74
ARMA(1, 1)	54021	740,70	232,42	1093,08	1106,56
ARMA(1, 2)	54006	740,63	232,39	1095,06	1106,91
ARMA(2, 1)	54082	740,58	232,95	1095,17	1107,02

Tabela 3: Seleção dos modelos Auto-regressivos e de médias móveis ajustados para o município de Imaculada, seguido dos respectivos critérios de avaliação.

Modelo	$\hat{\sigma}^2$	$\hat{\beta}_0$	EQM	AIC	BIC
ARMA(1, 1)	66032	663,12	256,98	1123,53	1109,05
ARMA(1, 2)	65625	662,84	256,17	1110,64	1122,48
ARMA(2, 1)	65648	662,54	256,21	1110,67	1122,52
ARMA(3, 2)	59166	662,90	243,24	1106,94	1121,53

Tabela 4: Seleção dos modelos Auto-regressivos e de médias móveis ajustados para o município de Teixeira, seguido dos respectivos critérios de avaliação.

Modelo	$\hat{\sigma}^2$	$\hat{\beta}_0$	EQM	AIC	BIC
ARMA(1,1)	105720	755,50	325,15	1146,14	1155,61
ARMA(3,3)	86923	756,08	294,83	1143,78	1142,73
ARMA(2,1)	105280	755,47	324,47	1147,82	1159,67
ARMA(1,2)	105205	755,50	324,35	1147,77	1159,62

Ainda de acordo com as Tabelas 2, 3 e 4 pode-se observar uma redução considerável nas variâncias estimadas para os modelos que apresentaram menores valores de AIC e BIC, colaborando assim, para diminuição do EQM.

A tabela a seguir mostra as estimativas dos parâmetros ϕ e θ , mias o intercepto dos modelos ARMA selecionados.

Tabela 5: Estimativas dos parâmetros dos modelos selecionados.

Cidades	$\hat{\phi}_1$	$\hat{\phi}_2$	$\hat{\phi}_3$	$\hat{\theta}_1$	$\hat{\theta}_2$	$\hat{\theta}_3$	$\hat{\beta}_0$
Conceição	-1,30	-0,80	-	1,48	1,00	-	740,54
Imaculada	0,15	-0,75	0,40	0,12	0,77	-	662,91
Teixeira	0,22	-0,01	0,71	0,02	-0,02	-1,00	756,08

Pode-se destacar alguns artigos que ajustaram modelos de séries temporais a dados climáticos, por exemplo, o artigo de Silva *et al.* (2008) referente a previsão da temperatura média mensal de Uberlândia - MG, descrevendo-se os componentes necessários para uma previsão subsequente. Os referidos autores identificaram a presença de 32 componentes de tendência e sazonalidade.

No artigo de Chechi e Bayer (2012) é possível destacar modelos univariados de séries

temporais na previsão das temperaturas médias mensais de Erechim - RS, destacando-se a classe de modelos ARIMA. Modelos do tipo SARIMA foram ajustados e, por meio dos critérios BIC e EQM foi selecionado o modelo SARIMA (3,1,0)(0,1,1) para fins de previsão.

No trabalho de Chechi e Sanches (2013), o modelo ARMA foi aplicado em uma série temporal, considerando dados de temperatura e precipitação em Portugal de 1856 a 1994, num total de 138 anos. Os resultados obtidos na utilização do modelo ARMA em longas séries temporais, nesses casos, as séries de temperatura e precipitação, mostraram-se extremamente eficientes com resultados muito próximos dos dados reais, demonstrando boa confiabilidade no modelo.

Biase e Silva (2013) procuraram analisar o comportamento das séries temporais de temperatura na cidade de Nossa Senhora da Glória (SE), e utilizando do modelo ARIMA os autores verificaram que a variação da temperatura não é regular, ao longo do ano, demonstrando que o trimestre janeiro, fevereiro e março possuem maior variação. Os resultados mostraram, ainda, que as temperaturas no mês de março apresentaram os maiores índices de variação.

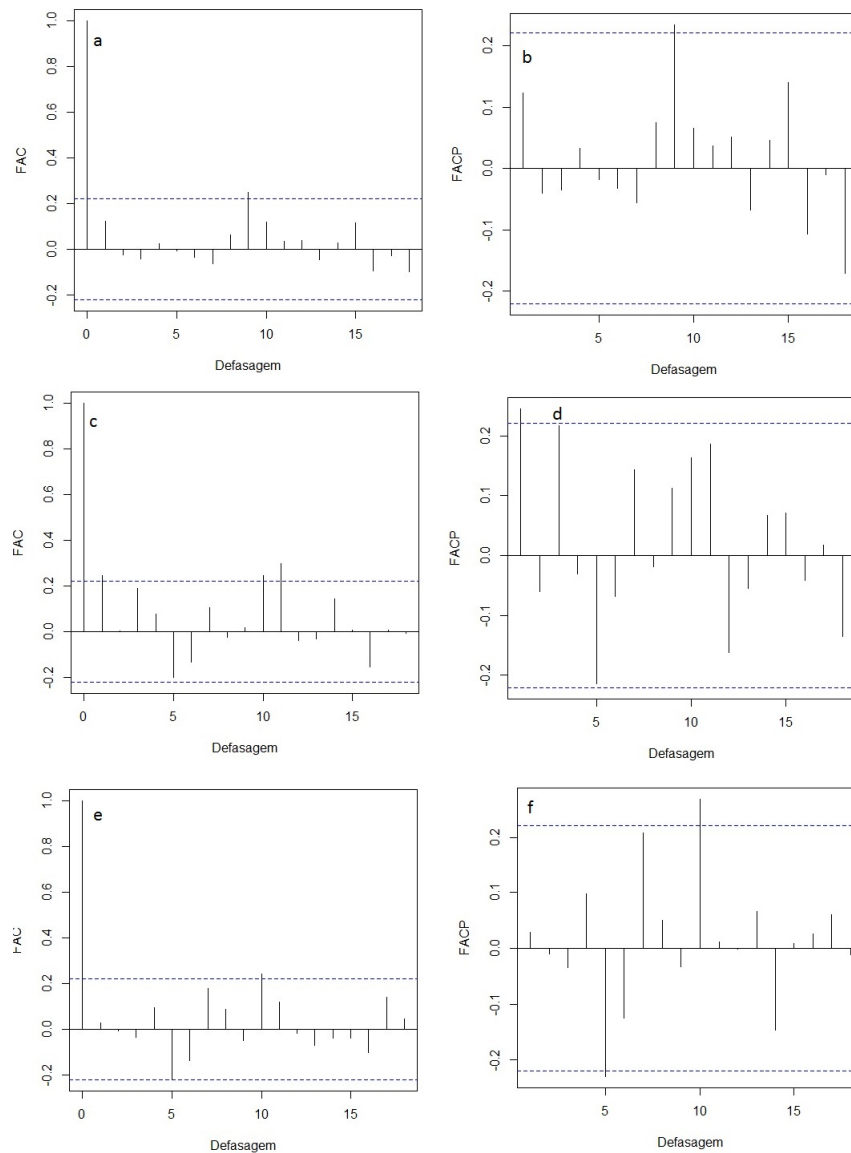


Figura 2: Funções de autocorrelação (FAC)(a,c,e) e funções de autocorrelações parciais (FACP)(b,d,f) para os municípios de Conceição, Imaculada e Teixeira, respectivamente.

Pelos gráficos das FAC's e FACP's, pode-se concluir que as séries são estacionárias, uma vez que seus valores tendem a zero com a FAC contendo dois lag's significativo e a FACP declinando, tem-se a sugestão de um modelo ARMA (2,2) no município de Conceição Figuras 2a e 2b. Nas Figuras 2c e 2d, município de Imaculada, a sugestão é de um modelo ARMA (3,2) com a FAC contendo três lag's significativo e a FACP declinando. Por fim, nas Figuras 2e e 2f, município de Teixeira, o modelo sugerido trata-se também de um ARMA (3,3), com o FAC apresentando três lag's significativos e a FACP declinante.

Para análise de diagnóstico do modelo, utilizou-se o teste de Ljung-Box, apresentados

nas Figuras 3b, 3d e 3f para as localidades de Conceição, Imaculada e Teixeira, respectivamente. O teste Ljung-Box verifica a falha do ajuste de um modelo de série temporal. O teste é aplicado aos resíduos de uma série temporal após o ajustamento de um modelo $ARMA(p, q)$ aos dados. O teste examina as autocorrelações dos resíduos. Se as autocorrelações forem muito pequenas, concluí-se que o modelo não exhibe falha significativa de ajuste.

Analisando-se os resultados apresentados na Figura 3 percebe-se que os resíduos padronizados encontram-se entre os valores -3 e 3 . Em relação ao correlograma dos resíduos do modelo, pode-se observar que o mesmo não apresenta auto-correlação significativamente diferente de zero em nenhuma defasagem, indicando um bom ajuste do modelo e que o mesmo conseguiu captar a auto-correlação serial. Já em relação aos p -valores do teste de Ljung-Box apresentados graficamente para m diferentes defasagens, todos os valores estão acima de 5%, indicando que não rejeita-se a hipótese nula de que as m primeiras auto-correlações dos erros são iguais a zero. Desta maneira, conclui-se que o modelo descreve adequadamente os dados, validando o seu uso para traçar previsões.

As Figuras 3a, 3c e 3e, apresentam a Função de Auto-correlação residual dos modelos ajustados aos dados de Precipitação das localidades de Conceição, Imaculada e Teixeira, respectivamente. Estes resultados evidenciam o comportamento de um ruído branco, pois os coeficientes de auto-correlação ficaram dentro dos limites de confiabilidade.

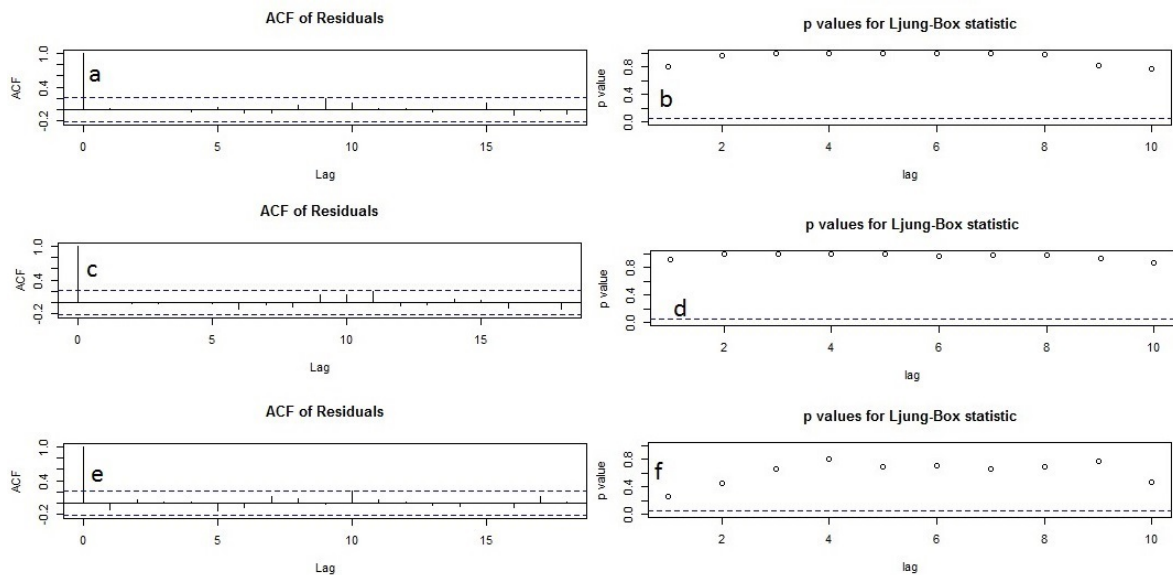


Figura 3: Funções de autocorrelação dos resíduos(FAC)(a,c,e) e Estatística de Ljung-Box(b,d,f) para os municípios de Conceição, Imaculada e Teixeira.

Partindo-se da interpretação da Figura 3, é possível detectar, em geral, um comportamento aceitável das autocorrelações nas variâncias residuais com a utilização dos modelos ARMA. No entanto, Oliveira *et al.* (2014) ao ajustarem modelos ARMA aos dados de precipitação do município de São João do Cariri-PB detectaram ausência de ruído branco, tendo em vista a autocorrelação nas estimativas da variância residual. Os referidos autores conseguiram contornar este problema com o ajuste de modelos GARCH.

A última etapa a ser executada na modelagem consiste em realizar a previsão da série, ou seja, prever os potenciais valores futuros para a série estudada. A previsão a ser realizada pode assumir dois aspectos. Num momento ela pode ser usada para prever valores futuros, que ainda não existem e pode haver também a realização de previsões acerca dos valores já existentes dentro da série estudada. O modelo selecionado na etapa de identificação poderá ser corrigido na etapa de estimação, quando a significância dos parâmetros será analisada, com vistas à obtenção das previsões (CARDOSO, 2001).

Os modelos ARMA são excelentes modelos de previsão de curto prazo (DIAS, 1987). Resultados de análises com esses modelos mostram que os melhores resultados (previsões) são obtidos entre 5 a 10 anos de informação, particularmente na ausência de sazonalidade.

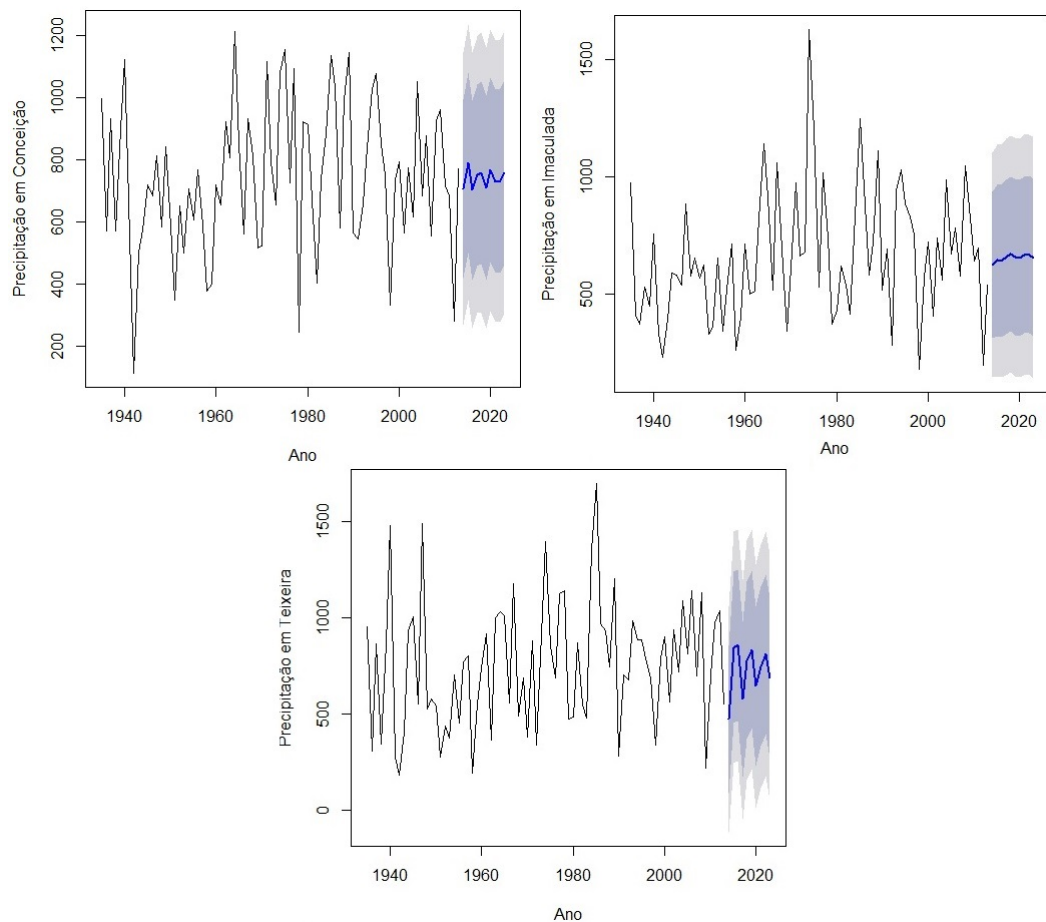


Figura 4: Previsão da precipitação acumulada anual(mm) para os próximos dez anos, nos municípios de Conceição, Imaculada e Teixeira.

Analisando-se a Figura 4 é possível afirmar que a média da precipitação acumulada anual(mm) para os próximos dez anos, apresenta-se em torno da média geral dos dados da série em questão, nos três municípios em estudo. Ainda de acordo com a Figura 4, pode-se observar uma fraca tendência (decaimento) da precipitação acumulada para os próximos anos. Este fato era de se esperar tendo em vista a localização desses municípios, localizados no Sertão paraibano.

Já na região do litoral do Ceará, Fortaleza, Magalhaes e Zanella (2011) buscaram entender o comportamento das variáveis climáticas: temperatura do ar e precipitação. Os referidos autores observaram uma tendência crescente nas chuvas e um comportamento heterogêneo espacial e temporalmente, porém similar a cada ano, podendo causar chuvas excessivas em curtos períodos acarretando sérios problemas a população.

4 Considerações Finais

Utilizou-se a modelagem estatística por meio de séries temporais para dados obtidos na Agência Executiva de Gestão das Águas do Estado da Paraíba (AESAs), relativos ao período de 1935 a 2013, observados no município de Conceição, Imaculada e Teixeira localizadas no alto Sertão paraibano,

Após especificar o modelo que melhor se ajustou aos dados, pôde-se verificar por meio da previsão que os valores obtidos encontram-se num patamar esperado para os próximos 10 anos.

Almeja-se que os estudos desenvolvidos nesta pesquisa sirvam como material de auxílio e estímulo para profissionais da área que invistam em estudos relacionados à identificação de tendências, sobretudo do regime pluvial, e aos possíveis efeitos no risco hidrológico associados aos diferentes componentes dos sistemas de recursos hídricos.

De acordo com os resultados obtidos neste trabalho, conclui-se que para as séries climáticas dos municípios de Conceição, Imaculada e Teixeira, os modelos ARMA(2,2), ARMA(3,2) e ARMA(3,3), respectivamente, se mostraram satisfatórios para análise e previsão dos dados de precipitação, contornando o problema de estacionariedade e tendência, ajudando na leitura a respeito da precipitação anual nos próximos anos.

Referências

- ARÊDES, A.; PEREIRA, M. W. G. Potencialidade da utilização de modelos de séries temporais na previsão do preço do trigo no estado do paran . *Rev. de Economia Agr cola, S o Paulo*, v. 55, n. 1, p. 63–76, 2008.
- BERLATO, M. A.; FONTANA, D. C.; BONO, L. Tend ncia temporal da precipita o pluvial anual no estado do rio grande do sul. *Revista Brasileira de Agrometeorologia, Santa Maria*, v. 3, n. 1, p. 111–113, 1995.
- BIASE, N. G.; SOUSA SILVA, M. I. de. Ajuste de modelos de s ries temporais com interven o para prever o consumo de gasolina no brasil. *Sigmae*, v. 2, n. 1, p. 23–33, 2013.
- BRESSAN, A. A. Tomada de decis o em futuros agropecu rios com modelos de previs o de s ries temporais. *RAE-eletr nica, SciELO Brasil*, v. 3, n. 1, 2004.
- CARDOSO, M. R. A. An lise de s ries temporais em epidemiologia: uma introdu o sobre os aspectos metodol gicos. *Rev. bras. epidemiol, SciELO Public Health*, v. 4, n. 3, 2001.
- CHECHI, L.; BAYER, F. M. Modelos univariados de s ries temporais para previs o das temperaturas m dias mensais de erechim, rs. *R. Bras. Eng. Agr cula. Ambiental, SciELO Brasil*, v. 16, n. 12, p. 1321–1329, 2012.
- CHECHI, L.; OLIVEIRA SANCHES, F. de. An lise de uma s rie temporal de precipita o para erechim (rs) e um poss vel m todo de previs o clim tica analysis of a series of precipitation for erechim (rs) and a method of possible climate prediction. *AMBI NCIA*, v. 9, n. 1, p. 43–55, 2013.
- DIAS, M. Sistemas de mesoescala e previs o de tempo a curto prazo. *Rev. Brasil. Meteor*, p. 2–133, 1987.
- DINIZ, H.; ANDRADE, L. C. M.; CARVALHO, A. C. P.; ANDRADE, M. G. Previs o de s ries temporais utilizando redes neurais artificiais e modelos de box e jenkins. In: *Anais do Simp sio Brasileiro de Redes Neurais*. [S.l.: s.n.], 1998. p. 173–178.
- FIGUEREDO, C. J. *Previs o de S ries Temporais Utilizando a Metodologia Box e Jenkins e Redes Neurais para Inicializa o de Planejamento e Controle de Produ o*. Tese (Doutorado) — Universidade Federal do Paran , 2008.
- LUNA IVETTE E BALLINI, R. e. S. S. T cnica de identifica o de modelos lineares e n o-lineares de s ries temporais. *Sba: Controle e Automa o Sociedade Brasileira de Automatica, SciELO Brasil*, v. 17, n. 3, p. 245–256, 2006.

- MAGALHAES, G. B.; ZANELLA, M. E. Comportamento climático da região metropolitana de fortaleza (dynamics of climate of metropolitan region of fortaleza). *Revista Mercator*, v. 10, n. 23, p. 129–a, 2011.
- MARGARIDO, M. A.; MEDEIROS JUNIOR, H. d. Teste para mais de uma raiz unitária: uso do software sas® na elaboração de uma rotina para o teste dickey-pantula. *Pesquisa e Debate. Revista do Programa de Estudos Pós-Graduados em Economia Política. ISSN 1806-9029*, v. 17, n. 1 (29), 2006.
- MORAES, R. F.; HOLANDA SALES, P. R.; COSTA, J. F. S. Utilização do software estatístico r na previsão de séries temporais: série prêmio de resseguro. *Cadernos do IME-Série Estatística*, v. 30, n. 1, p. 1, 2011.
- MORETTIN, P. A.; TOLOI, C. *Análise de Séries Temporais*. [S.l.]: Blucher, 2006.
- MORETTIN, P. A.; TOLOI, C. M. C. Previsão de séries temporais. *São Paulo: Atual*, 1987.
- OLIVEIRA, M. R. G. d.; OLIVEIRA, E. P. d.; SERAFIM, M. D. V. A. *et al.* Análise estatística da série temporal de precipitação do município de são joão do cariri-pb (pp. 144-148). *Revista da Estatística da Universidade Federal de Ouro Preto*, v. 3, n. 3, 2014.
- PADILHA, J. B.; ROSSI, P.; SCHNEKENBERG, G.; FAM, H. S.; NASCIMENTO, B. M.; SANTOS, G. H. P.; CHEN, R. F. F. Modelagem box-jenkins (arima) para gestão de risco de preço na pecuária de corte do estado do paraná. In: *Congresso Virtual Brasileiro de Administração-CONVIBRA*. [S.l.: s.n.], 2013. p. 12.
- SILVA, L.; ARTHR, C. B. Sazonalidade em séries temporais económicas uma introdução e duas contribuições. 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, SciELO Brasil*, v. 12, n. 5, p. 480–485, 2008.
- SOUZA, V.; MENDONÇA, A. Aplicação e performance da análise de intervenção em séries macroeconômicas brasileiras. *Monografia de Especialização, UFSM*, 1991.
- SOUZA, V. D.; NUÑES, B. H. C.; ALMEIDA, A. N.; EISFELD, C. L. Utilização da metodologia de box e jenkins na previsão do preço futuro pago as exportações paranaenses de madeira serrada. *Universidade Federal do Paraná*, 2006.
- WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos box-jenkins na área de assistência técnica de computadores pessoais. *Revista Gestão e Produção, SciELO Brasil*, v. 10, n. 1, p. 47–67, 2003.

Apêndice

```

# Análise Temporal de PI para o município de Conceição

# Carregando pacotes necessários para análise

require(epicalc)

require(forecast)
require(tseries)
require(urca)
require(stats)
require(GeneCycle)
require(Kendall)
require(adehabitatl)
#Análise gráfica da série temporal

Conceicao = read.table("Precip - Conceicao.txt",header=TRUE)

head(Conceicao)
attach(Conceicao)
precipC = ts(Conceicao$precip, start = c(1935, 1), end = c(2013, 1), frequency=1) plot.ts(precipC,xlab = "Ano",ylab = "Precipitação")
# Aplicando as funções de Autocorrelação (Amostrada e Parcial)

#Função de Autocorrelação

acf(precipC,xlab="Defasagem",ylab="FAC")

#Obtendo apenas os valores da FAC
fac=acf(precipC,xlab="Defasagem",ylab="FAC",plot=FALSE);fac

#Função de Autocorrelação Parcial
pacf(precipC,xlab="Defasagem",ylab="FACP")

#Obtendo apenas os valores da FACP
pacf=pacf(precipC,xlab="Defasagem",ylab="FACP",plot=FALSE);pacf

#Testes para não-estacionariedade: Dickey-Fuller

#Teste de Dickey-Fuller

adf.test(precipC)

#Pelo teste de Dickey-Fuller, rejeita-se a hipótese nula
#de não-estacionariedade, ou seja, a série é estacionária

#Teste de Mann-Kendall para verificar tendência na série temporal, sob a hipótese:

#H0:" As observações da série são independentes e identicamente distribuídas"
#H1:" As observações da série possuem tendência monotônica no tempo"
MannKendall(precipC)
plot(precipC)
lines(lowess(time(precipC),precipC),lwd=1, col=2)
# Série, ACF e PACF após diferença (se necessário diferenciar)
#Ordem da diferença 1
dif.1=diff(precipC,lag=1,differences=1)
par(mfrow=c(3,1))
plot.ts(dif.1)
acf(dif.1)
pacf(dif.1)
#Ordem da diferença 2 dif.2=diff(precipC,lag=1,differences=2)
X11()
par(mfrow=c(3,1))
plot.ts(dif.2)
acf(dif.2)
pacf(dif.2)
# Ajuste do modelo ARMA, tendo em vista que a série é estacionária

```

```

# Os modelos selecionados entre muitos testados segue destacados no trabalho.
modelo1=arima(precipC,order=c(1,0,1));modelo1
summary(modelo1)
modelo2=arima(precipC,order=c(1,0,2));modelo2
summary(modelo2)
modelo3=arima(precipC,order=c(2,0,1));modelo3
summary(modelo3)
modelo4=arima(precipC,order=c(2,0,2));modelo4
summary(modelo4)
modelo5=arima(precipC,order=c(0,0,1));modelo5
summary(modelo5)
modelo6=arima(precipC,order=c(1,0,0));modelo6
summary(modelo6)
modelo7=arima(precipC,order=c(1,1,1));modelo7
summary(modelo7)
modelo8=arima(precipC,order=c(1,1,2));modelo8
summary(modelo8)
modelo9=arima(precipC,order=c(2,1,1));modelo9
summary(modelo9)
modelo10=arima(precipC,order=c(2,1,2));modelo10
summary(modelo10)
modelo11=arima(precipC,order=c(2,2,2));modelo11
summary(modelo11)
modelo12=arima(precipC,order=c(3,1,1));modelo12
summary(modelo12)
modelo13=arima(precipC,order=c(3,2,1));modelo13
summary(modelo13)
modelo14=arima(precipC,order=c(3,2,2));modelo14
summary(modelo14)
modelo15=arima(precipC,order=c(3,2,3));modelo15
summary(modelo15)
modelo16=arima(precipC,order=c(3,3,3));modelo16
summary(modelo16)
modelo17=arima(precipC,order=c(3,1,3));modelo17
summary(modelo17)
modelo18=arima(precipC,order=c(1,2,3));modelo18
summary(modelo18)
#Previsão para os próximos anos
# A tabela com as previsões
prevC=forecast.Arima(modelo4, h=4);prevC
#Gráfico p/previsões
plot.forecast(prevC,main=,xlab="Ano",ylab="Precipitação em Conceição")
plot(prev,type="l", xlab="tempo",ylab="Produtividade",main="Nobres")

```