



**UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE CIÊNCIAS AGRÁRIAS  
CURSO DE AGRONOMIA**

**JOSÉ JURANDEZ BURITI DE MELO JÚNIOR**

**MODELAGEM DE SÉRIES TEMPORAIS APLICADA À PREVISÃO DA  
PRECIPITAÇÃO NAS MICRORREGIÕES DO ESTADO DA PARAÍBA**

**AREIA  
2022**

**JOSÉ JURANDEZ BURITI DE MELO JÚNIOR**

**MODELAGEM DE SÉRIES TEMPORAIS APLICADA À PREVISÃO DA  
PRECIPITAÇÃO NAS MICRORREGIÕES DO ESTADO DA PARAÍBA**

Trabalho de graduação apresentado à  
Coordenação do Curso de Agronomia, do  
Centro de Ciências Agrárias, da Universidade  
Federal da Paraíba, em cumprimento às  
exigências para obtenção do título de  
Engenheiro Agrônomo.

**Orientador(a):** Prof. Dr. Péricles de Farias  
Borges.

**AREIA  
2022**

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

M528m Melo Júnior, José Jurandez Buriti de.

Modelagem de séries temporais aplicada à previsão da precipitação nas microrregiões do estado da Paraíba / José Jurandez Buriti de Melo Júnior. - Areia:s.n, 2022. 38 f. : il.

Orientação: Péricles de Farias Borges.  
TCC (Graduação) - UFPB/CCA.

1. Agronomia. 2. Séries temporais. 3. Previsão. 4. Paraíba. I. Borges, Péricles de Farias. II. Título.

UFPB/CCA-AREIA

CDU 631/635(02)



**UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE CIÊNCIAS AGRÁRIAS  
COORDENAÇÃO DE AGRONOMIA  
CAMPUS II – AREIA - PB**

## **DEFESA DO TRABALHO DE GRADUAÇÃO**

Aprovada em 16/12/2022

**“Título: MODELAGEM DE SÉRIES TEMPORAIS APLICADA À  
PREVISÃO DA PRECIPITAÇÃO NAS MICRORREGIÕES DO  
ESTADO DA PARAÍBA”**

**Autor: JOSÉ JURANDEZ BURITI DE MELO JÚNIOR**

Banca Examinadora:

Prof.º Dr.º. Péricles de Farias Borges  
Orientador(a) – UFPB

Prof.º Dr.º. Lázaro de Souto Araújo  
Examinador(a) – UFPB

Prof.º Dr.º. Walter Esfrain Pereira  
Examinador(a) – UFPB

Aos meus pais, José Jurandez Buriti de Melo e Célia Maria da Silva Melo, por todo apoio e incentivo a minha formação, DEDICO.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus por ter me mantido firme nesta caminhada e me dado força para superar as dificuldades.

Aos meus pais Jurandez e Célia por sempre incentivar minha formação, sem medir esforços para que eu pudesse realizar este sonho, aos meus irmãos Pedro Augusto e Henrique Cesar por todo apoio, aos meus sobrinhos João Pedro e Gabriel pelo carinho e a todos familiares e amigos que com seus incentivos me fizeram chegar à conclusão do meu curso. A minha namorada Elisandra, por todo companheirismo, por dar forças para eu vencer mais essa etapa da minha vida.

A todos os professores do Curso de Agronomia da UFPB, em especial ao meu orientador professor Dr. Péricles, por todos ensinamentos e oportunidades concedidas, contribuindo para minha formação pessoal e profissional.

Aos amigos da Turma 2017.2 Alexandre Ferreira, João Victor, Murilo Paiva, Wagner de Pontes por todos os momentos vivenciados, pela troca de conhecimento, incentivo uns aos outros, sempre buscando o crescimento de todos, e por todas as resenhas. A Allef Souza, colega de turma e companheiro de alojamento durante todo o curso, que considero como um irmão pelos momentos de amizade e apoio.

Em nome de seu Assis do Ru agradeço a todos os funcionários da Centro De Ciências Agrárias.

A todos amigos que fiz na universidade: Bruno Medeiros, Josias, Ricardo, Igor, Matheus, Mayra, Gleiderson, Lucas (Zóba) e Evilásio (villas).

Assim minha eterna gratidão a todos vocês que se fizeram presente para que eu chegasse até aqui, meu muito obrigado.

“Até aqui o Senhor nos ajudou”.  
1 Samuel 7:12

## RESUMO

O objetivo geral deste trabalho foi verificar os dados pluviométricos coletados diariamente no período de janeiro de 1996 a dezembro de 2016 de municípios paraibanos, afim de analisar a capacidade de diferentes modelos de séries temporais na previsão da precipitação mensal para as microrregiões Paraibanas. A metodologia compreendeu a utilização dos seguintes modelos: Modelo Auto-regressivos (AR), Modelos de Médias Móveis (MA), Modelos Auto-regressivos e de Médias Móveis (ARMA), Modelos Auto-regressivos Integrado de Médias Móveis (ARIMA) e Modelos Mistos Integrados Sazonais (SARIMA) em 11 estruturas diferentes baseadas em testes para avaliar a capacidade destes modelos na predição da precipitação mensal, através de software R, versão 4.0.5. A metodologia Box & Jenkins utilizada mostrou-se adequada para a modelagem de dados climatológicos. Confirma-se que o melhor método para o ajuste da série e previsão foi descrito pelo modelo SARIMA. Portanto, a partir da interpretação dos resultados é possível o planejamento de diversas atividades econômicas para as microrregiões do estado da Paraíba, em especial no setor agrícola.

**Palavras-Chave:** séries temporais; previsão; paraíba.

## ABSTRACT

The general objective of this work was to verify the rainfall data collected daily from January 1996 to December 2016 in Paraíba municipalities, in order to analyze the ability of different time series models to predict monthly precipitation for the Paraíba micro-regions. The work's methodology included the use of the following models: Auto-regressive Models (AR), Moving Average Models (MA), Auto-Regressive and Moving Average Models (ARMA), Integrated Auto-Regressive Moving Average Models (ARIMA) and Seasonal Integrated Mixed Models (SARIMA) in 11 different test-based structures to evaluate the ability of these models to predict monthly precipitation, using R software, version 4.0.5. The Box & Jenkins methodology used proved to be adequate for modeling climatological data. It is confirmed that the best method for adjusting the series and forecasting was described by the SARIMA model. Therefore, based on the interpretation of the results, it is possible to plan various economic activities for the micro-regions of the state of Paraíba, especially in the agricultural sector.

**Keywords:** time series; prediction; paraíba.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Microrregiões pluviometricamente homogêneas do Estado da Paraíba.....	18
Figura 2 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Litoral.....	22
Figura 3 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Agreste.....	23
Figura 4 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Brejo.....	24
Figura 5 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Cariri/Curimataú.....	25
Figura 6 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Sertão.....	26
Figura 7 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Alto Sertão.....	27
Figura 8 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para o estado da Paraíba.....	28

## LISTA DE ABREVIATURAS E SIGLAS

AESA	Agência Executiva de Gestão das Águas do Estado da Paraíba
ANA	Agência Nacional de Águas
AR	Modelo Auto-regressivos
ARIMA	Modelos Auto-regressivos e de Médias Móveis
ARMA	Modelos Auto-regressivos Integrado de Médias Móveis
CIAGRO	Centro Integrado de Informações Agrometeorológicas
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
IAC	Instituto Agrônômico de Campinas
IAPAR	Instituto Agrônômico do Paraná
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
MA	Modelos de Médias Móveis
SARIMA	Modelos Mistos Integrados Sazonais

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	10
1.1 Objetivos.....	11
1.1.1 Objetivo geral .....	11
1.1.2 Objetivos específicos.....	11
<b>2 REVISÃO DE LITERATURA</b> .....	12
2.1 Série temporal.....	12
2.2 Modelos para séries temporais .....	13
2.2.1 Modelos autorregressivos (AR).....	13
2.2.2 Modelos de médias móveis (MA) .....	13
2.2.3 Modelos autorregressivos de médias móveis (ARMA).....	14
2.2.4 Modelos auto-regressivos e de médias móveis (ARIMA).....	14
2.2.5 Modelos mistos integrados sazonais (SARIMA) .....	14
2.3 Aplicação de análises de séries temporais a dados meteorológicos .....	15
2.4 Precipitação no Estado da Paraíba.....	16
<b>3 METODOLOGIA</b> .....	18
<b>4 RESULTADOS E DISCUSSÕES</b> .....	20
<b>5 CONSIDERAÇÕES FINAIS</b> .....	29
<b>6 REFERÊNCIAS</b> .....	30
<b>APÊNDICE A – ROTINA DO R</b> .....	34

## 1 INTRODUÇÃO

Desde a antiguidade, o homem tem a necessidade de compreender as condições climáticas de uma região, objetivando revelar os fatores que modificam o tempo. Nos dias atuais, a preocupação está sobre as mudanças climáticas, suas consequências e impactos (ARAÚJO, 2020).

O clima interfere diretamente em muitas atividades econômicas, determinando o sucesso ou fracasso de vários empreendimentos, sobretudo os ligados a produção agrícola. (ALBUQUERQUE, 2015). Para ASSAD et al (2020) as mudanças climáticas devem, portanto, aumentar a variabilidade da produtividade agrícola, a qual poderá ser reduzida drasticamente ao longo da segunda metade deste século na ausência de medidas de adaptação e de mitigação dos impactos ambientais.

De acordo com DANTAS (2016) o estado da Paraíba é susceptível a mudanças climáticas devido à alta variabilidade espaço-temporal da precipitação, proporcionando desta forma eventos de secas como também de precipitação intensa fazendo-se a necessidade de pesquisas onde se possa determinar uma climatologia mais precisa sobre esses determinados eventos.

Buscando compreender cientificamente esta variabilidade, modelos estatísticos aplicados a dados climatológicos tem despertado um especial interesse entre diversos pesquisadores (ALBUQUERQUE, 2015). Neste contexto, os modelos estatísticos utilizados buscam captar o mecanismo gerador da série via dados históricos, coletados ao longo do tempo e referentes a uma variável de interesse. A adequabilidade destes é verificada em função da capacidade de ajustar as principais características de uma série temporal, denominadas como tendência e sazonalidade (MORETTIN & TOLOI, 2006).

A presente pesquisa justifica-se pela relevante importância de compreender a dinâmica temporal das precipitações nas microrregiões do estado da Paraíba, com o intuito de contribuir para a caracterização do regime de chuvas no estado e auxiliar produtores rurais na tomada de decisões em relação ao planejamento e desenvolvimento das atividades agrícolas, tendo em vista que estas decisões possui relação direta com a situação climática das regiões que residem.

A metodologia do trabalho compreendeu a utilização dos seguintes modelos: Modelo Auto-regressivos (AR), Modelos de Médias Móveis (MA), Modelos Auto-regressivos e de Médias Móveis (ARMA), Modelos Auto-regressivos Integrado de Médias Móveis (ARIMA)

e Modelos Mistos Integrados Sazonais (SARIMA) em 11 estruturas diferentes baseadas em testes e para avaliar a capacidade destes modelos na predição da precipitação mensal, através do software estatístico.

## **1.1 Objetivos**

### **1.1.1 Objetivo geral**

Analisar a capacidade de diferentes modelos de séries temporais na previsão da precipitação mensal para as microrregiões Paraibanas no período de janeiro de 1996 a dezembro de 2016.

### **1.1.2 Objetivos específicos**

- Decompor as séries em suas componentes de tendência, sazonalidade e a parte aleatória;
- Analisar o comportamento entre diferentes modelos de séries temporais aplicando à previsão mensal de precipitação em condições do semiárido paraibano;
- Identificar o modelo que melhor representa os dados em estudo;
- Avaliar a capacidade desses modelos de previsão de precipitação na condição de clima semiárido das microrregiões da Paraíba.

## 2 REVISÃO DE LITERATURA

### 2.1 Série temporal

Em um mundo cada vez mais globalizado e competitivo as análises estatísticas têm se tornado cada vez mais importantes, impondo parâmetros e bases para tomar decisões visando o planejamento de ações futuras. Neste contexto, a Análise de Séries Temporais é uma importante ferramenta, onde se destaca a metodologia desenvolvida por Box & Jenkins (1976) (DE MORAES; DE HOLANDA SALES; COSTA, 2011).

De acordo com DA COSTA (2019) pode se definir uma série temporal como sendo um conjunto de observações de uma dada característica coletadas em sequência, sendo a sua maior característica a dependência dos dados vizinhos. As séries temporais podem ser classificadas em contínuas ou discretas, sendo contínuas quando as observações são feitas de modo contínuo no tempo, dado um conjunto  $T = \{t : t_1 < t < t_2\}$  a série será escrita como  $\{X_t : t \in T\}$ . E discretas quando as observações são realizadas em tempos distintos, na maioria das vezes equiespaçados, dada pelo conjunto  $\{X_t = t_1, t_2, \dots, t_n\}$ .

Para realizar a previsão de um comportamento com base na análise de séries temporais considerado o histórico de uma variável ao longo do tempo até o presente momento. Existem quatro fatores principais que a previsão com base em séries temporais busca identificar no intuito de realizar previsões, os chamados componentes de uma série temporal. A tendência, o efeito cíclico, a sazonalidade e os efeitos aleatórios (MOURÃO, 2019)

A Tendência é descrita por GUEDES (2019) como a componente macro de uma série, sendo a indicadora da direção global dos dados (ou o movimento geral da variável). Esse movimento pode ser de crescimento/decréscimo linear ou não-linear.

O efeito cíclico é a componentes que provocam oscilações de subida e de queda nas séries, de forma suave e repetitiva, ao longo da componente de tendência. (RODRIGUES, 2006)

Já a componente sazonalidade representa padrões idênticos, ou quase, que uma série temporal parece obedecer durante uma determinada época do ano. Esse movimento refere-se aos ciclos de curto prazo em torno da tendência. (GUEDES, 2019)

Para MOURÃO (2019) quaisquer dados que não sigam um padrão específico ou que não são regulares são considerados parte das variações irregulares ou efeitos aleatórios. Apresentando movimentos ascendentes e descendentes da série após a ocorrência de um efeito de tendência, um efeito cíclico, ou de um efeito sazonal.

Segundo RODRIGUES (2006) a maioria dos métodos de previsão baseia-se na ideia de que as observações passadas contêm informações sobre o padrão de comportamento da série temporal, quanto a classificação dos modelos de previsão eles podem ser em univariados, os quais têm a previsão dos valores futuros explicados somente pelos valores passados da própria série ou causais, os que levam em conta outras informações relevantes como influentes para a previsão de uma variável.

## 2.2 Modelos para séries temporais

### 2.2.1 Modelos autorregressivos (AR)

Segundo COSTA (2019) a classe de modelos autorregressivos é caracterizada por uma formulação para  $f(\cdot)$  onde apenas as defasagens dos retornos são capazes de modelar o retorno em  $t$ , sendo o termo de erro ( $a_t$ ) um ruído branco estacionário (média zero, variância constante e não-autocorrelacionado). De forma geral, podemos escrever um modelo autorregressivo da seguinte forma:

$$r_t = \phi_0 + \phi_1 r_{t-1} + \phi_2 r_{t-2} + \phi_3 r_{t-3} + \dots + \phi_p r_{t-p} + a_t \quad (1)$$

Esta formulação é conhecida como AR( $p$ ) dado que  $p$  defasagens do retorno foram usadas para especificar a forma funcional linear a ser estimada.

### 2.2.2 Modelos de médias móveis (MA)

De acordo com MORETTIN E TOLOI (2004), o nome média móvel é utilizado porque, a cada período, a observação mais antiga é substituída pela mais recente, calculando-se uma mais recente. Um processo é classificado como sendo de médias móveis de ordem  $q$ , onde o mesmo é denotado por MA( $q$ ), quando apresentar as seguintes características, até um processo aleatório com média  $\mu$  e variância  $\sigma_a^2$ . Com isto, o modelo de médias móveis tem a seguinte representação,

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

onde define-se  $a_t$  como ruído branco da série e  $\theta_j$  é a média móvel

### 2.2.3 Modelos autorregressivos de médias móveis (ARMA)

FRANCO, SOARES & RIBEIRO (2004) definem que os modelos autorregressivos de médias móveis conhecidos como ARMA  $(p,q)$  são constituídos por um componente autorregressivo de ordem  $p$  e por um componente de média móvel de ordem  $q$ . Uma representação deste modelo é dada:

$$\phi_p(B)Z_t = \theta_q(B)u_t \quad (3)$$

Sendo:

$Z_t$  : a série em estudo subtraída de sua média, ou seja,  $Z_t = z_t - \mu$ ;

$B$ : é o operador de retardo, cuja relação,  $Z_{t-1} = BZ_t$  é válida;

$\phi_p(B)$  : componente autorregressivo;

$\theta_q(B)$ : componente da média móvel;

$u_t$  : ruído branco com média zero e variância constante

### 2.2.4 Modelos auto-regressivos e de médias móveis (ARIMA)

Segundo GONZAGA (2022) a combinação entre os métodos de diferenciação e os modelos de autoregressão e média móvel resultam em um modelo ARIMA (AutoRegressive Integrated Moving Average model) não-sazonal, que pode ser descrito matematicamente como:

$$y_t = c + \phi_1 \hat{y}_{t-1} + \dots + \phi_p \hat{y}_{t-p} + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t \quad (4)$$

Onde  $\hat{y}_t$  é a série diferenciada. A equação acima é o que descreve o modelo ARIMA(p, d, q), onde:

- $p$  é a ordem do modelo autorregressivo;
- $d$  é o grau de diferenciação;
- $q$  é a ordem do modelo de média móvel.

### 2.2.5 Modelos mistos integrados sazonais (SARIMA)

Muitas séries temporais apresentam um componente sazonal importante e pode ser preciso modelar este componente também para se obter um modelo mais fidedigno. Para tal

foram desenvolvidos os modelos ARIMA sazonais, conhecidos como SARIMA (PACHECO, 2001)

Segundo FERREIRA (2018) um modelo SARIMA  $(p,d,q)X(P,D,Q)_s$ , sendo  $s$  o período correspondente à sazonalidade, é representado da seguinte forma:

$$\phi(L)\Phi(L)\Delta^d\Delta^s y_t = \theta(L)\Theta(L)\varepsilon_t \quad (5)$$

onde:

$p$  é a ordem do polinômio autoregressivo não sazonal  $\phi(L)$ ;

$P$  é a ordem do polinômio autoregressivo sazonal  $\Phi(L)$ ;

$q$  é a ordem do polinômio de médias móveis não sazonal  $\theta(L)$ ;

$Q$  é a ordem do polinômio de médias móveis sazonal  $\Theta(L)$ ;

$d$  é a ordem de diferença não sazonal;

$D$  é a ordem de diferença sazonal;

$$\phi(L) = (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p);$$

$$\Phi(L) = (1 - \phi_1 L^s - \phi_2 L^{2s} - \dots - \phi_p L^{ps});$$

$$\theta(L) = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q);$$

$$\Theta(L) = (1 - \theta_1 L^s - \theta_2 L^{2s} - \dots - \theta_q L^{qs});$$

$$\Delta = 1 - L; \quad L \text{ é o operador de defasagem tal que } L^n y_t = y_{t-n}$$

No modelo SARIMA, primeiro especificar os valores de  $d$  e  $D$ , parâmetros que tornam a série aproximadamente estacionária, em seguida determinar os valores dos outros parâmetro,  $p, q, P$  e  $Q$  por meio das funções de autocorrelações (DA COSTA, 2019).

E assim, após encontrar os valores de ordem, é possível utilizar um modelo similar aplicado ao processo de média.

### 2.3 Aplicação de análises de séries temporais a dados meteorológicos

Segundo SILVA (2007) os elementos meteorológicos têm desafiado a humanidade diante dos benefícios ou prejuízos no qual o tempo meteorológico se apresenta, levando-nos a uma busca crescente ao seu entendimento através da aplicação de técnicas estatísticas, partindo dos fatores que provocam sua variação independente da sua escala de abrangência.

A utilização das técnicas estatísticas dependerá dos objetivos do problema de pesquisa que está sendo analisado, e da validade de alguns pressupostos necessários aos modelos estatísticos aplicados (SILVESTRE, 2016). A partir da análise de séries temporais

climatológicas é possível se construir modelos de previsão que necessitam basicamente de um vetor de valores observados ao longo do tempo (CHECHI; SANCHES, 2013).

Diversas plataformas nacionais disponibilizam gratuitamente sua base dados meteorológicas referentes às diversas cidades brasileiras, o que vem a facilitar o surgimento de pesquisas que tratam de assuntos gerais e específicos envolvidos desses temas (LIMA et al, 2020). Dentre elas, podemos citar:

- Instituto Nacional de Meteorologia (INMET) ,
- Agência Nacional de Águas (ANA),
- Instituto Agronômico de Campinas (IAC),
- Centro Integrado de Informações Agrometeorológicas (CIIAGRO),
- Instituto Agronômico do Paraná (IAPAR),
- Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA),
- Sistema de Monitoramento Agrometeorológico (AGRITEMPO),
- Instituto Nacional de Pesquisas Espaciais (INPE)

A variáveis meteorológicas com maior interesse para a realização de estudos é a precipitação pluviométrica. DE ALBUQUERQUE et al (2020) analisaram dados referentes a precipitação mensal de chuva no Sertão do Estado de Pernambuco, usando a metodologia de Box&Jenkins, para descrever o comportamento da série por meio de seu modelo de decomposição, verificando a existência dos componentes de sazonalidade e de tendência para cada cidade estudada, e encontrar o modelo que melhor representa seu caráter preditivo. COSTA et al (2015) identificaram que o melhor método para o ajuste da série e previsão da precipitação média mensal da região do brejo do Estado da Paraíba foi descrito pelo modelo SARIMA, o qual obteve um bom ajuste para a variável em estudo.

A habilidade de antecipar como o clima irá mudar de um ano para o outro, possibilita melhor gerenciamento da agricultura, recursos hídricos e atividade pesqueira, além da possibilidade de contribuição nos campos dos transportes, abastecimento, turismo e lazer (SILVA & TAVARES, 2008)

## **2.4 Precipitação no Estado da Paraíba**

O órgão responsável pelas informações da precipitação pluvial na Paraíba é a Agência Executiva de Gestão das Águas do Estado da Paraíba (AESAs), aonde são registradas

as medidas das precipitações diárias, mensais, e anuais para 253 postos pluviométricos distribuídos nos 223 municípios paraibanos (SILVA, 2007).

Segundo FRANCISCO & SANTOS (2017), o estado da Paraíba é caracterizado por dois regimes de chuvas, um de fevereiro a maio, nas regiões do Alto Sertão, Sertão e Cariri/Curimataú; e o outro de abril a julho, no Agreste, Brejo e Litoral.

O clima da Paraíba é tropical úmido no litoral, com chuvas abundantes. À medida que nos deslocamos para o interior, o clima torna-se semi-árido, representando aproximadamente 80% do território paraibano, que corresponde ao Carriri/Curimataú, Sertão e Alto Sertão, sendo, dessa forma, afetado por longas e graves secas (LIMEIRA, 2008). Como exemplo desta heterogeneidade nas precipitação DE ARAÚJO et al.(2003), cita que Cabaceiras, localizada no Cariri paraibano acumula uma média anual em torno de 300mm enquanto que na faixa litorânea, distante aproximadamente 150 km, o total anual de precipitação média é superior a 1500mm.

Segundo DA SILVA et al (2022), a variabilidade da precipitação no estado da Paraíba, também está associada aos padrões da temperatura da superfície do mar (TSM), sobre os oceanos tropicais, os quais afetam a posição e intensidade da zona de convergência intertropical (ZCIT) sobre o Oceano Atlântico, contribuindo na ocorrência ou inibição de precipitação no setor norte do nordeste brasileiro.

### 3 METODOLOGIA

A variável climatológica avaliada foi a precipitação entre os anos de 1996 a 2016, totalizando 20 anos de dados para o Estado da Paraíba. Os dados pluviométricos utilizados foram obtidos pela Agência Executiva de Gestão das Águas do Estado da Paraíba (AESA-PB) e disponibilizados no site do órgão. Os valores de precipitação foram tabulados considerando seus valores diários, obtendo a partir desses dados as médias mensais de cada ano.

Esta pesquisa foi realizada para as seis microrregiões pluviometricamente homogêneas da Paraíba, onde a partir de uma semelhança pluviométrica entre seus municípios SILVA (2007) divide o estado em: Litoral, Brejo, Agreste, Cariri/Curimataú, Sertão e Alto Sertão.

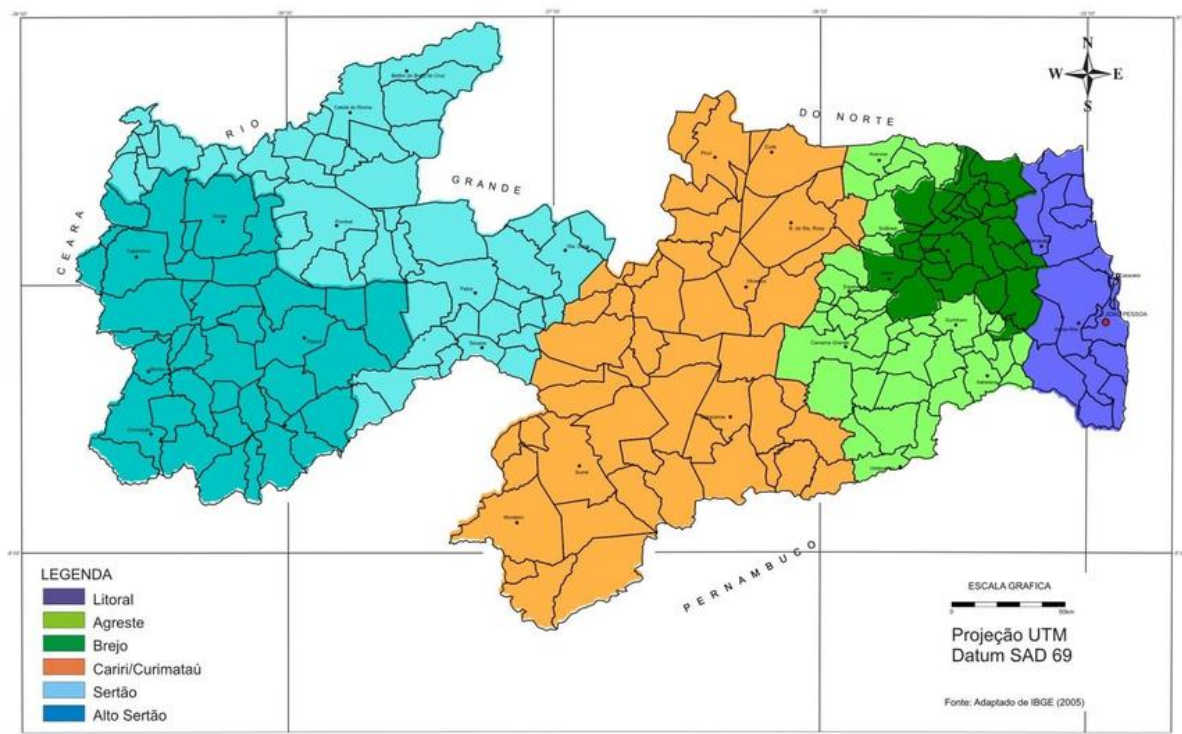


Figura 1 - Microrregiões pluviometricamente homogêneas do Estado da Paraíba. Fonte: DE MEDEIROS (2015)

Nesta pesquisa, modelos AR, MA, ARMA, ARIMA e SARIMA em 11 estruturas diferentes baseadas em testes foram examinados e utilizados para avaliar a capacidade destes modelos na previsão da precipitação mensal. As análises desenvolvidas neste trabalho ocorreram por meio do software R-versão 4.0.5. O procedimento metodológico inicial, ocorreu em virtude da decomposição da série em suas componentes de tendência, sazonalidade e a parte aleatória.

Cada microrregião foi representada pelas médias das precipitações mensais de três municípios (Tabela 1) para a realização dos testes.

<b>Microrregião</b>	<b>Municípios</b>
Litoral	João Pessoa
	Alhandra
	Mamanguape
Brejo	Areia
	Bananeiras
	Guarabira
Agreste	Campina Grande
	Remígio
	Umbuzeiro
Cariri/Curimataú	Cabaceiras
	Cuité
	Sumé
Sertão	Patos
	Pombal
	Uiraúna
Alto Sertão	Sousa
	Princesa Isabel
	Cajazeiras

Tabela 1 – Cidades escolhidas para coleta de dados nas microrregiões da Paraíba

## 4 RESULTADOS E DISCUSSÕES

As decomposições das séries temporais das precipitações médias mensais das principais cidades que fazem parte das microrregiões Paraibanas estão representadas nas Figuras 2A, 3A, 4A, 5A, 6A, 7<sup>a</sup>, e a Figura 8A representa o Estado da Paraíba. De acordo com a decomposição das séries em suas componentes de tendência, sazonalidade e aleatoriedade, é possível notar que as séries possuem um comportamento bastante semelhante e que a componente sazonalidade está bem definida, portanto, pode-se afirmar diante desse pressuposto, que as séries desta componente são estacionárias. Segundo COSTA (2019) uma série temporal é dita estacionária se ela se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável.

Pela análise da componente tendência verificam-se alguns períodos atípicos, em especial a partir de 2012, onde observamos uma drástica redução nos índices de precipitações. Segundo MARENGO, CUNHA e ALVES (2016) sinais de seca começaram a aparecer no nordeste brasileiro em dezembro de 2011 e se intensificaram durante o verão e outono de 2012, teve uma intensidade e impacto não vistos em várias décadas, gerando deficiência hídrica em quase todo o semiárido.

Segundo DANTAS (2016) obter informações concretas das características da série temporal de cada município do estado é de fundamental importância na compreensão da variável estudada, por isso realiza-se primeiro uma análise descritiva dos dados pela decomposição das séries em suas componentes temporais, descrevendo deste modo a presença de tendência, ciclos, sazonalidade e a aleatoriedade.

O ajuste das séries foram realizados através do modelo SARIMA, nos gráficos (Figuras 2B, 3B, 4B, 5B, 6B, 7B, 8B) os valores reais das séries históricas das precipitações médias mensais são demonstrados em linhas na cor preta, já os valores ajustados estão representados na cor vermelha. Observamos que o modelo se mostrou eficaz para realizar previsões, mesmo havendo discordâncias entre os valores extremos.

De acordo com ALBUQUERQUE (2015) o último passo a ser feito na modelagem consiste em realizar a previsão da série, ou seja, prever os prováveis 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.

As Figuras 2C, 3C, 4C, 5C, 6C e 7C representam os gráficos das séries originais, na linha de cor preta, com os valores previstos para os próximos anos da variável precipitação

nas microrregiões Paraibanas, linhas de cor azul, e na Figura 8C para o estado da Paraíba. Através desses gráficos observa-se que o comportamento da precipitação média mensal na Paraíba para os próximos anos será similar ao que vem ocorrendo recentemente. A escolha do modelo mais adequado foi realizado com base no Critério de informação de Akaike (AIC), onde aqueles que apresentaram menores valores de AIC foram considerados com os Melhores.

Compreender o comportamento futuro das precipitações é de grande importância para a agricultura de sequeiro, pois segundo SILVA (2007) a quantidade e a distribuição de chuvas são importantes para as culturas, pois a demanda hídrica deve ser considerada para que as plantas apresentem um bom desenvolvimento, que resultará em boa produtividade.

BARBOSA et al (2015) destaca que é possível obter previsões mais precisas desde que ocorra uma atualização periódica dos dados (semestralmente ou anualmente), isto é, se após o conhecimento de tais valores reais, estes forem incorporados ao conjunto de dados e a análise refeita, no intuito de agregar histórico de observações e captar novos padrões temporais

O presente trabalho vai de encontro com as observações realizada por DE ALBUQUERQUE et al. (2020), que seu estudo verificou-se a aplicação da metodologia Box & Jenkins em dados de precipitação na região do sertão do estado de Pernambuco, onde apresentaram resultados satisfatórios a aplicação de modelos estatísticos a dados climatológicos.

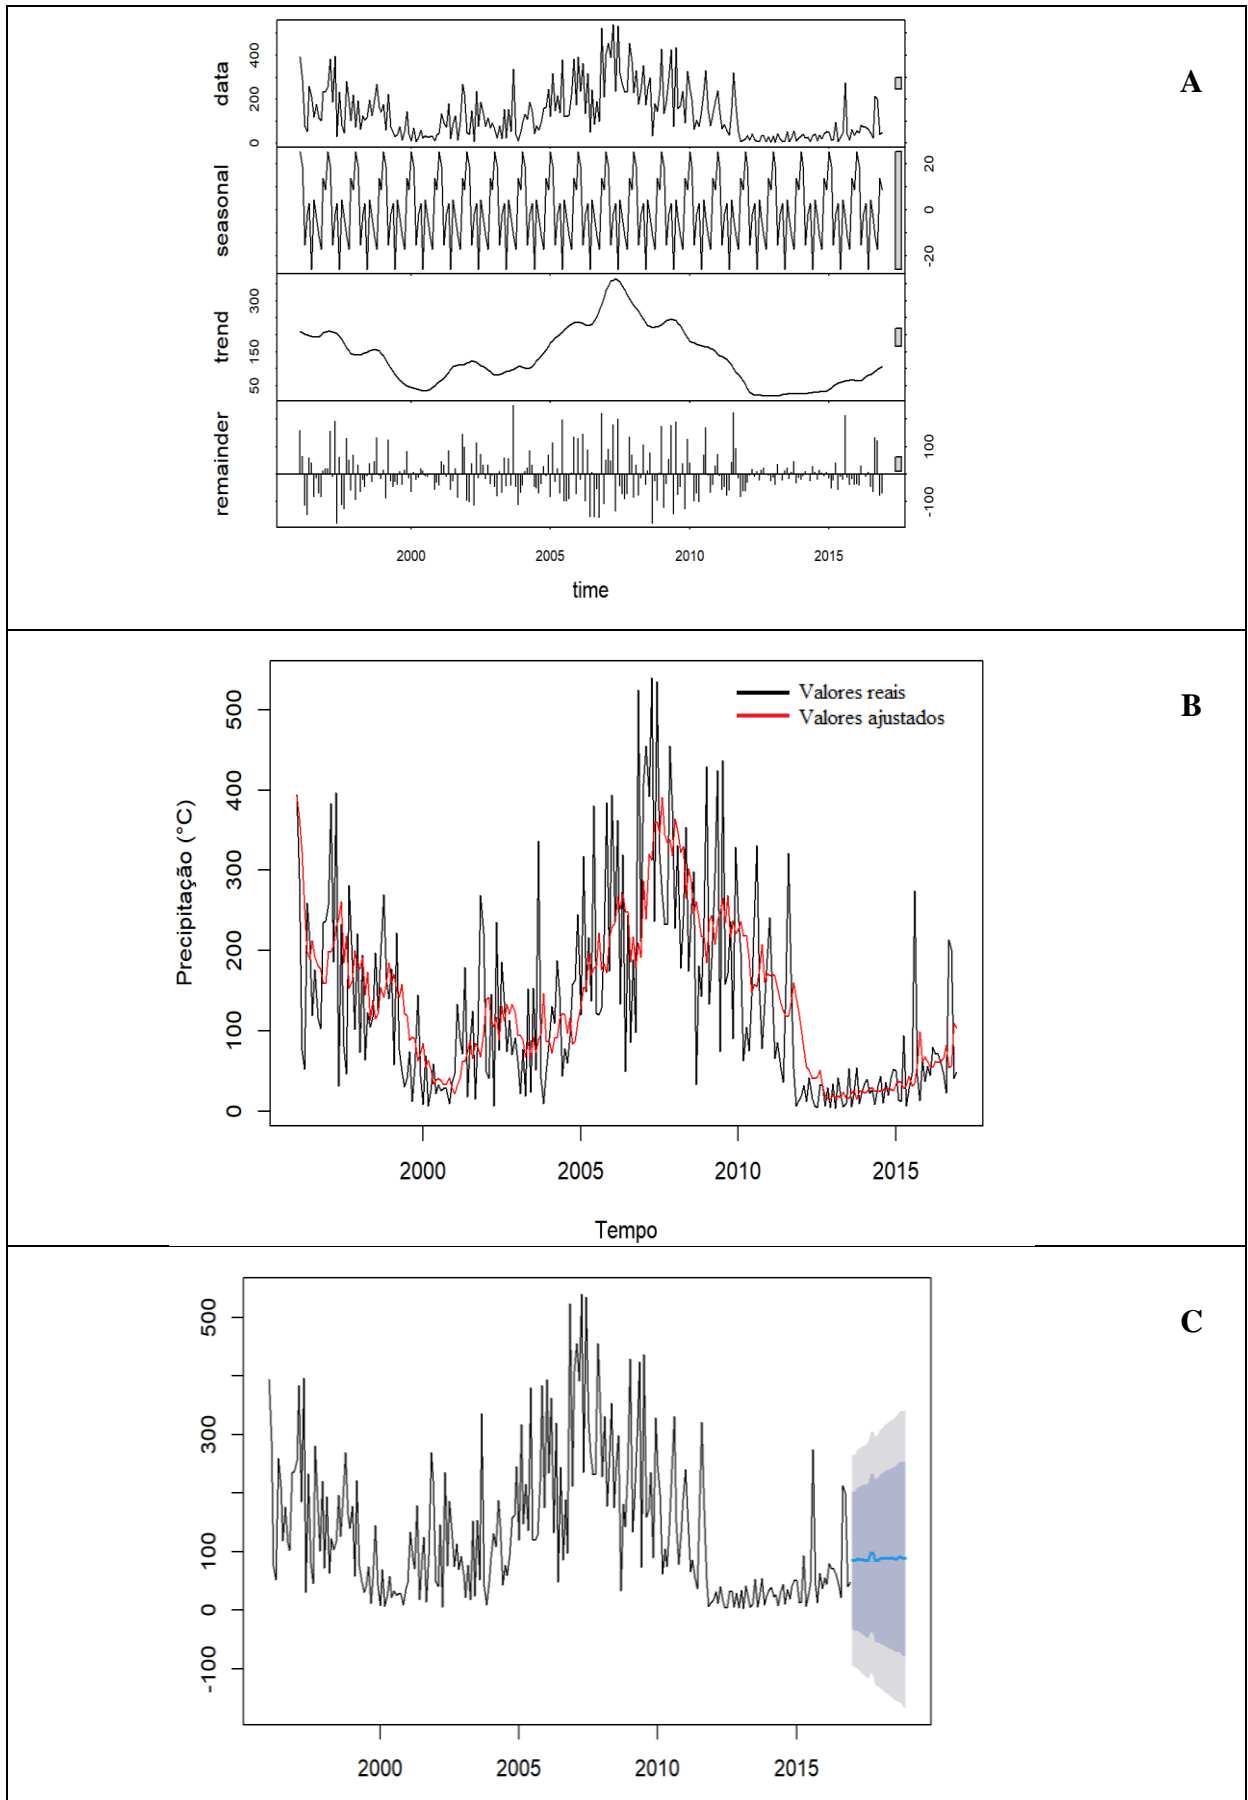


Figura 2 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Litoral. Fonte: Autor

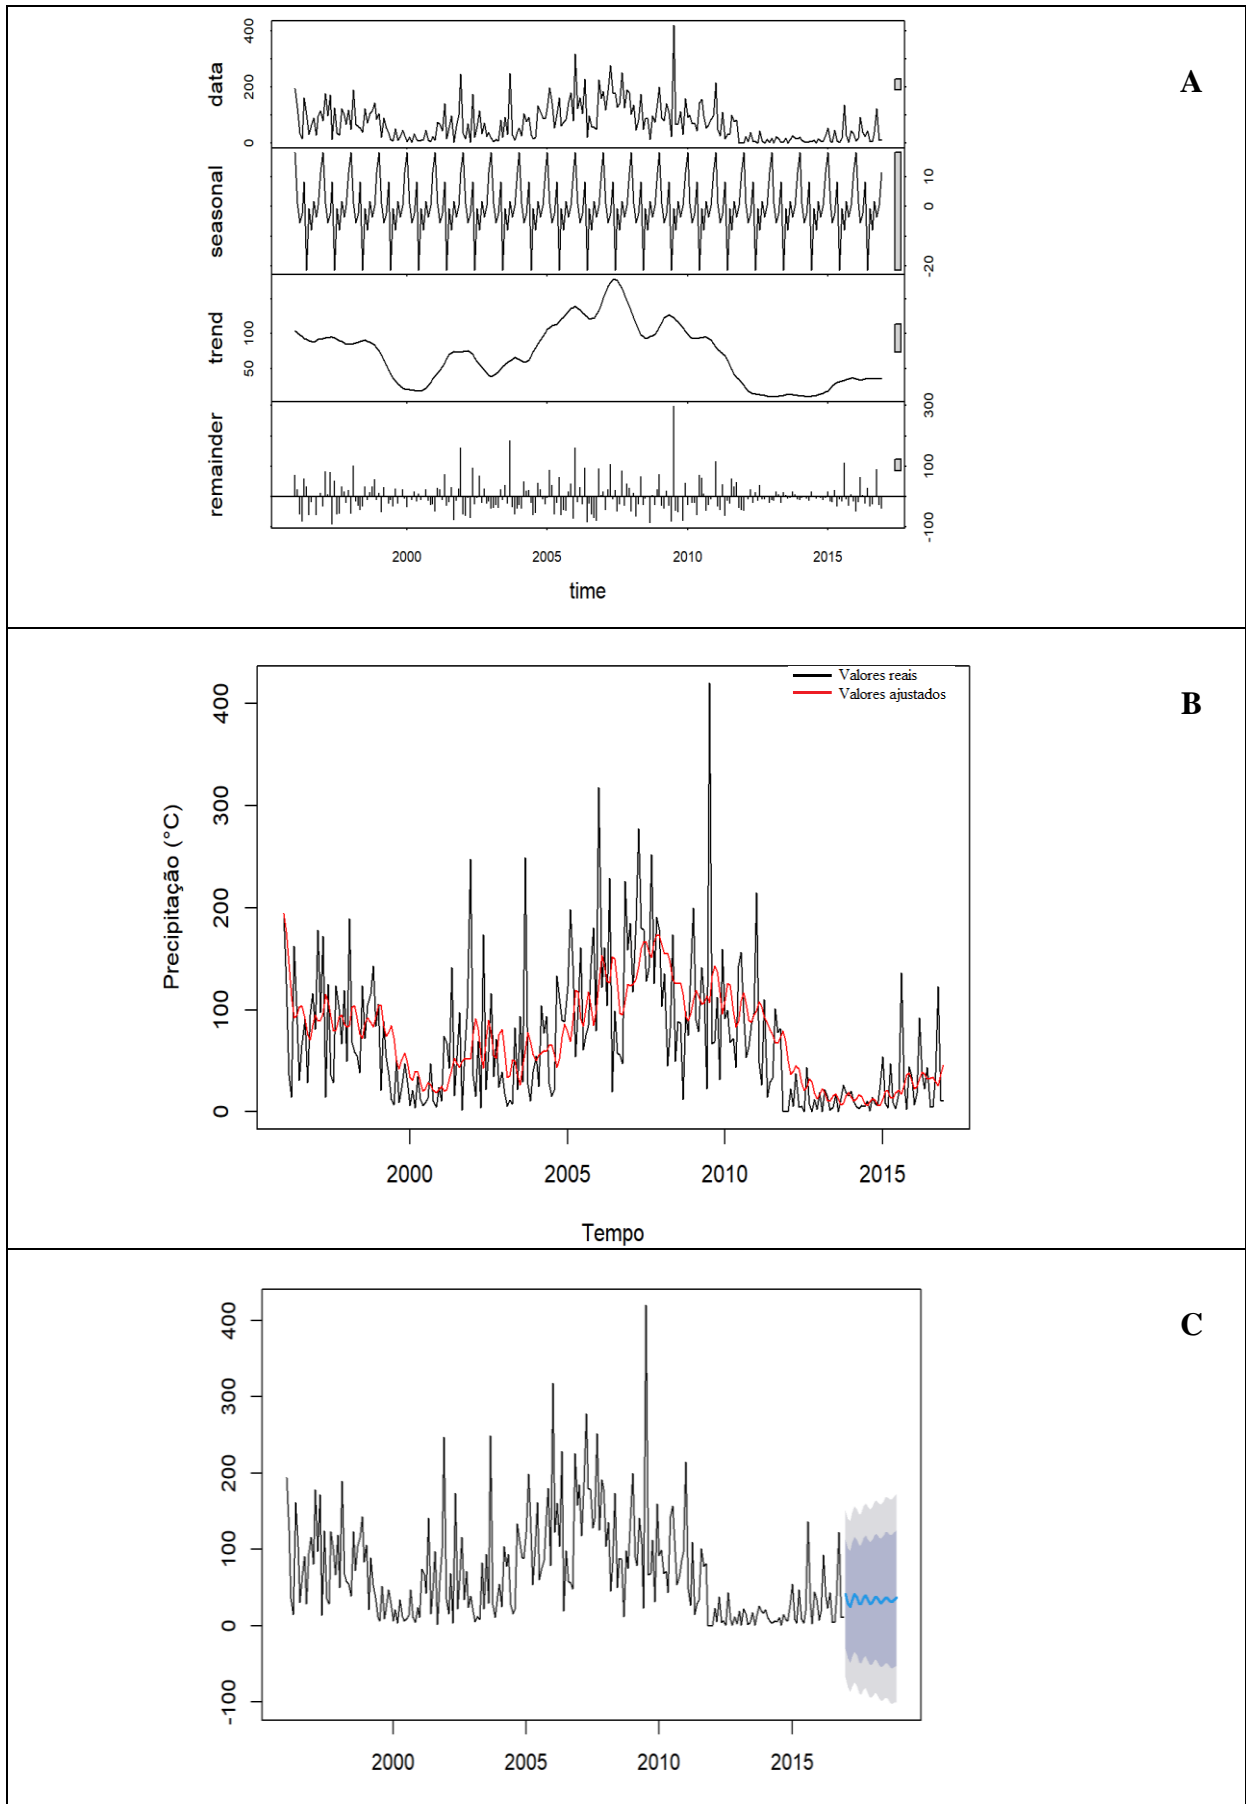


Figura 3 - Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Arima (C) para a microrregião do Agreste. Fonte: Autor.

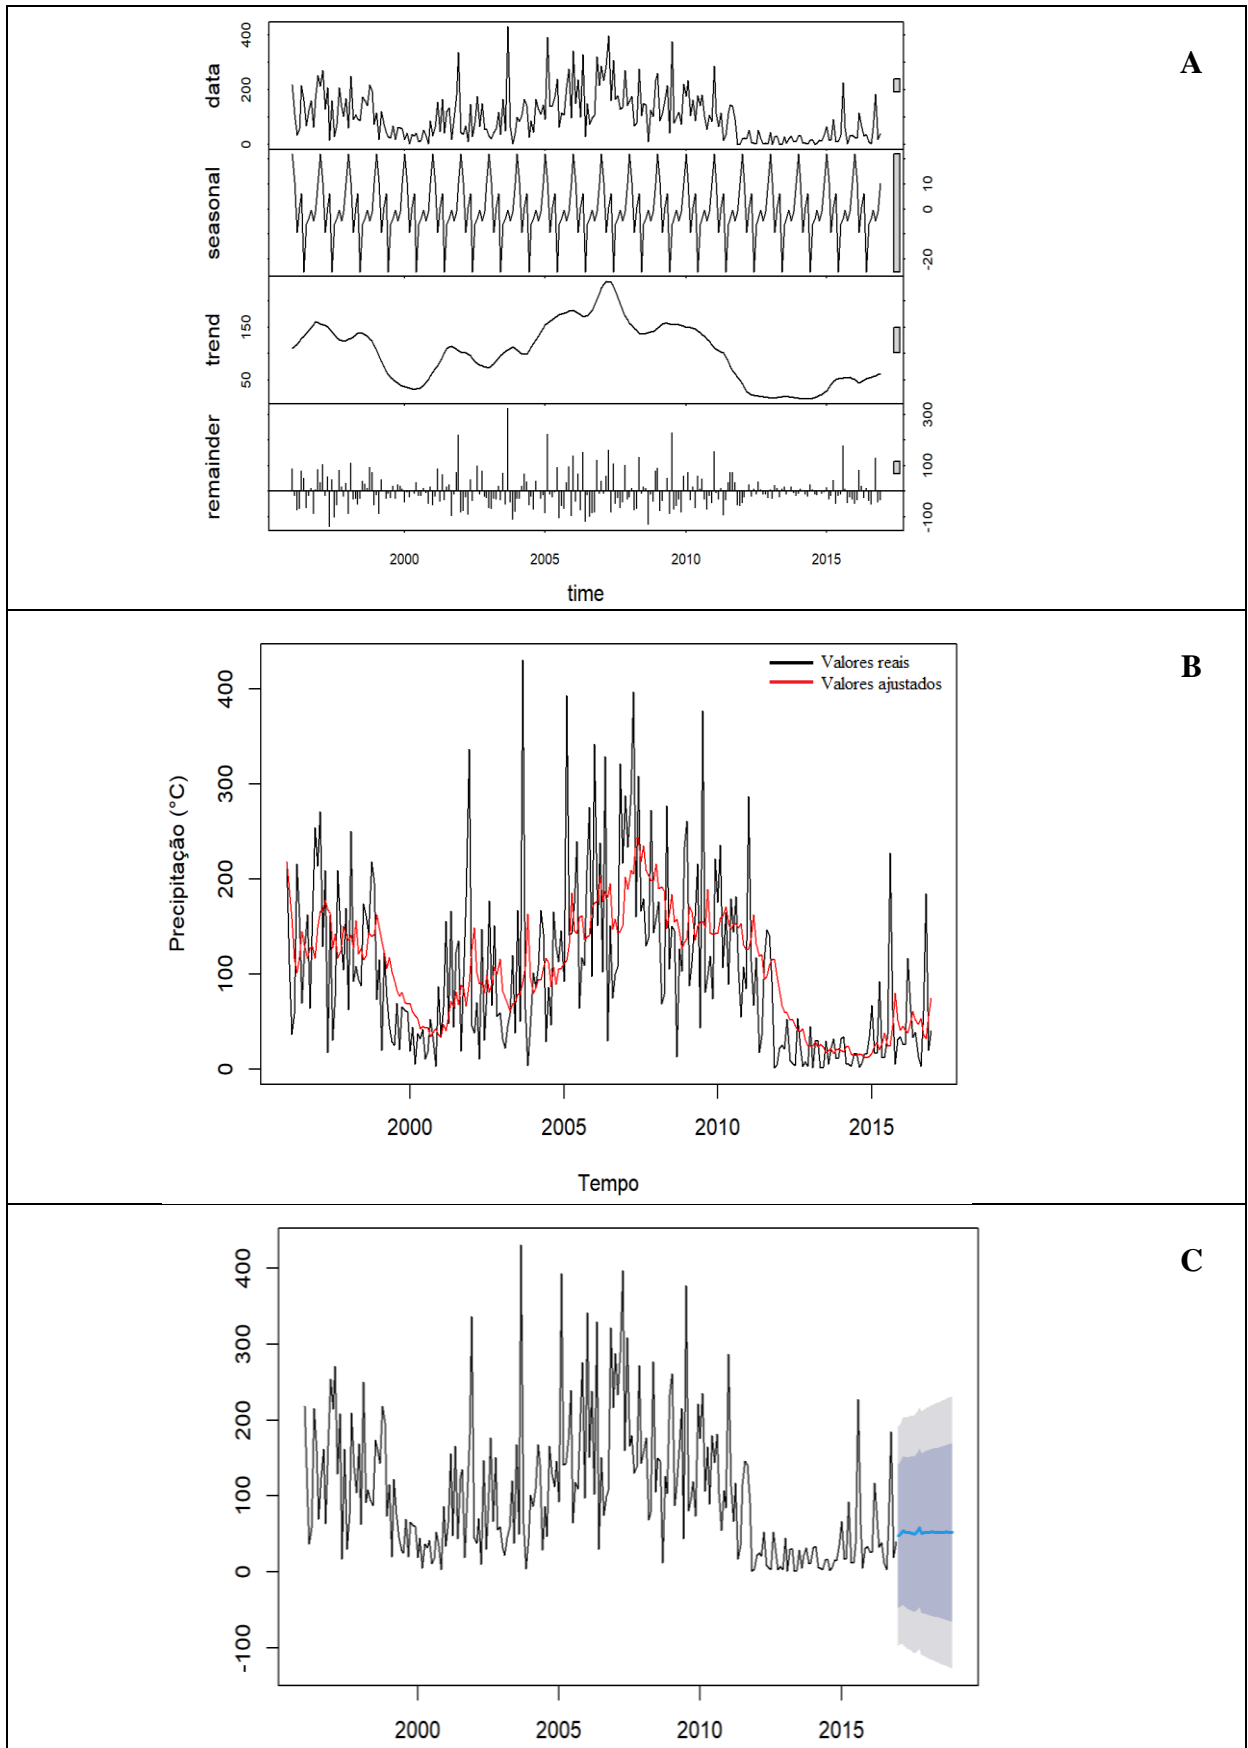


Figura 4 - Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Brejo. Fonte: Autor.

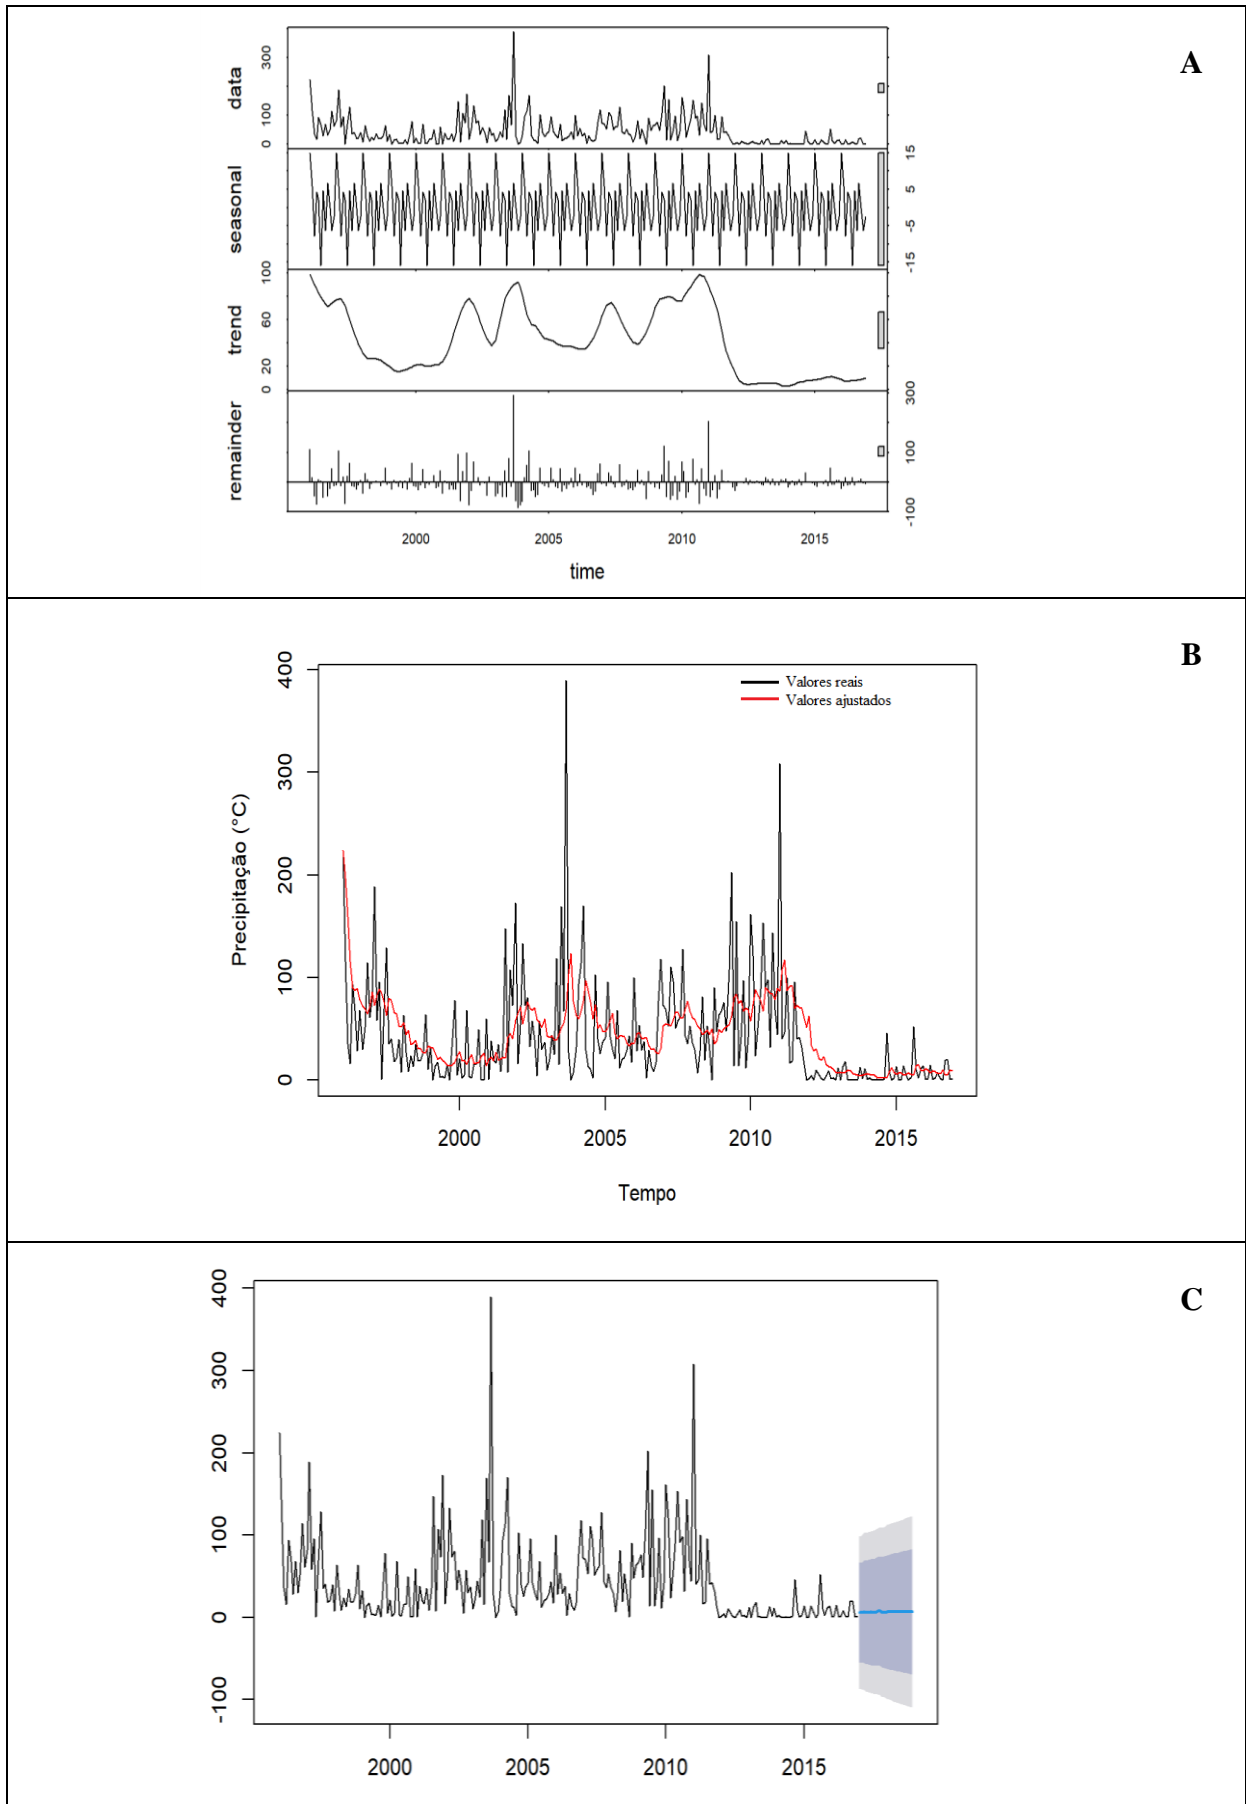


Figura 5 - Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Cariri/Curimatá. Fonte: Autor.

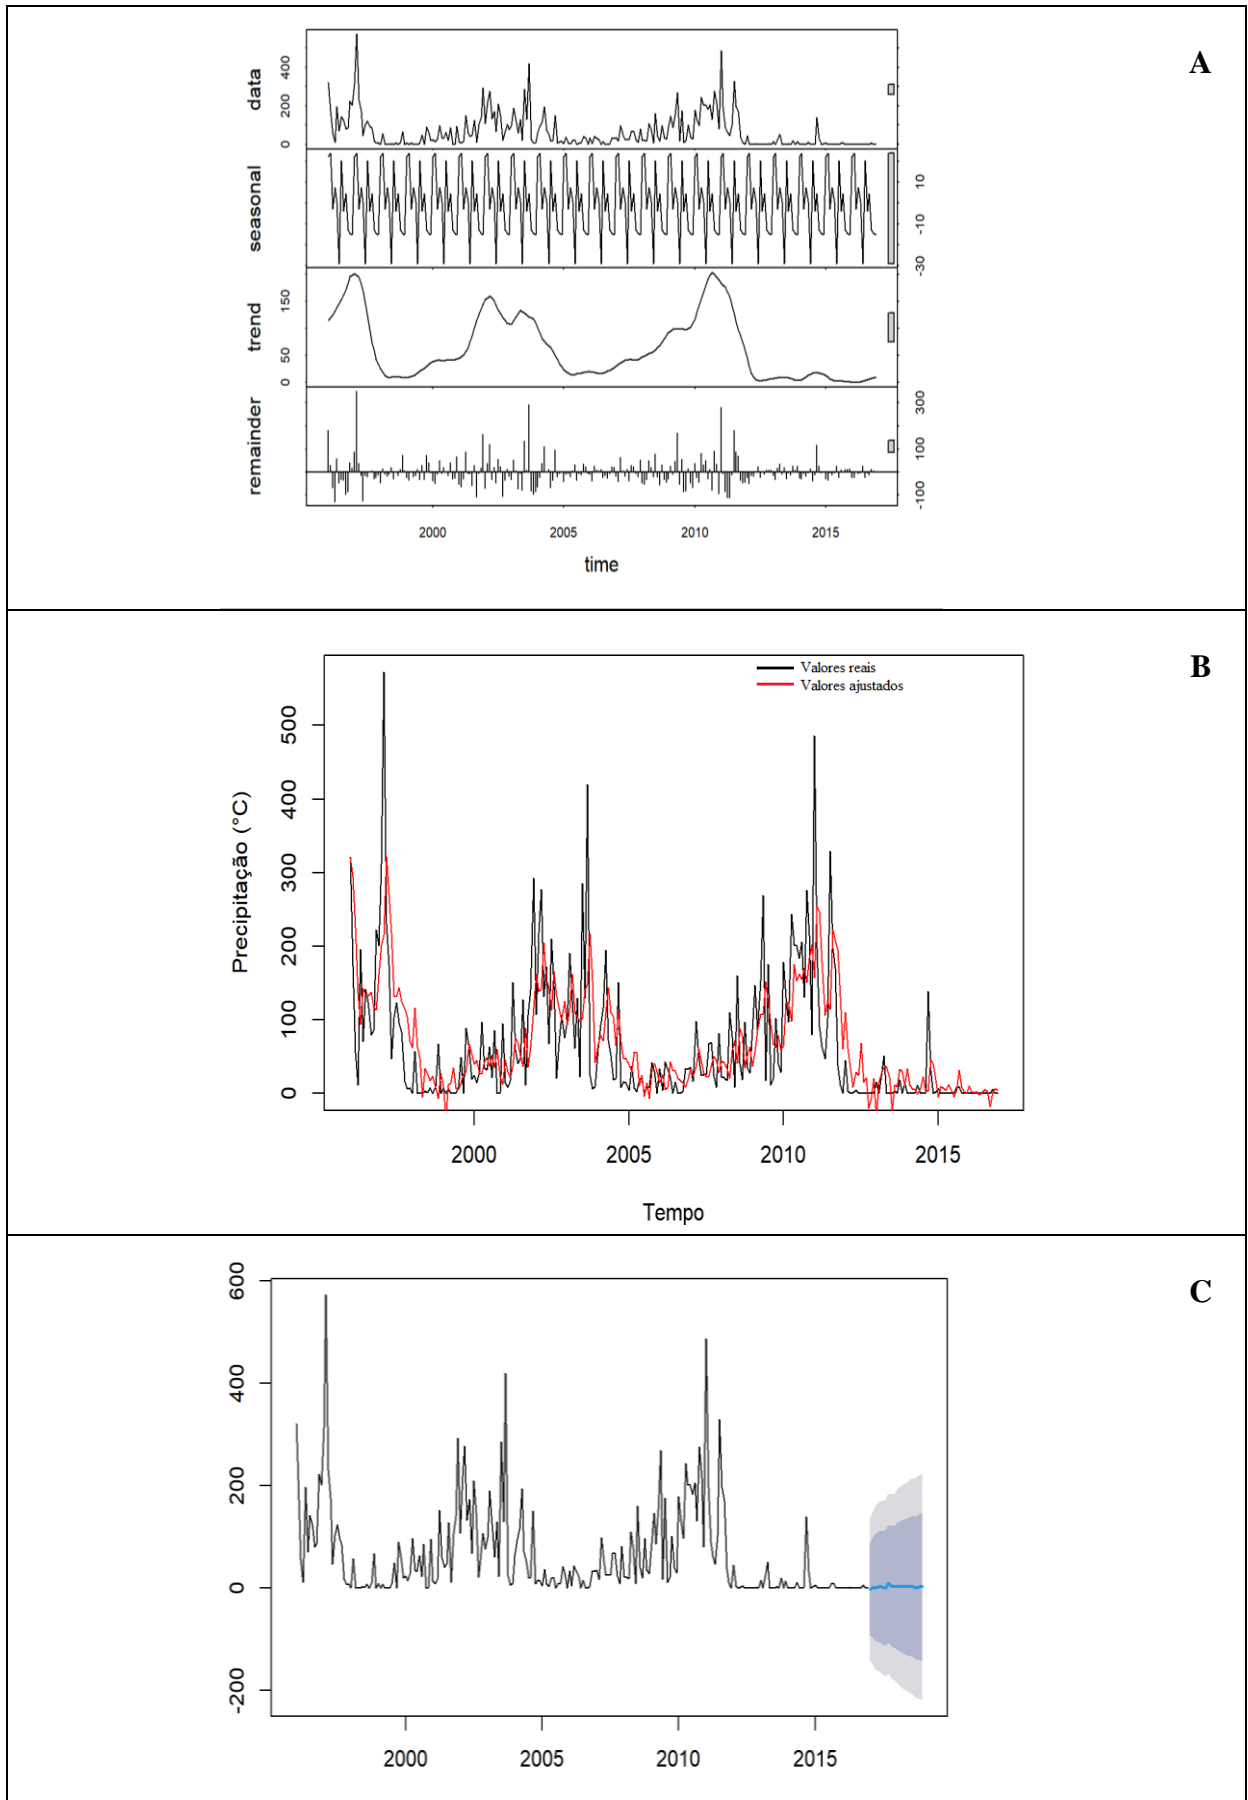


Figura 6 - Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Sertão. Fonte: Autor.

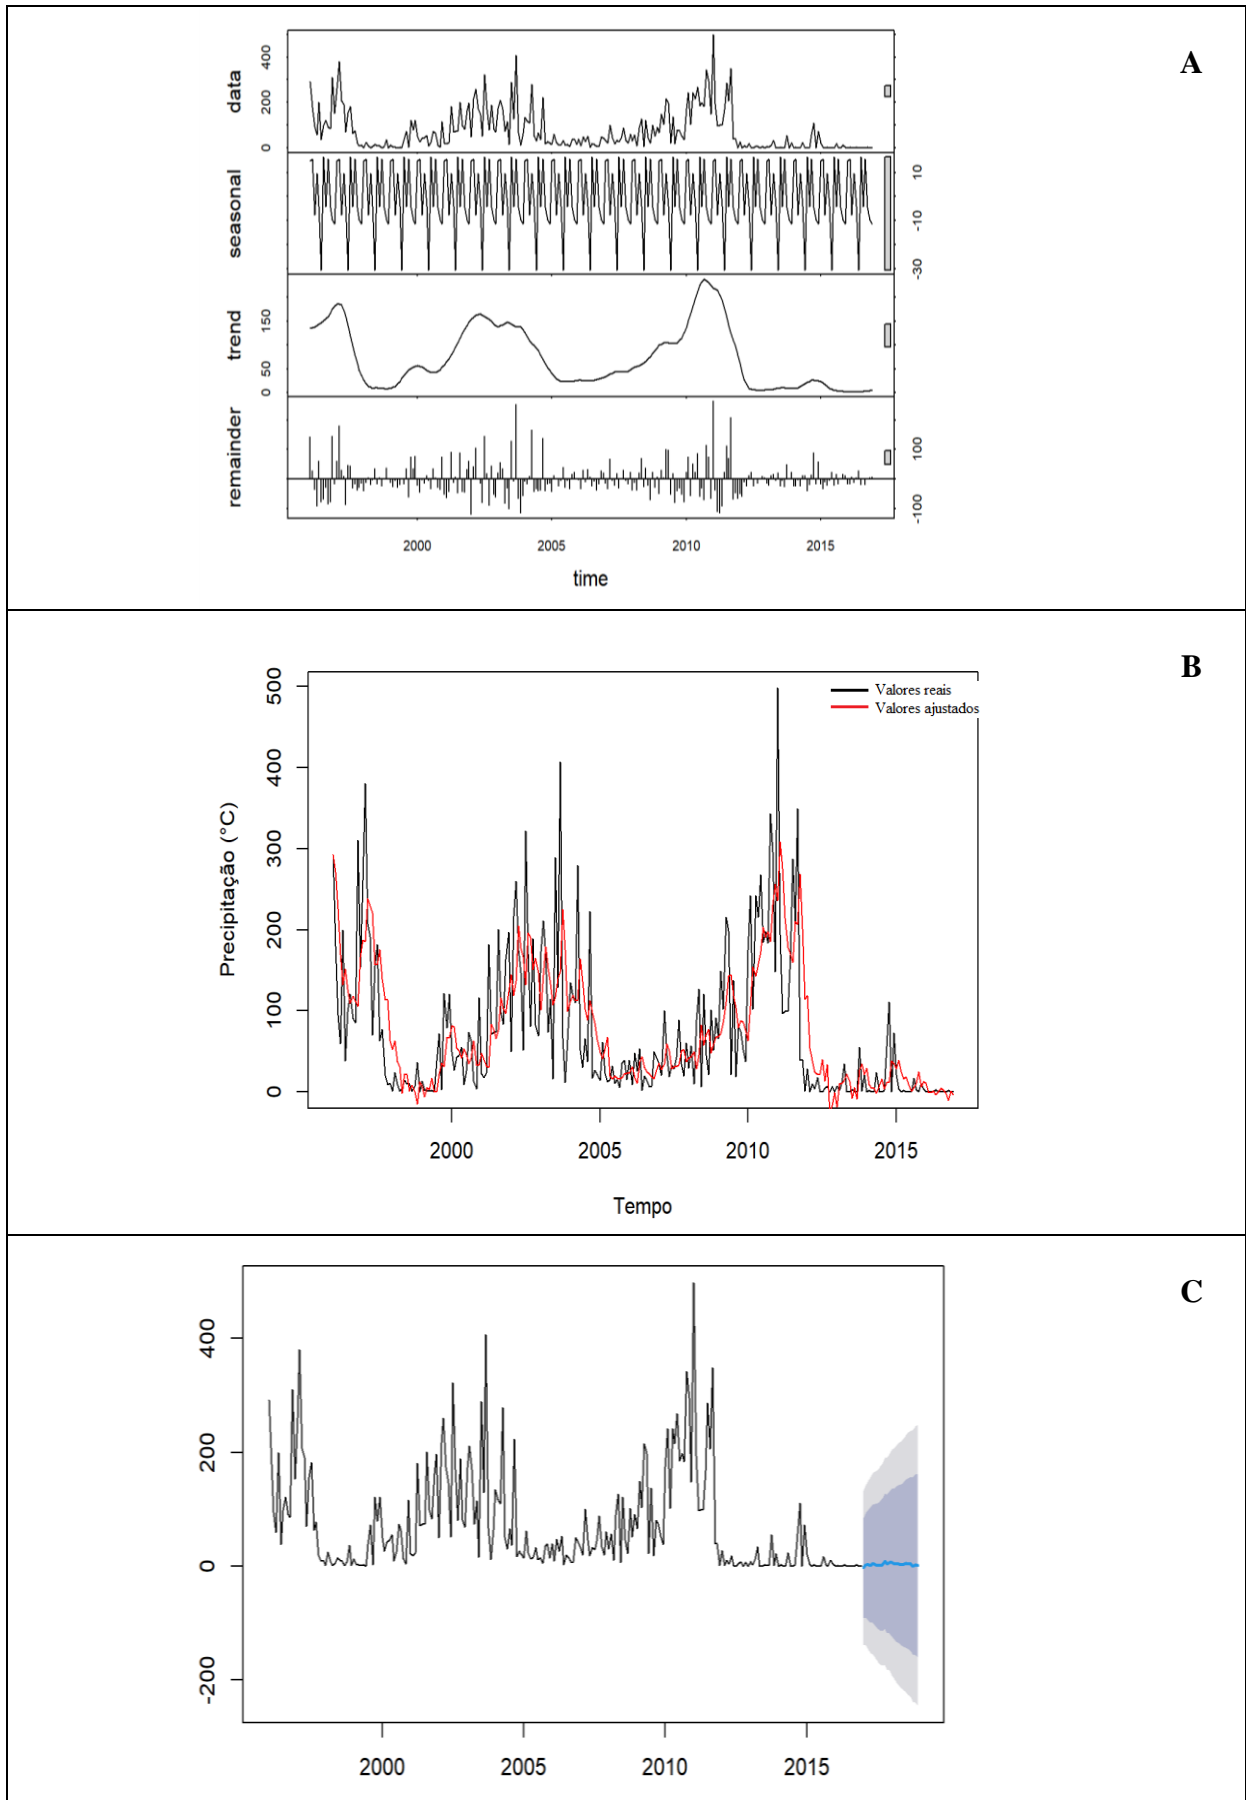


Figura 7 - Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para a microrregião do Alto Sertão. Fonte: Autor.

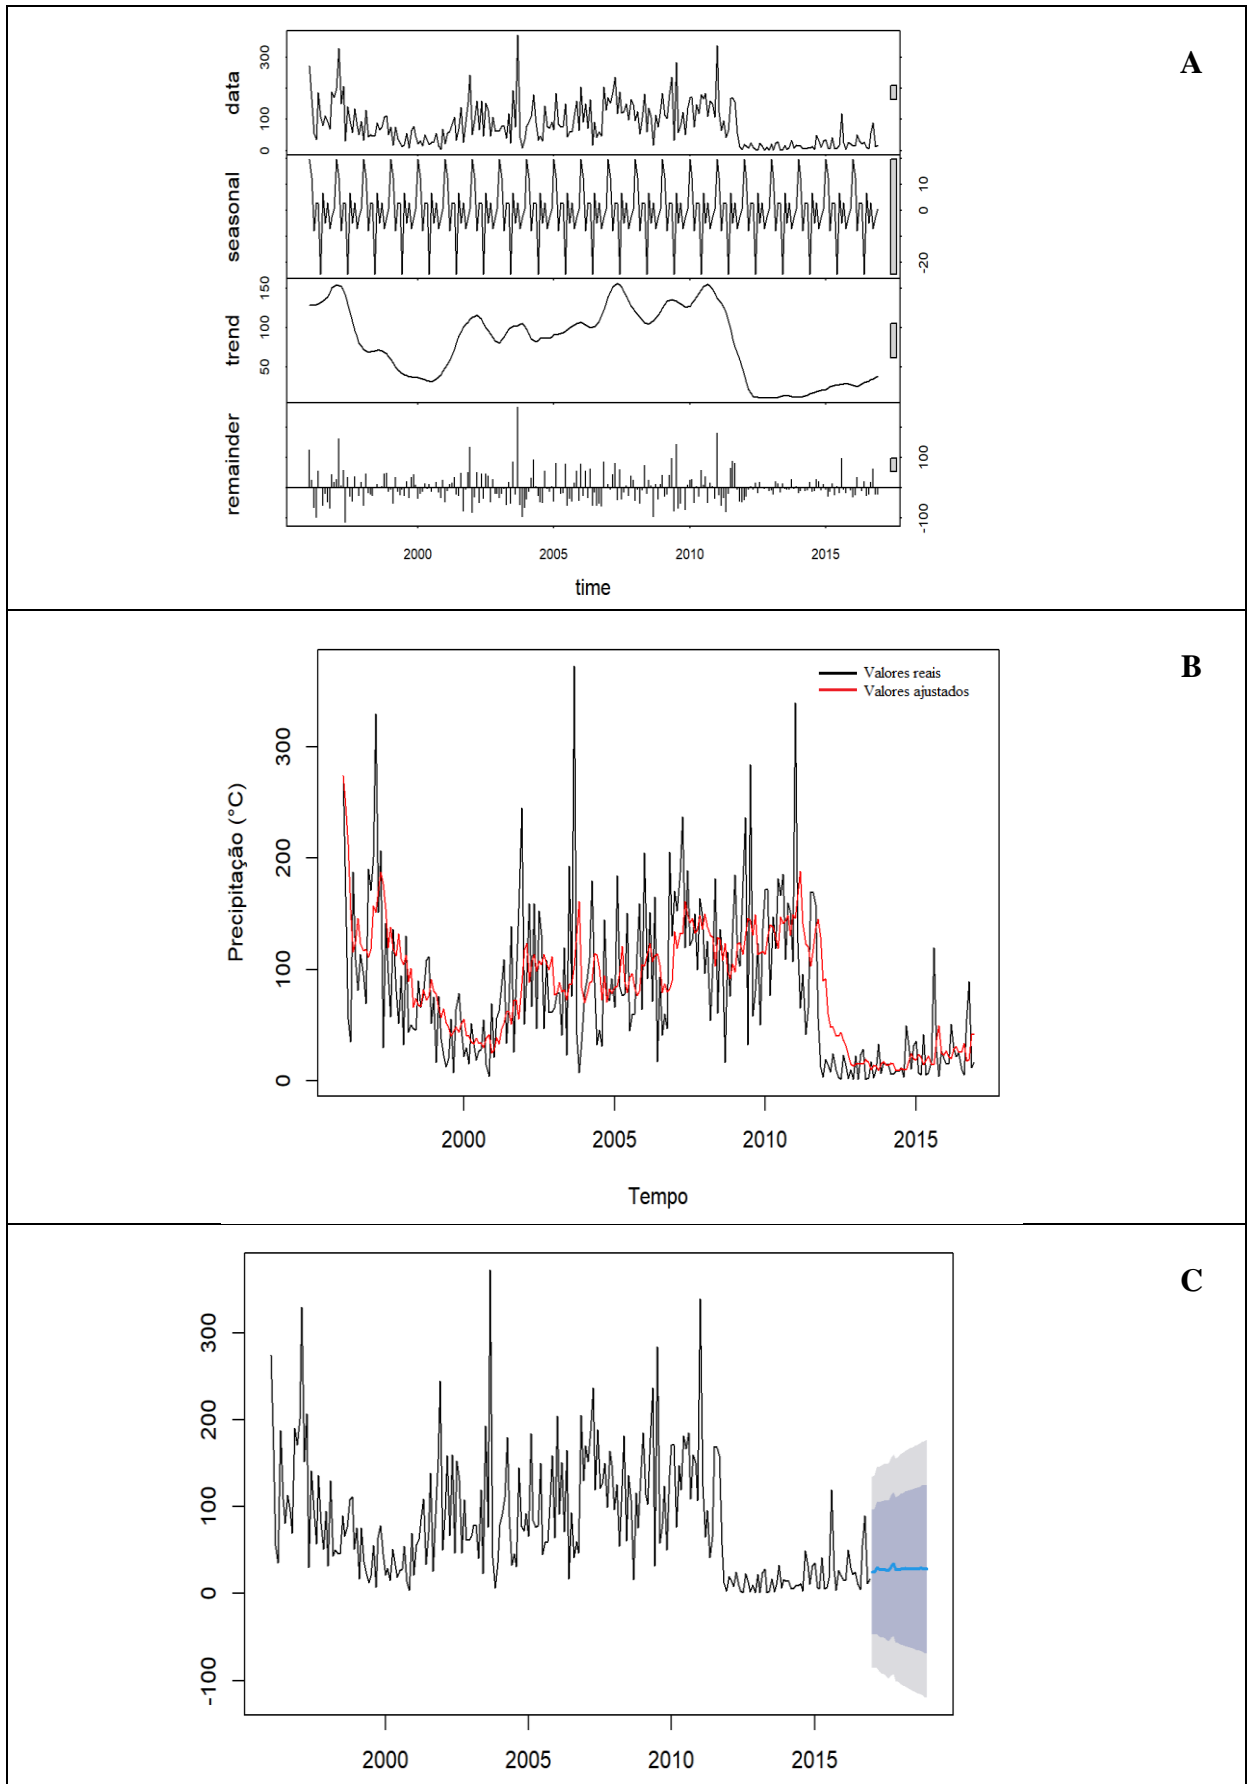


Figura 8 – Gráficos da decomposição da série temporal (A), ajuste da série (B) e previsão com o modelo Sarima (C) para o estado da Paraíba. Fonte: Autor.

## 5 CONSIDERAÇÕES FINAIS

De modo geral os resultados condizem ao requerido para a pesquisa, destaca-se que a metodologia Box & Jenkins utilizada neste trabalho mostrou-se adequada para a modelagem de dados climatológicos, identificando as séries climatológicas, o comportamento estacionário, a ausência de tendências demonstrando suas respectivas sazonalidades e a normalidade das séries.

Quanto a escolha do modelo mais adequado é possível concluir que o SARIMA apresentou o melhor padrão de representatividade encontrado exceto no Agreste. Este modelo se mostrou satisfatório para análise e previsão dos dados de precipitação, contornando o problema de estacionariedade e tendência, ajudando na leitura a respeito das precipitações. Isso é um ótimo resultado, principalmente devido às incertezas e imprevistos associados ao tempo e clima.

Portanto, a partir da interpretação dos resultados é possível o planejamento de diversas atividades econômicas para as microrregiões do estado da Paraíba, em especial projetos voltados para a agricultura familiar com o objetivos de evitar perdas e danos destes produtores que movimentam a economia regional.

## 6 REFERÊNCIAS

ALBUQUERQUE, R. C. **Modelagem de séries temporais aplicados a dados climatológicos no sertão paraibano. Trabalho de conclusão de curso.** Universidade Estadual da Paraíba. 35 p. 2015.

ARAÚJO, Maressa Oliveira Lopes. **Análise Da Precipitação Horária No Estado Da Paraíba.** João Pessoa, 2020. 58p

ASSAD, E. D., VICTORIA, D. D. C., CUADRA, S. V., PUGLIERO, V. S., & ZANETTI, M. R. **Efeito Das Mudanças Climáticas Na Agricultura Do Cerrado.** (2020)

BARBOSA, E. C., SÁFADI, T., NASCIMENTO, M., NASCIMENTO, A. C. C., SILVA, C. H. O., & Manuli, R. C.. **Metodologia box & jenkins para previsão de temperatura média mensal da cidade de bauru (sp).** Revista Brasileira de Biometria, v. 33, n. 1, p. 104-117, 2015.

BRITO, J. J.; BRAGA, C.C. **Chuvras No Estado Da Paraíba Em 2004.**Boletim da Sociedade Brasileira de Meteorologia, São José dos Campos, v. 29, n.1, p.27-32, mar., 2005.

CHECHI, Leonardo; SANCHES, Fabio de Oliveira. **Análise de uma série temporal de precipitação para erechim (rs) e um possível método de previsão climática.** AMBIÊNCIA, v. 9, n. 1, p. 43-55, 2013.

COSTA, A. D. S., OLIVEIRA, V. D., PEREIRA, A., BORGES, P. D. F., & ARAÚJO, L. D. S. (2015). **Estudo do clima na região do brejo paraibano utilizando técnicas de séries temporais, para previsão com o modelo sarima.** Gaia Scientia, v. 9, n. 1, p. 127-133, 2015

COSTA, Hudson Chaves. **Séries Temporais Univariadas.** 2019. Disponível em: <https://rpubs.com/hudsonchavs/seriestemporaisunivariadas>. Acesso em: 11 dez. 2022.

DA COSTA, Ellder Silva. **Análise Da Série Temporal De Precipitação Total Mensal Do Município De Cruz Das Almas-BA.** Universidade Federal do Recôncavo da Bahia. Bacharelado em Ciências Exatas e Tecnológicas, 2019.

DANTAS, Leydson Galvêncio et al. **Aplicação De Modelos Para Séries Temporais E Pluviométricas No Estado Da Paraíba.** 2016.

DA SILVA, E. A., DE BRITO, J. I. B., BECKER, C. T., CAVALCANTI, E. P., MANDÚ, T. B., & DE LIMA, I. P. C. **Determinação de limiares para a precipitação mensal das regiões homogêneas da Paraíba usando quantis.** Revista Brasileira de Climatologia, v. 30, p. 92-111, 2022.

DE ALBUQUERQUE, R. C., DE OLINDA, R. A., CUNHA, A. L. X., TAVARES, R. G., De ARRUDA, V. C. M., & CUNHA FILHO, M. (2020). **Aplicação Da Metodologia Box & Jenkins Em Dados De Precipitação Na Região Do Sertão Do Estado De Pernambuco–Brasil.** Revista Geama, , v. 6, n. 1, p. 25-30, 2020.

DE ARAÚJO, Lincoln Eloi; BECKER, Carmem Terezinha; DE LIMA PONTES, Alana. **Periodicidade Da Precipitação Pluviométrica No Estado Da Paraíba.** 2003.

DE MEDEIROS, Raimundo Mainar; FRANCISCO, Paulo Roberto Megna; SANTOS, Djail. **Balço Hídrico E Erosividade Em Função Das Mudanças Climáticas No Estado Da Paraíba.** Revista Brasileira de Geografia Física, v. 8, n. 04, p. 1068-1084, 2015.

DE MORAES, Rafael Ferraz; DE HOLANDA SALES, Paulo Roberto; COSTA, José Fabiano Serra. **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.

FERREIRA, Pedro Costa. **Business forecasting: Previsão das vendas de passagens aéreas utilizando os modelos (S)ARIMA.** 2018. Disponível em: [http://rstudio-pubs-static.s3.amazonaws.com/352308\\_76e434a17cf24868b8b05b1b34de25dd.html#introdu%C3%A7%C3%A3o](http://rstudio-pubs-static.s3.amazonaws.com/352308_76e434a17cf24868b8b05b1b34de25dd.html#introdu%C3%A7%C3%A3o). Acesso em: 14 dez. 2022

FRANCISCO, Paulo Roberto Megna; SANTOS, Djail. **Climatologia Do Estado Da Paraíba**, ed. 1. Campina Grande: EDUFPG, 2017.

FRANCO, G. C.; Soares, J. P. & Ribeiro, J. A.. **Comparação dos Softwares MINITAB, SAS, SPSS e EVIEWS na Estimação de Modelos ARIMA(p,d,q)**. RTE-02. 2004  
Disponível em: <http://www.est.ufmg.br/portal/arquivos/rts/rte0402.pdf>. Acesso em: 14 dez. 2022

GUEDES, Everaldo Freitas. **Uma Introdução À Análise De Séries Temporais Com R**. Salvador, 2019. Disponível em: [http://www.csds2019.ime.ufba.br/SC5\\_Everaldo%20Guedes.pdf](http://www.csds2019.ime.ufba.br/SC5_Everaldo%20Guedes.pdf). Acesso em: 30 nov. 2022.

GONZAGA, Sillas Teixeira. **Curso de Séries Temporais**. 2019. Disponível em: [http://sillasgonzaga.com/material/curso\\_series\\_temporais/](http://sillasgonzaga.com/material/curso_series_temporais/). Acesso em: 13 dez. 2022

IBGE – Instituto Brasileiro de Geografia e Estatística. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/pb.html>. Acesso em: 08 dez. 2022.

LIMA, L. P. A., JÚNIOR, A. A. S., CARVALHO, A. C. X., & De MUSIS, C. R. **Utilização de estatística descritiva e de modelo sarima no estudo de precipitação na região sudeste de mato grosso**. Revista de Ciências Ambientais, v. 14, n. 1, p. 25-34, 2020.

LIMEIRA, Rodrigo César et al. **Variabilidade E Tendência Das Chuvas No Estado Da Paraíba**. 2008.

MARENGO, Jose A.; CUNHA, Ana P.; ALVES, Lincoln M. **A seca de 2012-15 no semiárido do Nordeste do Brasil no contexto histórico**. Revista Climanalise, v. 3, n. 1, p. 49-54, 2016.

MIRZAVAND, Mohammad; GHAZAVI, Reza. **Uma Técnica De Modelagem Estocástica Para Previsão Do Nível Das Águas Subterrâneas Em Um Ambiente Árido Usando Métodos De Séries Temporais**. Gestão de recursos hídricos , v. 29, n. 4, pág. 1315-1328, 2015.

MORETTIN, P. A.; TOLOI, C. **Análise de Séries Temporais**. [S.l.]: Blucher, 2004. 535 p.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais. Associação brasileira de estatística**. São Paulo: Edgard Blucher, 2.ed., 2006. 538p.

MOURÃO, Ícaro de Sena. **Predição De Séries Temporais Climáticas Com Aprendizagem Profunda**. 60 f. TCC (Graduação) - Curso de Ciência da Computação, Universidade Federal do Ceará, Crateús, 2019.

PACHECO, Antonio Guilherme. **Estudo da influência de variáveis metereológicas no aparecimento de casos graves de leptospirose em Salvador-BA via modelos de séries temporais**. 2001. Tese de Doutorado.

RODRIGUES, Bruno Dore. **Modelagem De Séries Temporais Focada Na Precificação De Derivativos Climáticos**. 2006. Tese de Doutorado. Dissertação de Mestrado. Rio de Janeiro, PUC-RJ.

SILVA, Lindenberglucena da et al. **Precipitações Pluviais Da Pré-Estação Chuvosa No Período Chuvoso E Suas Influências Na Produtividade Agrícola Da Paraíba**. 2007.

SILVA, Maria IS; GUIMARÃES, Ednaldo C.; TAVARES, Marcelo. **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.

SILVESTRE, Miriam Rodrigues. **Técnicas Estatísticas Utilizadas Em Climatologia Geográfica: Diagnóstico E Propostas**. 2016.

SOKOLNIKOV, André U.. **Identificação THz para fins de defesa e segurança: identificação de materiais, substâncias e itens**. Mundial Científico. 2013.

## APÊNDICE A – ROTINA DO R

```

dados<-data.frame(
  stringsAsFactors = FALSE,
  check.names = FALSE,
  ANO = c("Jan","Fev",
          "Mar","Abr","Mai","Jun","Jul","Ago","Set",
          "Out","Nov","Dez"),
  `1996` = c(65.69,85.21,
            171.49,274.13,105.17,92.91,77.39,80.63,41.52,
            17.06,56.03,20.13),
  `1997` = c(78.47,108.66,
            171.41,165.83,181.63,41.13,72.03,51.5,5.57,
            2.52,12.63,55.29),
  `1998` = c(78.81,33.56,
            76.64,55.78,60.54,59.86,92.03,94.54,7.18,9.97,
            3.16,7.54),
  `1999` = c(40.77,70.16,
            147.51,35.14,136.18,46.89,66.01,32.26,17.61,
            33.18,19.3,64.29),
  `2000` = c(119.69,138.73,
            119.09,187.78,107.84,205.37,184.06,129.81,
            119.35,6.94,14.69,78.46),
  `2001` = c(22.92,25.49,
            181.38,108.88,16.49,129.94,84.34,43.32,26.26,
            16.48,8.17,46.34),
  `2002` = c(193.07,91.21,
            166.7,81.27,115.63,170.64,76.43,50.05,4.07,
            14.53,24.53,21.56),
  `2003` = c(76.16,154.78,
            185.22,113.37,75.94,152.19,78.23,46.89,26.97,
            14.68,9.63,29.5),
  `2004` = c(372.07,244.81,
            108.89,94.98,132.8,186.55,150.22,45.73,20.59,
            5.65,3.43,15.19),

```

`2005` = c(41.72,50.53,  
159.94,69.56,185.14,237.01,44.94,89.95,15.01,  
5.87,1.43,51.24),

`2006` = c(6.97,96.96,  
150.95,190.45,113.82,119.46,59.39,65.85,15.37,  
8.92,23.23,32.98),

`2007` = c(35.31,159.13,  
107.18,170.71,103.21,188.56,60.07,76.81,50.7,  
8.84,13.78,18.78),

`2008` = c(79.08,66.66,  
339.36,201,179.21,121.17,113.38,108.08,29.91,  
11.82,1.78,26.44),

`2009` = c(91.1,159.39,  
124.21,329.17,236.39,126.88,158.83,111.8,21.89,  
3.04,9.77,28.08),

`2010` = c(110.32,46.64,  
65.51,151.42,32.22,149.98,63.99,51.31,25.21,  
49.66,1.66,54.54),

`2011` = c(179.48,152.51,  
96.02,206.91,283.72,99.46,204.41,75.4,10.61,  
32.62,22.13,14.78),

`2012` = c(88.67,131.15,  
41.85,29.97,58.41,163.91,91.72,16.79,5.07,  
10.55,1.21,3.89),

`2013` = c(32.67,46.88,  
65.07,141.3,80.37,148.68,151.01,76.03,55.29,  
31.59,23.73,69.58),

`2014` = c(45.86,108.42,  
169.73,96.97,123.53,96.58,71.27,37.38,89.36,  
35.47,28.36,21.43),

`2015` = c(31.17,61.5,  
168.79,57.52,49.97,125.29,165.26,23.12,11.92,  
7.27,1.51,56.17),

`2016` = c(144.83,62.01,

```
158.72,135.93,136.39,54.38,17.09,12.46,16.67,  
5.51,2.86,62.49)  
)  
library(tidyverse)  
  
dados1<-gather(dados, key = Meses, value = Precipitação, -ANO)  
  
dados1<-dados1 %>% arrange(ANO)  
  
library(tseries)  
  
x<-ts(dados1$Precipitação, start=c(1996, 1), end=c(2016, 12), freq=12)  
  
x  
  
stl(x, "periodic")  
  
plot(stl(x, "periodic"))  
  
adf.test(diff(x), alternative="stationary", k=0)  
  
plot(diff(x))  
  
library(seasonal)  
  
decompose(x)  
acf(x)  
pacf(x)  
  
library(forecast)  
  
modelo<-auto.arima(x)  
modelo  
summary(modelo)
```

```
plot(modelo)
plot(forecast(modelo))

plot(modelo,plot.type="single")

library(ggplot2)
autoplot(modelo)

plot(x, ylab="Precipitação (mm)", xlab="Tempo")
lines(fitted(modelo), col='red')

tsdiag(modelo)
Box.test(modelo$residuals, lag=1)
Box.test(modelo$residuals, type="Ljung-Box")
modelo.predict<-forecast(modelo, h = 1)
modelo.predict
modelo.predict<-forecast(modelo)
modelo.predict

modelo.predict<-forecast(modelo, h = 12)
modelo.predict
estimativas<-forecast(modelo)

estimativas

#SARIMA
require(astsa)

diff12 = diff(x,12)
plot(diff12)
acf2(diff12, 48)

#igual ao anterior
modelo2<-sarima(x, 0,0,0,2,0,0,12, details=F)
```

```
print(modelo2)
```

```
modelo3<-sarima(x, 2,0,0,0,1,1,12)
```

```
print(modelo3)
```

```
class(modelo3$fit)
```

```
#igual ao anterior
```

```
modelo4<-arima(x, order = c(2,0,0), seasonal = list(order = c(0,1,1), period=36))
```

```
modelo4
```

```
class(modelo4)
```

```
predict(modelo4)
```

```
fitted(modelo4)
```

```
plot(x)
```

```
lines(fitted(modelo4), col="red")
```

```
plot(x)
```

```
lines(fitted(modelo2$fit), col="red") #Melhor ajuste que modelo
```

```
dev.off()
```

```
library(dygraphs)
```

```
#https://rstudio.github.io/dygraphs/gallery-axis-options.html
```

```
dygraph(x)
```

```
dygraph(x) %>% dyRangeSelector()
```

```
dygraph(x) %>%
```

```
  dySeries("V1", label = "Precipitação (mm)")
```