

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO**

**MODELOS DE SÉRIES TEMPORAIS APLICADOS A
DADOS DE UMIDADE RELATIVA DO AR**

DISSERTAÇÃO DE MESTRADO

Cleiton Tibulo

**Santa Maria, RS, Brasil
2014**

MODELOS DE SÉRIES TEMPORAIS APLICADOS A DADOS DE UMIDADE RELATIVA DO AR

CLEITON TIBULO

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação em Engenharia de Produção, Área de Concentração em Gerência da Produção, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de
Mestre em Engenharia da Produção

Orientadora: Profa. Dra. Roselaine Ruviaro Zanini

**Santa Maria, RS, Brasil
2014**

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

Tibulo, Cleiton

Modelos de séries temporais aplicados a dados de umidade relativa do ar / Cleiton Tibulo.-2014.

98 p.; 30cm

Orientadora: Roselaine Ruviaro Zanini

Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Produção, RS, 2014

1. Modelos de séries temporais 2. Umidade relativa do ar 3. Comparação do desempenho de modelos de séries temporais I. Ruviaro Zanini, Roselaine II. Título.

© 2014

Todos os direitos autorais reservados a Cleiton Tibulo. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

Endereço: São Marcos, Tuparendi, RS. CEP: 98940-000

Endereço Eletrônico: tibulo_cleiton@hotmail.com

**Universidade Federal de Santa Maria
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia de Produção**

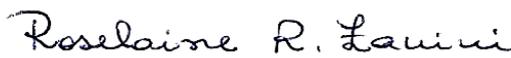
**A Comissão Examinadora, abaixo assinada,
aprova a dissertação de Mestrado**

**MODELOS DE SÉRIES TEMPORAIS APLICADOS A DADOS DE
UMIDADE RELATIVA DO AR**

elaborado por
Cleiton Tibulo

como requisito parcial para obtenção do grau de
Mestre em Engenharia de Produção

COMISSÃO EXAMINADORA:


Roselaine Ruviaro Zanini, Dra.
(Presidente/Orientadora)


Adriano Mendonça Souza, Dr.
(UFSM)


Luciane Flores Jacobi, Dra.
(UFSM)

Santa Maria, 11 de dezembro de 2014.

AGRADECIMENTOS

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

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

À minha orientadora, professora Roselaine Ruviano Zanini, pelo conhecimento, competência, incentivo, paciência, dedicação e amizade transmitida. Um especial muito obrigado!

Ao professor Adriano Mendonça Souza, pela compreensão, ajuda e colaboração dadas ao longo desse período.

Ao meu pai, Ivar Tibulo, e minha mãe, Valdomira Tibulo, por me ensinarem a prosseguir mesmo em situações adversas.

À minha família como um todo pelos incentivos proferidos.

Agradeço à Universidade Federal de Santa Maria e a todos os professores e funcionários do PPGE/UFMS que me auxiliaram nestes dois últimos anos.

Ao Colégio Militar de Santa Maria que forneceu ferramentas necessárias para que este curso fosse realizado.

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

Obrigado a todos!

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

RESUMO

Dissertação de Mestrado
Programa de Pós Graduação em Engenharia de Produção
Universidade Federal de Santa Maria

MODELOS DE SÉRIES TEMPORAIS APLICADOS A DADOS DE UMIDADE RELATIVA DO AR

Autor: Cleiton Tibulo

Orientadora: Roselaine Ruviaro Zanini

Data e Local da Defesa: Santa Maria-RS, 11 de dezembro de 2014.

Modelos de séries temporais vêm sendo empregados em diversas áreas do conhecimento e têm surgido como necessidade atual para empresas sobreviverem em um mercado globalizado e competitivo, bem como fatores climáticos sempre foram motivo de preocupação pelas diferentes formas que interferem na vida humana. Nesse contexto, o presente trabalho tem por objetivo apresentar uma comparação do desempenho das classes de modelos de séries temporais ARIMA, ARMAX e Alisamento Exponencial, ajustados a dados de umidade relativa do ar (UR) e verificar a volatilidade presente na série por meio de modelos não-lineares ARCH/GARCH ajustados aos resíduos dos modelos ARIMA e ARMAX. Os dados foram coletados junto ao INMET no período de 01 de outubro de 2001 a 22 de janeiro de 2014. Na comparação dos resultados e na seleção do melhor modelo foram utilizados os critérios MAPE, EQM, MAD e SSE. Os resultados mostraram que o modelo ARMAX(3,0) com a inclusão de variáveis exógenas produziu melhores resultados de previsão em relação aos seus concorrentes SARMA(3,0)(1,1)₁₂ e o Holt-Winters multiplicativo. No estudo da volatilidade da série via modelo não-linear ARCH(1), ajustado aos quadrados dos resíduos dos modelos SARMA(3,0)(1,1)₁₂ e ARMAX(3,0), observou-se que a volatilidade não tende a influenciar as observações futuras em longo prazo. Conclui-se que as classes de modelos utilizadas e comparadas neste estudo, para dados de uma variável climatológica, demonstraram bom desempenho e ajuste. Destaca-se a ampla possibilidade de utilização das técnicas de séries temporais quando se deseja fazer previsões e descrever um processo temporal, podendo ser utilizadas como ferramenta eficiente de apoio nas tomadas de decisão.

Palavras-chave: Umidade Relativa do Ar. Modelos ARIMA. Modelos de Alisamento Exponencial. Modelos ARMAX, Modelos ARCH/GARCH.

ABSTRACT

Master Degree Dissertation
Production Engineering Pos Graduation Program
Federal University of Santa Maria

MODELS OF TEMPORAL SERIES APPLIED TO AIR RELATIVE HUMIDITY DATA

Author: Cleiton Tibulo

Advisor: Roselaine Ruviaro Zanini

Date and place of presentation: Santa Maria-RS, December, 11th, 2014.

Time series model have been used in many areas of knowledge and have become a current necessity for companies to survive in a globalized and competitive market, as well as climatic factors that have always been a concern because of the different ways they interfere in human life. In this context, this work aims to present a comparison among the performances by the following models of time series: ARIMA, ARMAX and Exponential Smoothing, adjusted to air relative humidity (UR) and also to verify the volatility present in the series through non-linear models ARCH/GARCH, adjusted to residues of the ARIMA and ARMAX models. The data were collected from INMET from October, 1st to January, 22nd, 2014. In the comparison of the results and the selection of the best model, the criteria MAPE, EQM, MAD and SSE were used. The results showed that the model ARMAX(3,0), with the inclusion of exogenous variables produced better forecast results, compared to the other models SARMA(3,0)(1,1)₁₂ and the Holt-Winters multiplicative. In the volatility study of the series via non-linear ARCH(1), adjusted to the quadrants of SARMA(3,0)(1,1)₁₂ and ARMAX(3,0) residues, it was observed that the volatility does not tend to influence the future long-term observations. It was then concluded that the classes of models used and compared in this study, for data of a climatologic variable, showed a good performance and adjustment. We highlight the broad usage possibility in the techniques of temporal series when it is necessary to make forecasts and also to describe a temporal process, being able to be used as an efficient support tool in decision making.

Keywords: Air Relative Humidity. ARIMA Models. Exponential Smoothing Models. ARMAX Models. ARCH/GARCH Models.

LISTA DE FIGURAS

Figura 1 - Ciclo Hidrológico	24
Figura 2 - Diagrama do conforto humano	30
Figura 3 - Diagrama psicrômetro	34
Figura 4 - Psicrômetro de funda e psicrômetro Assmann	35
Figura 5 – Higrômetro	35
Figura 6 - Observações de uma série temporal com previsões de origem t e horizontes de previsão iguais a um, dois e h passos à frente	38
Figura 7 - Aplicação dos métodos de análise de séries temporais	47
Figura 8 - Série Original da Umidade Relativa em Santa Maria – RS	65
Figura 9 - Decomposição da série temporal em componentes de ciclo, sazonalidade, tendência e aleatoriedade	65
Figura 10 - Função de Autocorrelação (ACF) e Autocorrelação Parcial (PACF)	67
Figura 11 – Modelo SARMA (3,0)(1,1) ₁₂ ajustado a série observada	69
Figura 12 – Função de Autocorrelação (ACF) e Autocorrelação Parcial (PACF) dos ε_t^2 do modelo SARMA(3,0)(1,1) ₁₂	70
Figura 13 - Volatilidade modelo SARMA-ARCH	71
Figura 14 – Modelo ARMAX (3,0,[1,1]) ajustado a série observada	74
Figura 15 – Função de Autocorrelação (ACF) e Autocorrelação Parcial (PACF) dos ε_t^2 do modelo ARMAX(3,0,[1,1])	75
Figura 16 - Volatilidade modelo ARMAX-ARCH	76
Figura 17 - Holt-Winters multiplicativo	78

LISTA DE TABELAS

Tabela 1 – Critérios de avaliação de previsão do modelo Holt-Winters	59
Tabela 2- Medidas descritivas da UR de Santa Maria – RS, 2001 a 2014	64
Tabela 3 - Modelos concorrentes SARMA e os respectivos critérios	68
Tabela 4 - Valores Previstos (h=21) modelos SARMA(3,0)(1,1) ₁₂	69
Tabela 5 - Parâmetros modelo ARCH ajustados aos ε_t^2 do modelo SARMA(3,0)(1,1) ₁₂ ..	71
Tabela 6 - Modelos concorrentes ARMAX e os respectivos critérios	72
Tabela 7 - Valores Previstos (h=21) modelo ARMAX(3,0,[1,1])	73
Tabela 8 - Parâmetros modelo ARCH ajustados aos ε_t^2 do modelo ARMAX(3,0,[1,1]) ...	75
Tabela 9 - Valores Previstos (h=21) modelos Holt-Winters	77
Tabela 10 - Critérios de seleção modelo Holt-Winters	77
Tabela 11 - Comparação dos modelos utilizando os critérios de seleção	78

LISTA DE SIGLAS E SÍMBOLOS

ABNT - Associação Brasileira de Normas Técnicas

AR - Modelo Autorregressivo

ARMA - Modelo Autorregressivo e de Médias Móveis

ARIMA - Modelo Autorregressivo Integrado de Médias Móveis

ARMAX - Modelo Autorregressivo e de médias móveis com entrada de variáveis exógenas

ARCH – Modelo Autorregressivo Condicional Heterocedástico

GARCH – Modelo Generalizado Autorregressivo Condicional Heterocedástico

Embrapa - Empresa Brasileira de Pesquisa Agropecuária

INMET - Instituto Nacional de Meteorologia

MA - Modelo de Médias Móveis

SARIMA - Modelo Autorregressivo Integrado de Médias Móveis Sazonal

UR - Umidade Relativa do Ar

Z_t - Série temporal

Φ - Parâmetro autorregressivo

Φ - Parâmetro autorregressivo sazonal

Θ - Parâmetro de médias móveis

Θ - Parâmetro de médias móveis sazonal

p - Número de parâmetros autorregressivos

d - Número de diferenciações

q - Número de parâmetros de médias móveis

P - Número de parâmetros autorregressivos sazonais

D - Número de diferenciações sazonais

Q - Número de parâmetros de médias móveis sazonais

μ - Média de uma variável aleatória

p_a - pressão de vapor de água

p_{as} - pressão de vapor de água saturado

t_a - temperatura do ar °C

t_{bu} - temperatura de bulbo úmido °C

AEHW - Alisamento Exponencial de Holt-Winters

ε - Erro aleatório

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Problemática	18
1.2 Objetivos	19
1.2.1 Objetivo geral	19
1.2.2 Objetivos específicos	19
1.3 Justificativa	20
1.4 Organização do trabalho	20
2 REVISÃO BIBLIOGRÁFICA	22
2.1 Umidade Relativa do Ar	22
2.1.1 Influências da Umidade Relativa do Ar para o setor primário	25
2.1.2 Interferências da Umidade Relativa do Ar para a saúde	27
2.1.3 Processos de obtenção da Umidade Relativa do Ar	32
2.1.4 Instrumentos de medição da Umidade Relativa do Ar	34
2.2 Modelos de Séries Temporais	36
2.2.1 Testes para estacionariedade Dickey-Fuller	40
2.2.2 Testes para tendência	41
2.2.2.1 Teste de sequências (Wald-Wolfowitz)	42
2.2.3 Testes para sazonalidade	43
2.2.3.1 Teste de Kruskal-Wallis	43
2.2.3.2 Teste de Friedman	44
2.2.4 Modelos de Box-Jenkins	45
2.2.4.1 Modelo Autorregressivo	49
2.2.4.2 Modelo de Médias Móveis	49
2.2.4.3 Modelo Autorregressivo e de Médias Móveis	50
2.2.4.4 Modelo SARIMA	50
2.2.4.5 Modelo ARMAX	51
2.2.4.6 Modelos para Estimativa da Volatilidade ARCH/GARCH	52
2.2.5 Modelos de Alisamento Exponencial de Holt-Winters	54
2.3 Critérios de seleção dos melhores modelos	57

2.3.1 Critérios de Seleção Modelos Box Jenkins	57
2.3.2 Critérios de avaliação do melhor modelo Holt-Winters	58
2.3.3 Critérios de comparação de modelos	59
2.4 Teste de autocorrelação	60
2.4.1 Teste Ljung-Box	60
2.4.2 Teste Box e Pirce	61
3 METODOLOGIA	62
4 ANÁLISE E DICUSSÃO DOS RESULTADOS	64
4.1 Características Estatísticas da Série	64
4.2 Modelagem ARIMA	66
4.2.1 Modelagem ARIMA-GARCH	70
4.3 Modelagem ARMAX	72
4.3.1 Modelagem ARMAX-ARCH/GARCH	74
4.4 Alisamento Exponencial de Holt-Winters (AEHW)	76
4.5 Comparação dos modelos ajustados SARMA, Holt-Winters e ARMAX	78
5 CONSIDERAÇÕES FINAIS	80
REFERÊNCIAS	81
APÊNDICE	91

1 INTRODUÇÃO

Nos últimos anos, vários estudos vêm desenvolvendo e aperfeiçoando modelos estatísticos cada vez mais sofisticados, com o intuito de melhorar as pesquisas nas mais diversas áreas do conhecimento.

Entre eles, destaca-se os modelos para previsão de séries temporais, cuja importância tem crescido e continua como interesse atual. Conhecer previamente um valor futuro pode representar grande diferença na tomada de decisões em inúmeras áreas do conhecimento.

Nesse contexto, a análise de séries temporais aplicadas a dados climatológicos atrai interesse especial, considerando que o clima interfere diretamente na qualidade de vida dos habitantes de qualquer região ou ainda, que na área econômica determina o sucesso ou o fracasso de vários empreendimentos.

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

Um número crescente de métodos e técnicas estatísticas tem sido desenvolvido e testados com o objetivo de obter previsões cada vez mais acuradas, seja em séries temporais macroeconômicas, seja em séries de consumo ou produção, segundo Diebold (1998).

Vários fatores influenciam nas mudanças climáticas de centros urbanos, tais como: cobertura vegetal, alta densidade demográfica, quantidades de edificações, fábricas e automóveis. Tais fatores têm contribuído significativamente para as variações climáticas como: temperatura máxima e mínima, umidade relativa do ar, precipitações e direção dos ventos, intensificando a formação de ilhas de calor e o desconforto térmico, segundo Bezerra et al. (2013).

Dessa forma, é de fundamental importância o uso de modelos matemáticos adequados para se fazer previsões e produzir diagnósticos o mais próximo do real. Assim, é possível contribuir para tomada de decisão de diversos setores da sociedade, tendo em vista que os fatores climáticos de uma forma ou outra afetam a todos.

Segundo Ferreira e Assis (2010), modelos teóricos podem auxiliar na previsão do comportamento de variáveis climáticas em cidades. Dessa forma, seria possível prever impactos na atmosfera urbana ocasionados por fatores meteorológicos.

Para Chechi e Sanches (2013), a partir da análise de séries temporais climatológicas é possível construir-se modelos de previsão que necessitam basicamente de uma série de valores observados ao longo do tempo.

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

A área da saúde é uma das mais afetadas pelas mudanças climatológicas. Segundo Pinto et al. (2008), a baixa umidade relativa do ar pode gerar vários problemas de saúde, como: respiratórios, alergias, sinusites, asma e outras doenças tendem a se agravar. Já de acordo com Camargo e Furlan (2011), quando a umidade relativa do ar é muito alta, pode ocorrer estresse por calor, sensação desagradável, elevação da temperatura corporal, doenças térmicas brandas e doenças relacionadas com o quadro de desidratação e hipertermia.

Destaca-se também a importância das análises em climatologia para a agricultura e a pecuária. Consoante Bardin et al. (2010), a temperatura do ar é um elemento meteorológico fundamental para o crescimento e desenvolvimento das plantas, duração das fases de desenvolvimento das plantas e dos ciclos de cada cultura. Oliveira (2010) destaca que o clima, no conjunto dos seus parâmetros como temperatura, umidade, radiação e precipitações, exerce fundamental importância nos sistemas produtivos agrícolas e exerce influência na forma e ocupação de espaços, que obedecem ao conjunto de condições oferecidas pelo clima. Ainda segundo o último autor, é indiscutível a importância do clima para agricultura e pecuária.

Modelos estatísticos vêm sendo utilizados de maneira satisfatória nesta área. Antonini et al. (2009) desenvolveram um modelo matemático para estimativa da temperatura média diária do ar para o estado de Goiás considerando simultaneamente as variações espaciais e temporal, através de observações de séries históricas de 21 estações meteorológicas, por meio de regressão linear múltipla das combinações da altitude, latitude e longitude e da série trigonométrica de Fourier. Esses dados foram coletados no período 1985–2000, obtidos no Instituto Nacional de Meteorologia (INMET), e de 2000–2007, obtidos no Sistema de Meteorologia e Hidrologia do Estado de Goiás (Simehgo), e de 1983–2006, na estação meteorológica da Embrapa Arroz e Feijão. O coeficiente de correlação ajustado foi de 0,91 e o modelo testado apresentou desempenho mediano para altas e baixas altitudes e muito bom desempenho para altitudes medianas, prevendo adequadamente a temperatura média para o Estado de Goiás.

Modelos físicos matemáticos foram testados por Delgado et al. (2007), para o cálculo da umidade relativa do ar em escala horária a partir de dados de temperatura máximo e

mínima no município de Muriaé em Minas Gerais. Para tal, foram utilizados dados do INEMT da estação automática A517, durante o período de 10 de outubro de 2006 a 10 de dezembro de 2006. Os autores concluíram que modelos de previsão da umidade relativa do ar tem importância significativa principalmente para locais que dispõem de dados de temperatura máxima e mínima ou em locais que apresentem séries históricas falhas.

Para o nordeste brasileiro, Cavalcanti et al. (2006) estabeleceram um modelo de estimativa da temperatura do ar em função das coordenadas geográficas e das anomalias de temperaturas da superfície do mar, reconstruindo as séries temporais das médias mensais de temperatura (médias diárias, mínimas e máximas) através da altitude, latitude e longitude de 69 estações meteorológicas do nordeste brasileiro e oceano Atlântico. Os autores perceberam que o modelo desenvolvido pode ser utilizado com bom nível de precisão para a construção de séries temporais de temperatura do ar e que a temperatura do ar de todo o litoral do nordeste é fortemente influenciada pela temperatura da superfície do mar.

Para a mesma região, Medeiros et al. (2005), por meio de equações de regressão múltipla, com ajuste quadrático, estimaram as temperaturas do ar mínimas, médias e máximas, mensais e anuais a fins de fornecer subsídio para planejamento agroclimático em regiões onde não há disponibilidade de dados. Os registros de temperatura do ar, para obtenção dos coeficientes das equações de 74 estações meteorológicas dos Estados do Nordeste, foram obtidos pelo (INMET). A partir das equações ajustadas, os mapas das normais de temperatura do ar mínimo, médio, e máxima mensal e anual foram gerados apresentando bons valores de coeficiente de determinação. Os autores concluíram que o ajuste de equação de regressão é uma alternativa viável para a estimativa da temperatura média, mínima e máximas mensais e anuais de regiões que não possuem estações meteorológicas, fornecendo assim dados para um melhor planejamento agropecuário da região.

Modelos regressivos múltiplos da classe SARIMAX foram aplicados por Chechi e Sanches (2013) tendo em vista os dados de precipitação apresentarem pouca correlação, dificultando o ajuste dos modelos SARIMA e Holt-Winters. O modelo SARIMAX permite a inclusão de variáveis explicativas na forma de estrutura de regressão e tem por finalidade modelar os índices médios mensais pluviométricos. A série histórica estudada refere-se aos totais mensais de precipitação da cidade de Erechim (RS), no período de janeiro de 2003 a março de 2011, dados disponibilizados pela FEPAGRO/INMET. A inclusão das covariáveis temperatura mínima e máxima e a normal de precipitação no modelo SARIMAX (0,0,0)(2,2,1) mostrou-se ajustado ao conjunto de dados descrevendo de maneira satisfatória a série de dados.

Para a cidade de Uberlândia, Minas Gerais, Silva et al. (2008) analisaram a temperatura média mensal, no período de janeiro de 1981 a dezembro de 2003, dados pertencentes ao banco de dados do INMET, com o objetivo de descrever o comportamento da série e identificar modelos de previsão de temperatura para períodos subsequentes através do modelo de série temporal do tipo SARIMA. De acordo com os autores, o modelo SARIMA (3,1,0)(0,1,1) reproduziu de forma adequada a periodicidade e a tendência crescente detectada na série sendo considerado o modelo adequado para representar a temperatura média mensal.

Os valores máximo, mínimo médios, mensais e anuais de temperatura na região dos municípios que compõem o Pólo Turístico do Circuito das Frutas do Estado de São Paulo foram estimados por Bardin et al. (2010), através de regressão múltipla em função da altitude, latitude e longitude em dados do INMET, compreendidos no período de 1961 a 1990. Os valores dos coeficientes de determinação obtidos tanto para a temperatura máxima quanto para a temperatura mínima foram elevados, indicando que a equação pode ser utilizada para estimativas.

As variações de temperatura da cidade de Nossa Senhora da Glória estado de Sergipe foram investigadas por Andrade et. al. (2011), com dados fornecidos pelo centro de Previsão do Tempo, no período de janeiro de 2006 a dezembro de 2008, por meio do modelo de séries temporais ARIMA. Demonstrando a adequabilidade do modelo para a variável em estudo, constataram que a variação de temperatura não apresenta comportamento regular para a cidade, sendo que, em janeiro, fevereiro e março apresentam maior variação.

Estudos realizados por Soebiyanto et al. (2010) verificam efeitos diretos das principais variáveis climáticas (umidade do ar, precipitação, temperatura) no inverno como fator de transmissão da gripe em climas temperados. Os autores aplicaram o modelo de séries temporais ARIMA em dados das estações meteorológicas da NASA nas regiões de Hong Kong (China) e no Condado de Maricopa, Arizona (Estados Unidos da América), com o objetivo de prever a influência das variáveis climáticas na transmissão de gripe. Essas regiões têm clima parecido e só se diferem nos volumes de chuva. Os resultados mostraram que incluir variáveis climáticas melhora o desempenho do ajuste. O melhor modelo para a gripe de Hong Kong foi obtido quando temperatura de superfície de terra, precipitação e umidade relativa foram incluídas como sequências de entrada. O modelo para o Condado de Maricopa apresentou as mesmas características incluindo qualquer máximo atmosférico, pressão ou temperatura média. Os autores concluíram que incluir variáveis ambientais aumenta a capacidade de previsão. Portanto, para países sem sistemas avançados de vigilância da gripe,

variáveis ambientais podem ser usadas para estimar a transmissão da gripe no presente e no futuro.

Para o estado do Rio Grande do Sul, Cargnelutti Filho et al. (2008) estimaram a temperatura máxima média decenal do ar de 41 municípios através de modelos de regressão múltipla em função da altitude, latitude e longitude com dados provenientes do Banco de dados do Centro Meteorológico Aplicada, da Fundação Estadual de Pesquisa Agropecuária referentes ao período de 1945 a 1974. Os parâmetros do modelo foram estimados utilizando-se a taxa mínima e a máxima como variável dependente e altitude, latitude e longitude como variável independente. Para a validação do modelo, usou-se o coeficiente de correlação de Pearson entre a taxa mínima e a máxima estimadas de observação meteorológica de dez municípios do estado no período de 1974 a 2004. Os autores concluíram que as temperaturas máxima e média podem ser estimadas em função da altitude, latitude e longitude.

Análise de regressão e os testes não-paramétricos de Run, Mann-Kendall e Pettitt são empregados por Back (2001) para identificar tendências anuais da temperatura e precipitação na série histórica relativa ao período de 1924 a 1998, da estação meteorológica de Urussanga-SC. Na avaliação da precipitação, foram considerados os totais anuais e totais por trimestre do ano. Em relação à temperatura média, foram consideradas a temperatura média anual e a temperatura média dos meses de janeiro e julho. Os resultados indicam que houve tendência significativa no aumento da temperatura média anual e na temperatura média do mês de janeiro, sendo que a mudança ocorreu no ano de 1965. Não foi identificada nenhuma tendência significativa na temperatura média do mês de julho. Também foi identificada a tendência significativa de aumento da precipitação pluvial total anual de 3,4 mm por ano, e da precipitação pluvial total no quarto trimestre. Nos três primeiros trimestres do ano, nenhuma tendência significativa foi identificada.

Com o objetivo de prever focos de calor no Estado do Mato Grosso e diminuir as queimadas, Espinosa et al. (2010) utilizaram modelos de séries temporais ARIMA (SARIMA), com dados dos últimos 17 anos do Instituto Nacional de Pesquisas Espaciais. Segundo os autores, as queimadas e incêndios florestais vêm causando o empobrecimento do solo, alteração das propriedades físicas, químicas e biológicas, que contribuem para a sua erosão e esterilidade; poluição da atmosfera contaminando o ar, diminuição da umidade relativa do ar, aumento do aquecimento global; aumento das doenças respiratórias, alérgicas entre outras causas. Os autores acima citados sugerem que a educação ambiental deva ser realizada em todas as camadas sociais e níveis de ensino do Estado de Mato Grosso e mostraram que o maior número de focos de calor corresponde aos meses de agosto e

setembro, sendo que, nos últimos 6 anos, o mês de setembro tem apresentado um significativo aumento desses focos.

Apontam também que uma forma de redução do número de queimadas é a prevenção, não só por meio da conscientização e penalidades, mas também na utilização de técnicas estatística que podem prever número de focos de calor, levando em consideração os anos anteriores. O modelo SARIMA (1,0,0)(0,1,1) mostrou-se adequado para prever os focos de calor nos meses críticos, demonstrando que modelos de séries temporais podem auxiliar na prevenção de focos de queimadas.

Modelos de previsão de prognósticos em escala sazonal da variável precipitação são discutidos por Lúcio et al. (2010). Os autores utilizaram os modelos autorregressivos integrados e de médias móveis, suavização exponencial, e previsões por análise de correlação canônica para as séries de precipitação média trimestral correspondente às principais capitais brasileiras obtidas nas estações meteorológicas pertencentes ao INMET. Os autores constataram que todas as abordagens metodológicas imputadas às séries dos modelos de Alisamento Exponencial e Box-Jenkins revelaram que as estimativas da precipitação são aceitáveis dentro do âmbito meteorológico, tanto no caso dos modelos individuais, quanto no do modelo combinado, sendo que os resultados das previsões são factíveis, permitindo extrapolar o comportamento das séries trimestrais de precipitação.

Apesar de um número crescente de trabalhos abordando melhoramentos inferenciais, modelagem, técnicas de diagnóstico e aplicações de modelos estatísticos em variáveis climáticas, existem poucos resultados de pesquisas com essas abordagens para a Umidade Relativa do Ar (%). Percebe-se que diversas pesquisas podem ser desenvolvidas referentes à influência que esta variável exerce em diversos campos tanto econômico como social.

Tradicionalmente, estudos similares são focados nas variáveis climáticas: temperatura do ar e precipitação pluviométricas, relegando a um segundo plano outras variáveis meteorológicas como a umidade relativa do ar, sendo esta uma das mais importantes variáveis climáticas.

1.1 Problemática

A problemática que orienta a presente pesquisa está voltada para identificar as principais características e influências da Umidade Relativa do AR (UR) e para ajustar

modelos de séries temporais para a variável em estudo que possam ser largamente empregados em diversas séries de dados ligadas à Engenharia de Produção.

1.2 Objetivos

1.2.1 Objetivo geral

Apresentar um estudo comparativo do desempenho dos modelos de séries temporais ARIMA, ARMAX e Alisamento Exponencial de Holt-Winters, ajustados a dados de umidade relativa do ar.

1.2.2 Objetivos específicos

- Abordar aplicações dos modelos propostos ARIMA, ARMAX e Alisamento Exponencial de Holt-Winters;
- Ajustar modelos ARIMA, Alisamento Exponencial de Holt-Winters e ARMAX aos dados de umidade relativa do ar de Santa Maria no período de 01 de outubro de 2001 a 22 de janeiro de 2014;
- Comparar o desempenho das previsões dos modelos da classe ARIMA, ARMAX e Alisamento Exponencial de Holt-Winters;
- Ajustar modelos não-lineares ARCH/GARCH aos resíduos ao quadrado dos modelos ARIMA e ARMAX;
- Identificar as principais características e influências da UR(%).

1.3 Justificativa

O desenvolvimento e o aprimoramento de técnicas de previsão, planejamento e controle vêm ganhando espaço na sociedade atual. Dentre os mecanismos desenvolvidos, destacam-se os modelos de séries temporais, que podem ser utilizados em diversas áreas, tanto econômicas como sociais.

Nesse contexto, este trabalho tem por finalidade empregar modelos de séries temporais a variável UR. Destaca-se que a variável interfere diretamente no cotidiano de todos os habitantes de qualquer região e que há poucos estudos do emprego de modelos de séries temporais para a variável.

A presente pesquisa ainda busca demonstrar a importância do ajuste de modelos de séries temporais. Esses modelos podem ter grande aplicabilidade em diversas áreas da Engenharia de Produção, quando o interesse é modelar e prever índices de produção, proporção de itens defeituosos, etc. Na economia (taxa de desemprego, produção industrial, taxa de crescimento ou decrescimento, inflação, ações), climatológica (índices de precipitação pluviométrica, radiação solar, umidade relativa do ar), epidemiologia (proporção de casos de gripe A, meningite), índices demográficos (taxa de nascidos vivos, índice de crescimento populacional) entre outras.

1.4 Organização do trabalho

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

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

No capítulo 2, reúnem-se informações sobre umidade relativa do ar e revisão bibliográfica sobre modelos de séries temporais ARIMA, ARMAX, ARCH/GARCH e Alisamento Exponencial de Holt-Winters, com as suas características para emprego no problema.

No capítulo 3, é descrita a metodologia empregada para aplicação dos modelos ARIMA, ARMAX, ARCH/GARCH e Alisamento Exponencial de Holt-Winters.

O capítulo 4 apresenta as avaliações estatísticas com emprego das técnicas de séries temporais e os resultados obtidos.

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

2 REVISÃO BIBLIOGRÁFICA

Nos dias atuais, tem crescido bastante a preocupação com fatores climáticos. Diversos fenômenos, como: secas, temperaturas extremas, temporais, chuvas de granizo estão associadas a variações climáticas geram essa preocupação. De acordo com Biscaro (2007), séries históricas de elementos climáticos observados no decorrer de vários anos, podem fornecer informações bastante confiáveis.

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

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

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

2.1 Umidade relativa do ar

A umidade relativa do ar é definida por Tubilis e Nascimento (1992), como sendo a quantidade de água, na fase de vapor, existente na atmosfera. Segundo Silva (2006), a transferência de vapor para a atmosfera é causada pela evaporação da água, a qual tem como fontes naturais as superfícies de águas, o gelo, a neve, a superfície do solo além das superfícies animais e vegetais.

O vapor d'água que surge na interfase globo-atmosfera mistura-se ao ar, sendo rapidamente transportada pelas correntes aéreas. Posteriormente, encontra condições favoráveis e, então volta ao estado sólido ou líquido na própria atmosfera.

Para Oliveira (2010), a umidade relativa do ar é determinada pela radiação solar, que ativa os demais mecanismos para a entrada de água sob forma de precipitação, bem como, pela geração de calor. São as variáveis climáticas as principais responsáveis pela entrada de energia no sistema.

De acordo com Biscaro (2007), a radiação solar, temperatura e os ventos são os principais responsáveis pela evaporação da água de uma superfície e pela quantidade de vapor d'água presente na atmosfera. Para Bezerra et al. (2013), o processo de evapotranspiração da água funciona como um ar condicionado natural, convertendo energia do sol em calor, assim reduzindo a temperatura do ar.

Os primeiros registros sistemáticos de temperatura datam da década de 1850 e a análise histórica desses registros permite reconhecer algumas tendências de aumento da temperatura média do planeta, segundo Barcellos et al. (2009).

Os maiores percentuais da umidade relativa do ar estão registrados nos períodos do ano que possuem maiores índices de precipitação. Na maioria dos estados brasileiros, são os meses de dezembro a março. Nas regiões litorâneas e na Amazônia, a umidade relativa do ar é alta, superior a 75% e na região central e nordeste a umidade é baixa menos de 45%, de acordo com Biscaro (2007).

A quantidade de vapor de água que determinado volume de ar pode conter depende, basicamente, da temperatura do ar. A atmosfera por sua vez só consegue reter água (vapor) até um determinado limite, que irá variar de acordo com a temperatura e a pressão. É nesse momento que se pode afirmar que o ar está saturado. Quanto mais quente estiver o ar, maior será sua capacidade de reter vapor d'água e, durante o dia, a umidade relativa é menor do que a registrada durante a noite, segundo Biscaro (2007).

Deve-se ressaltar que o vapor d'água é o único componente da atmosfera que muda de estado em condições naturais e, em consequência disto, é o responsável pela origem das nuvens e por uma extensa série de fenômenos atmosféricos importantes (chuva, neve, orvalho etc.). Sua proporção na atmosfera determina o nível de conforto ambiental. (SILVA, 2006, p. 103).

O conhecimento da umidade relativa do ar e suas interações com outros elementos meteorológicos ajudam no planejamento, manejo e gestão dos recursos hídricos. E a sua medição ou estimativa é fundamental em diversas áreas do conhecimento. Valores extremos de umidades relativas combinadas com variáveis meteorológicas compõem um quadro danoso e desagradável, de acordo com Delgado et. al. (2007).

O ciclo hidrológico é uma sequência fechada de fenômenos naturais que pode ser dividida em duas partes: o ramo aéreo e o ramo terrestre. Os fenômenos pertinentes a cada um desses ramos é a interface globo-atmosfera. O ramo aéreo do ciclo hidrológico onde o vapor de água está inserido inicia-se quando a água é cedida à atmosfera, no estado de vapor,

encerrando-se no momento que é devolvida a superfície terrestre, no estado líquido ou sólido. Silva, (2006).

O ciclo hidrológico(ou ciclo da água) é o movimento contínuo da água presente nos oceanos, continentes (superfície, solo e rocha) e na atmosfera. Esse movimento é alimentado pela força da gravidade e pela energia do Sol, que provocam a evaporação das águas dos oceanos e dos continentes. Na atmosfera, forma as nuvens que, quando carregadas, provocam precipitações, na forma de chuva, granizo, orvalho e neve. A (Figura 1) representa o ciclo hídrico.

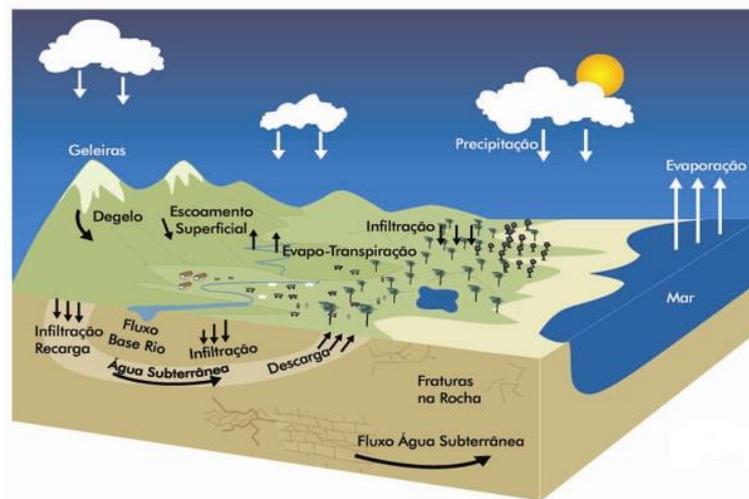


Figura 1 - Ciclo Hidrológico

Fonte: Ministério do Meio Ambiente (MMA)

De acordo com Palmieri (2009), dentre os elementos climáticos existem aqueles que podem ser considerados fundamentais como: umidade relativa do ar, temperatura e radiação solar, pois exercem influências sobre outros elementos climáticos como a precipitação.

O vapor d' água é o agente mais ativo do efeito estufa com 60% de participação, colaborando de forma preponderante no processo de aquecimento planetário e seu volume, na atmosfera, independe da ação humana. Origina-se da radiação solar sobre superfícies líquidas transformando a água, do estado líquido para o de vapor. (CONTI, 2005, p. 85).

Ainda segundo esse autor, os inúmeros estudos sobre aquecimento global não avaliam de forma adequada o papel do vapor d' água, subestimando essa variável e superestimando gases que têm uma participação percentual menor.

Cabe salientar ainda que o vapor de água é responsável pelas precipitações (chuvas), elemento essencial para o desenvolvimento vegetal e animal. De forma mais direta, todo o setor primário é dependente das precipitações.

2.1.1 Influências da Umidade Relativa do Ar para o setor primário

As grandes influências que os fatores climáticos têm no setor primário, direta ou indiretamente, atingem a toda população. Segundo Palmieri (2009), as variáveis climáticas como temperatura, umidade relativa do ar, radiação solar, exercem grande influência sobre a produção agrícola, sendo capazes de ocasionar perdas durante o processo produtivo, acarretando em um aumento considerável no preço do produto final.

Silva et al. (2007) destacam que o mercado produtivo necessita disponibilizar produtos com qualidade e baixo custo para se tornar competitivo e, nesse contexto, o controle das variáveis ambientais assume papel de destaque.

De acordo com Ghini et al. (2011), a severidade das doenças em plantas que ocorrem no campo, de modo geral, estão fortemente relacionadas à umidade do ar e à intensidade de chuvas que constituem uma série ameaça à agricultura. Essas variáveis também têm efeitos direto no crescimento, morfologia, fisiologia, reprodução, sobrevivência e predisposição das plantas. Os impactos ocasionados pelas mudanças climáticas, no ambiente, poderão ter efeito sobre o hospedeiro, o patógeno e sobre as interações entre plantas e bactérias.

Áreas como a agricultura e saúde podem se beneficiar diretamente de previsões de variáveis climatológicas. Barcellos et al. (2009) destacam que o clima da Terra esteve, desde sempre, sujeito a mudanças, produzidas por ciclos longos ou curtos, que estão registrados na história da Humanidade. E, segundo esses autores, são ainda necessários estudos mais detalhados no nível regional para verificar o impacto destes eventos na dinâmica de doenças infecciosas.

A aplicação de equações para o cálculo da umidade relativa do ar é essencial na agricultura, visto que esta variável meteorológica extrema pode causar danos principalmente aos cultivos agrícolas. O uso de métodos de estimativa da umidade

relativa do ar pode ser de grande utilidade, tanto ao setor agrícola como a qualquer outro. (DELGADO et al., 2007, p. 295).

De acordo com Ghini et al. (2008), as mudanças no ambiente poderão ter efeito prejudicial, benéfico ou não, causando alteração no ciclo de vida e na patogenicidade de bactérias e ainda poderão alterar a fisiologia e a resistência da planta hospedeira. Essas alterações poderão modificar a distribuição geográfica das principais bactérias de plantas e ocasionar migrações das culturas para outras regiões geográficas, com o deslocamento de culturas, fazendo com que eventuais medidas de controle tenham que ser adequadas para as novas realidades.

O clima é um sistema complexo e seu funcionamento atua diretamente sobre todo o sistema produtivo podendo refletir em resultados positivos ou negativos da produção final. A regularidade do clima no campo propicia o desenvolvimento de um sistema produtivo integrado e dependente de um ritmo pré-estabelecido, de acordo com, Oliveira (2010).

Ainda segundo Oliveira (2010), os fatores climáticos de uma região podem ser quantificados e qualificados e possui um valor para o sistema agrícola que de acordo com os resultados de produção determinam o valor de aluguéis/arrendo ou preço da terra. Dentre as variáveis citadas, a que possui maior peso é a variável precipitação, responsável por todo o sistema hídrico.

Nesse contexto, cabe ressaltar que a variável umidade do ar está intimamente ligada a índices pluviométricos ou pode-se dizer que é a responsável por ocasionar as chuvas ou precipitações.

De acordo com Delgado et al. (2007), o estudo do comportamento da umidade relativa do ar e sua influência para as culturas na agricultura, possibilita que os agricultores planejem suas atividades com menor risco de serem surpreendidos com efeitos extremos desta variável.

A umidade do ambiente é um dos fatores que condiciona o desenvolvimento de muitos microrganismos patológicos que atacam as plantas cultivadas, e a própria transpiração vegetal está intimamente ligada ao teor de umidade do ar, segundo Silva (2006).

Os estudos da umidade relativa do ar podem definir novas práticas agrícolas, por meio da introdução de novas culturas, mudanças nos períodos de plantio e colheita, alteração nos sistemas de armazenamento e estocagem de produtos e sementes tendo em vista grande influência por ela exercida. De acordo com Silva (2006), a manutenção de faixa ótima de umidade do ar constitui objeto de bastante controle durante a armazenagem de inúmeros produtos.

Para Antonini et al. (2009), o conhecimento das variáveis meteorológicas é importante nos estudos relacionados ao desempenho das culturas agrícolas, na estimativa dos ciclos e definição da época de semeadura.

De maneira geral as perdas na produção, influenciam diretamente no aspecto social. E sua minimização assume papel importante, neste sentido há importância de lançar mão de métodos para auxiliar na minimização das perdas. Dentre esses o monitoramento de variáveis climáticas como (temperatura do ar, umidade relativa do ar e radiação solar) as quais influenciam diretamente no rendimento e qualidade dos produtos agrícolas. (PALMIERI, 2009, P. 17).

O estudo de variáveis climáticas também é importante para indicação da época de semeadura, irrigação, determinação de potencial de produtividade, crédito e seguro agrícola, conforme destacam Cargnelutti Filho et al. (2008).

O ar atmosférico é um importante componente do ambiente, sendo a umidade relativa do ar um dos principais elementos responsáveis pelo aquecimento e o resfriamento. Em países de regime tropical, como o Brasil, o aquecimento torna-se o principal problema para obter alto rendimento produtivo, pois, para cada fase da produção, são exigidas diferentes faixas de temperatura e umidade relativa, conforme Silva et al. (2007).

Os parâmetros meteorológicos como a temperatura do ar, a temperatura do solo, a umidade relativa, a precipitação e as coberturas de nuvens são consideradas variáveis importantes na identificação de áreas com potencial de serem queimadas, de acordo com INMET (2014).

2.1.2 Interferências da Umidade Relativa do Ar para saúde

Estudos voltados a entender o comportamento climático vêm ganhando importância significativa nos últimos anos. Temas como aquecimento global, emissão de gases na atmosfera, índices pluviométricos, impactos da constante poluição, principalmente nas grandes cidades, qualidade do ar, índices de poluentes, raios solares, efeito estufa, etc. estão sendo constantemente debatidos e podem ser vistos em trabalhos de Magalhães e Zanella (2011), que buscaram entender o comportamento climático para a região de Fortaleza.

Mucelin e Bellini (2008) discutem os impactos ambientais no ecossistema urbano, enquanto que Espinosa et al. (2010), utilizando modelos matemáticos, buscaram prever os focos de calor do Mato Grosso do Sul.

Para Assis (2011), o processo de urbanização tem provocado uma série de mudanças e efeitos no clima local e, apesar disso ser reconhecido, há poucas informações e estudos dos impactos causados que possam auxiliar no planejamento de novos projetos urbanos. Conti (2005) discute as principais questões climáticas que vem sendo estudadas com especial interesse aos trabalhos que se dedicam às ciências da natureza e da sociedade.

Tais tópicos podem explicar uma série de fatores ligados à saúde e às mudanças climáticas e entender o comportamento destas séries climáticas, por meio de estudos de seus registros históricos pode auxiliar na orientação de adoção de novas políticas públicas.

De acordo com Back (2001, p. 717), “uma das grandes preocupações da comunidade científica na última década diz respeito às alterações climáticas e suas consequências para a humanidade”.

As mudanças climáticas podem produzir impactos sobre a saúde humana por diferentes vias. Por um lado impacta de forma direta, como no caso das ondas de calor, ou mortes causadas por outros eventos extremos como furacões e inundações. Mas muitas vezes, esse impacto é indireto, sendo mediado por alterações no ambiente como a alteração de ecossistemas e de ciclos biogeoquímicos, que podem aumentar a incidência de doenças infecciosas, mas também doenças não transmissíveis, que incluem a desnutrição e doenças mentais. (BARCELLOS et al., 2009, p.292).

Ainda, segundo os autores do excerto acima, modelos devem ser buscados a fim de relacionar processos climáticos com eventos ligados à saúde, pelo fato de que eventos climáticos extremos são de difícil previsão para a saúde pública.

Para Santos et al. (2011), o estudo do impacto das variáveis climáticas sobre o espaço urbano é de grande importância, sendo que essas informações podem orientar na tomada de decisões concernentes à preservação da qualidade de vida nos ambientes urbanos cada vez mais degradados.

De acordo com Gioda e Gioda (2006), em grandes cidades elevados níveis de poluição oriundos da circulação de automóveis, caminhões/ônibus, indústrias e outras fontes, associadas às constantes alterações entre níveis máximos e mínimos na temperatura e umidade relativa do ar, potencializam a concentração de poluentes causando danos à saúde. Os efeitos podem ser desde mudanças bioquímicas e fisiológicas a episódios de sinusite, hipertensão, ardência nos olhos, estresse, escamação da pele, perda dos sentidos, dificuldade de respirar, tosse e agravamento de doenças respiratórias e cardíacas.

Segundo Camargo e Furlan (2011), apesar da eficiência dos mecanismos termorreguladores do corpo humano, a alta temperatura associada à alta umidade do ar, juntamente com o trabalho muscular e à falta de aclimatação podem levar a pessoa ao estresse por calor. Este pode ocorrer tanto em ambientes internos quanto externos, seja em competições esportivas, seja em determinados ambientes laborais.

As alterações de temperatura, umidade e o regime de chuvas podem aumentar os efeitos das doenças respiratórias, assim como alterar as condições de exposição aos poluentes atmosféricos. O tempo de resistência de poluentes na atmosfera aumenta e podem ser transportados a longas distâncias em condições favoráveis de altas temperaturas e baixa umidade, afetando a saúde de populações distante das fontes geradoras, segundo Barcellos et al. (2009).

De acordo com Pinto et al. (2008), alguns cuidados devem ser tomados observando-se as faixas de porcentagem da umidade relativa do ar:

Caso estejam entre 20 e 30% (Estado de Atenção), recomenda-se:

- evitar exercícios físicos ao ar livre entre 11 e 15 horas;
- umidificar o ambiente através de vaporizadores, toalhas molhadas, recipientes com água, molhar os jardins, etc.;
- sempre que possível permanecer em locais protegidos do sol, em áreas vegetadas, etc.;
- consumir água à vontade.

Se estiverem entre 12 e 20% (Estado de Alerta), recomenda-se:

- observar as recomendações do estado de atenção;
- suprimir exercícios físicos e trabalhos ao ar livre entre 10 e 16 horas;
- evitar aglomerações em ambientes fechados;
- usar soro fisiológico para olhos e narinas.

E, abaixo de 12% (Estado de Emergência), a recomendação é:

- observar as recomendações para os estados de atenção e de alerta;
- determinar a interrupção de qualquer atividade ao ar livre entre 10 e 16 horas como aulas de educação física, coleta de lixo, entrega de correspondência, etc.;
- determinar a suspensão de atividades que exijam aglomerações de pessoas em recintos fechados como aulas, cinemas, etc. entre 10 e 16 horas;

- durante as tardes, manter com umidade os ambientes internos, principalmente quartos de crianças, hospitais, etc.

Na (Figura 2), é mostrado o diagrama de conforto humana da umidade relativa do ar em função da temperatura.

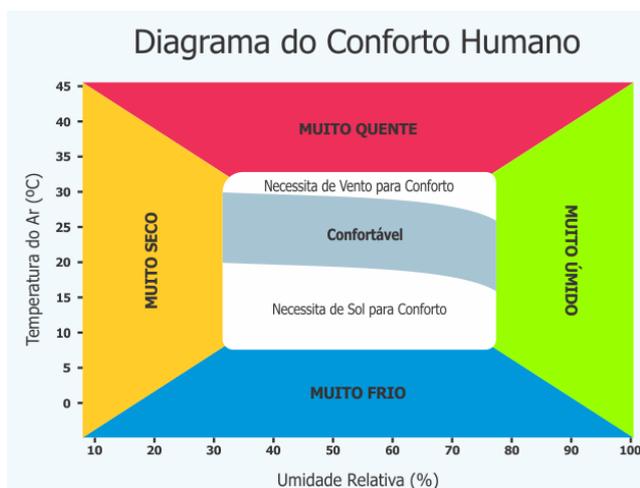


Figura 2 - Diagrama do conforto humano

Fonte: INMET (Instituto Nacional de Meteorologia)

De acordo com Marins (1998), é característico do clima brasileiro durante boa parte do ano, registrar altas temperaturas e altas umidades do ar o que recomenda cuidados especiais para a prática de exercícios físicos. As condições climáticas podem alterar as condições saudáveis dessas atividades e causar o surgimento do quadro de hipertermia ou hipotermia.

Ainda, segundo o autor acima citado, a umidade relativa do ar representa um importante elemento ambiental, interferindo decisivamente na formação e evaporação do suor, responsável pelo resfriamento do corpo. Quando a umidade está baixa, o suor produzido evapora-se facilmente, fazendo com que o corpo perca calor.

De acordo com Carter et al. (2007), em ambientes quentes e úmidos pode ocorrer um grave problema de saúde: o choque térmico. Este é uma causa persistente de morbidade e mortalidade em idosos e indivíduos mais propensos por diversos motivos, entre eles: atletas, militares, trabalhadores de construção civil e pessoas que realizam atividades físicas exaustivas.

Consoante Assis (2011), em grandes cidades, o estresse bioclimático causado pelo aumento da temperatura e diminuição da umidade relativa do ar vem afetando a saúde e a produtividade humana. Além de causar constante desconforto térmico, chuvas e enchentes, há um aumento dos índices de concentração de poluentes, que associados causam danos materiais e sociais.

Segundo Camargo (2007), os fatores relativos à temperatura do ar e à umidade relativa do ambiente influenciam diretamente na execução das tarefas, pois afetam o organismo humano, sendo que ambientes não climatizados associados à vestimenta, à atividade, à umidade relativa e à baixa velocidade do ar exerceram grande influência na insatisfação térmica de trabalhadores.

Para Guyton e Hall (2006), a taxa de perda de calor do corpo humano por meio da evaporação depende da umidade relativa do ar ambiente. Dessa forma, é extremamente importante a aclimação de pessoas que executam trabalhos braçais expostas a umidades do ar próximas a 100% e calor extremo. O aumento da tolerância a situações extremas de altas umidades do ar aumenta consideravelmente em 2 ou 3 semanas. Ainda segundo o mesmo autor, altas temperaturas associadas a altas umidades do ar podem elevar a temperatura corporal a um estado crítico causando sintomas que incluem desorientação, desconforto, vômitos, delírios, prejudicial aos tecidos cerebrais com eventual perda de memória, principalmente em situações que envolvam esforços físicos elevados.

As condições térmicas ambientais desfavoráveis (ambientes quentes e úmidos) ocasionam situações de estresse térmico, influenciam no desempenho das atividades humanas e, em certos casos, geram grandes tensões no trabalho, pois podem causar desconforto, fadiga, sonolência, risco de acidentes, insatisfação e, ainda, sérios danos à saúde, segundo Camargo e Furlan (2011).

Para Barbiero (2004), as condições ambientais nas variáveis temperatura do ar, velocidade e umidade do ar interferem na produtividade e na eficiência de funcionários de empresas aumenta o risco de acidentes e compromete a saúde. Ainda, segundo o autor, a saúde, a satisfação, a segurança e a produtividade são quesitos que estão ligados a um ambiente de trabalho saudável e termicamente neutro.

Segundo o Ministério da Saúde (2008), é necessário intensificar os estudos climáticos a nível regional para verificar os impactos desses eventos na dinâmica das doenças infecciosas, apesar de haver dificuldade em se obter dados climáticos e de saúde, com uma série histórica que permita avaliar o impacto das anomalias climáticas na saúde. Também

destaca que os impactos das mudanças climáticas vêm ameaçando as conquistas e os esforços na redução das doenças transmissíveis e não transmissíveis.

Ainda, segundo o Ministério da Saúde (2008), novas metodologias devem ser utilizadas, o que inclui a análise de extensas séries temporais com fatores climáticos, sendo também necessário implementar sistemas de alertas baseados em parâmetros ambientais que possam detectar antecipadamente as incidências de doenças infecciosas.

2.1.3 Processo de obtenção da Umidade Relativa do Ar

Palmieri (2009, p.24) defende que “a concentração de vapor de água que a atmosfera consegue reter é relativamente pequena, chegando a um máximo de 4% em volume”.

Apesar da baixa concentração na atmosfera, o vapor d’água é um fator atmosférico importantíssimo por interferir na distribuição da temperatura, absorção e emissão de calor sensível, além de atuar como veículo de energia ao transferir calor latente de evaporação, de uma região para outra, o qual é liberado como calor sensível, quando o vapor se condensa, de acordo com Silva (2006).

Segundo Delgado et. al. (2007), a aplicação de equações para o cálculo da umidade relativa do ar é essencial na agricultura, visto que esta variável meteorológica pode causar danos principalmente aos cultivos agrícolas.

Dados climáticos podem ser coletados em estações e postos meteorológicos, uma estação de coleta de dados meteorológicos é um local adequado e bem planejado, que contém um conjunto de instrumentos aptos a fornecerem: a temperatura, a direção e velocidade dos ventos, os volumes de precipitações, o tempo de insolação, a umidade da atmosfera, a capacidade de evaporação etc.(ANDRADE et al., 2011, p. 48).

De acordo com o INMET (2014), o psicrômetro mede a umidade relativa do ar de modo indireto em porcentagem (%). Compõe-se de dois termômetros idênticos, um denominado termômetro de bulbo seco (termômetro de mercúrio, com seu bulbo apenas exposto ao ar), e outro com o bulbo envolvido em gaze ou cadarço de algodão mantido constantemente molhado, denominado termômetro de bulbo úmido (tem seu bulbo envolvido por um condão umedecido em água a qual evapora, possibilitando assim o cálculo da umidade relativa do ar pela diferença de temperatura).

De acordo com Barbiero (2004), a umidade relativa do ar (e) é a relação da pressão parcial do vapor de água (p_a) e a pressão de saturação de vapor de água (p_{as}) na mesma temperatura e pressão atmosférica, dada pela equação:

$$p_{as} = 0,621 \cdot \exp\left(\frac{17,20t_a}{t_a + 237,3}\right) \quad (1)$$

$$p_a = -6,27 \times 10^{-4}(t_a - t_{bu}) \quad (2)$$

$$e = \frac{p_a}{p_{as}} \quad (3)$$

onde,

t_a = temperatura do ar °C;

t_{bu} = temperatura de bulbo úmido °C;

A umidade relativa do ar é utilizada em (%), de acordo com a equação:

$$UR = 100 \cdot e \quad (4)$$

Um ambiente é dito saturado a uma determinada temperatura, quando possui a quantidade máxima possível de vapor d'água àquela temperatura. No caso da atmosfera, quando a quantidade de vapor atinge o máximo, diz-se que o ar está saturado, segundo Silva (2006).

Entre as diversas formas de se obter a umidade relativa do ar, a mais usual é a leitura de termômetros de bulbo seco e úmido e transformação dos dados através de leitura de tabelas. Uma das tabelas é formada pela leitura do diagrama psicrômetro (Figura 3), sendo este tipo de tabela bastante utilizado na conservação de sementes e a própria secagem para a estocagem de produtos. Para efetuar a leitura da umidade relativa do ar através dele, seguem-se os passos de acordo com Embrapa (2010):

- 1) fazer a leitura no psicrômetro de bulbo seco e bulbo úmido;
- 2) identificar os eixos (eixo na horizontal bulbo seco, eixos na diagonal bulbo úmido);
- 3) a UR é dada pelo ponto de encontro entre os eixos da diagonal (bulbo úmido) e horizontal (bulbo seco) representada pela curva de linha vermelha.

A relação entre a pressão parcial e a pressão de vapor saturado define a umidade relativa do ambiente.

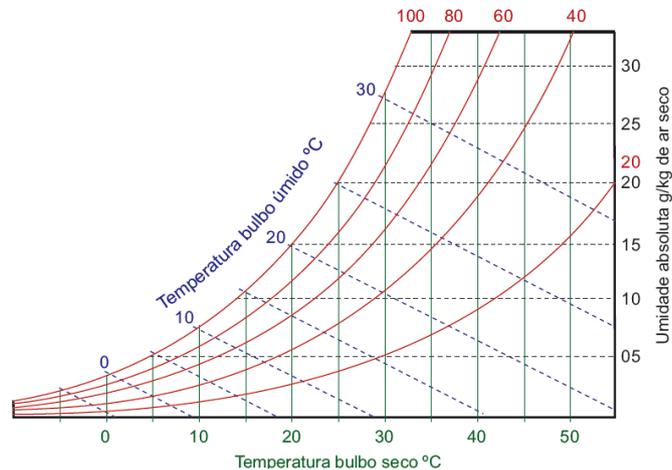


Figura 3 - Diagrama psicrômetro

Fonte: Embrapa (2010)

2.1.4 Instrumentos de medição da Umidade Relativa do Ar

A obtenção de dados climáticos tem gerado avanços enormes nas pesquisas. As informações meteorológicas contribuem com a sociedade brasileira em suas tomadas de decisões auxiliando a gerar o desenvolvimento do país, segundo o INMET (2014).

A umidade relativa do ar tem como instrumento de referência o psicrômetro, como citado anteriormente. Os psicrômetros mais simples podem ser separados em dois grupos, os ventilados e não ventilados e, segundo Palmieri (2009), o ventilado é o mais comumente utilizado e sua ventilação depende do fluxo de ar do ambiente.

Na Figura 4, pode-se observar dois modelos: o psicrômetro de funda, cuja ventilação é obtida fazendo girar o suporte dos termômetros e, o Assman, com aspirador mecânico embutido na parte superior.



Figura 4 - Psicômetro de funda (esquerda) e psicômetro Assmann (direita)

Fonte: (SILVA, 2006, p. 149)

O aparelho que fornece a umidade relativa do ar diretamente e é bastante utilizado por estações meteorológicas mais sofisticadas é o higrômetro, que pode ser observado na (Figura 5).

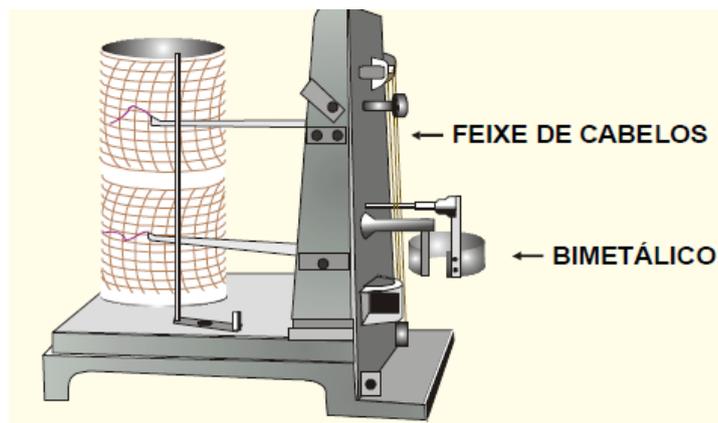


Figura 5 - Higrômetro

Fonte: (SILVA, 2006, p. 154)

Apesar de serem bastante utilizados, os aparelhos acima citados, estão sendo substituídos por aparelhos digitais. Segundo Silva et. al. (2007), os sistemas automáticos permitem controlar de forma segura e rápida as características do ambiente, apresentando vantagens em relação aos sistemas analógicos.

A seguir são apresentados os modelos de séries temporais utilizados nesta pesquisa.

2.2 Modelos de séries temporais

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

De acordo com Batista (2009), no estudo de uma série histórica, busca-se investigar o mecanismo gerador da série temporal, fazer previsões de valores futuros, descrever o seu comportamento, avaliar os fatores que influenciam no seu comportamento, buscando relações de causa e efeito, além de construir um modelo apropriado no intuito de se realizar previsões para embasar tomadas de decisão.

Para Morettin e Toloí (2004), a previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma conseqüente tomada de decisão, visando atingir determinados objetivos.

Diversos sistemas de apoio para a tomada de decisão utilizam métodos que envolvem previsões de fatos e situações futuras. Dentre eles, podem ser citados, por exemplo: previsão de vendas para planejamento de produção industrial, demandas de energia elétrica, previsões de temperaturas médias e estimativa de preços de ações na bolsa de valores, além de inúmeros outros. Para tanto, há um conjunto de técnicas disponíveis que dependem do tipo de série analisada e do objetivo pretendido, segundo Ribeiro et al. (2009).

De acordo com Werner e Ribeiro (2006), realizar previsões de demanda é importante para as empresas assegurarem sua participação nos mercados locais e internacionais. Em tempos de globalização, essa atividade torna-se fundamental para enfrentar a concorrência e as exigências do consumidor que mudam continuamente. Previsões confiáveis podem exigir a

utilização de vários métodos e modelos que vão variar de acordo com o comportamento da série temporal.

Sabe-se que os eventos não são iguais, porém não são completamente diferentes. Para Silva (2012), abstraindo-se as regularidades dos fenômenos observáveis de uma série é possível construir um modelo matemático como uma representação da realidade.

Para que seja possível prever os valores futuros com base em valores passados é necessário que se disponha de uma memória histórica de dados ocorridos anteriormente e que esses dados sejam confiáveis. Todavia, o conjunto de dados, por si só, não permite a previsão dos valores futuros. Para isso, é necessário a utilização de técnicas ou métodos de previsão estatísticos de séries temporais, que podem envolver cálculos simples ou procedimentos complexos com auxílio de programas específicos, segundo Ribeiro et al. (2009).

A construção de modelos depende de vários fatores, tais como o comportamento do fenômeno ou o conhecimento a priori que temos de sua natureza e do objeto da análise. Na prática, depende, também, da existência de métodos ótimos de estimação e da disponibilidade de programas (*software*) adequados. (MORETTIN e TOLOI, 2004, p.21).

Santos e Costa (2008) defendem que uma série temporal é simplesmente uma realização de um processo estocástico. Dessa forma, assume-se que cada valor de uma série $Z = (Z_1, Z_2, \dots, Z_t)$, é extraído aleatoriamente de uma distribuição de probabilidade. Assim, se fosse possível especificar a função de distribuição de probabilidade de uma determinada série temporal, se poderia determinar também a probabilidade de um resultado futuro da série.

Para Box et al. (1994), um processo estocástico é qualquer fenômeno estatístico que evolui no tempo de acordo com as leis probabilísticas e pode-se entendê-lo como um modelo que descreve a estrutura probabilística de uma sequência de observações.

Segundo Souza e Camargo (1996, p. 26), “o objetivo de um modelo é clarificar a estrutura e a dinâmica do fenômeno e, ajudar a fazer previsões e controlar o sistema”.

Conti (2005) advoga que séries temporais são indicadores estatísticos quantitativos e sua análise tem por objetivo descrever o comportamento, investigar o mecanismo gerador e fazer previsões. Podem expressar tendências, ciclos e variabilidade relevantes ou se revelar aleatórias, derivando daí sua aplicabilidade em climatologia.

Segundo Figueredo (2008), dentre os modelos quantitativos destacam-se, na análise de séries temporais, os modelos de correlação, que consistem em analisar dados históricos de um produto com o uso de modelos matemáticos para projetar a demanda futura.

Vários modelos estatísticos foram desenvolvidos para auxiliar na tarefa de previsão de séries temporais, como por exemplo: os modelos de Alisamento Exponencial (simples, linear de Brown, bi paramétrico de Holt, sazonal de Holt-Winters), modelos autorregressivos (AR), de médias móveis (MA), Modelos mistos (ARIMA, SARIMA, ARCH, GARCH, ARMAX), entre outros. Além disso, tecnologias de inteligência computacional, tais como redes neurais, lógica nebulosa e algoritmos genéticos, proporcionam a criação de metodologias avançadas de previsão.

Uma série temporal pode ser definida simplesmente como qualquer conjunto de observações ordenadas no tempo, de acordo com Morettin e Toloí (2004), sendo expressa por:

$$Z_t = \{Z_t \in \mathbb{R} \mid t = 1, 2, 3, \dots, N\} \quad (5)$$

Onde t é um índice temporal e N é o número de observações. Considerando a existência de observações de uma série temporal até o instante t , a previsão no instante $t+h$ é denotada por $\hat{Z}_t(h)$, cuja origem é t e o horizonte de previsão é h . As previsões em $Z(t+1)$, $Z(t+2)$, $Z(t+h)$, podem ser ilustradas por meio do exemplo contido na (Figura 6).

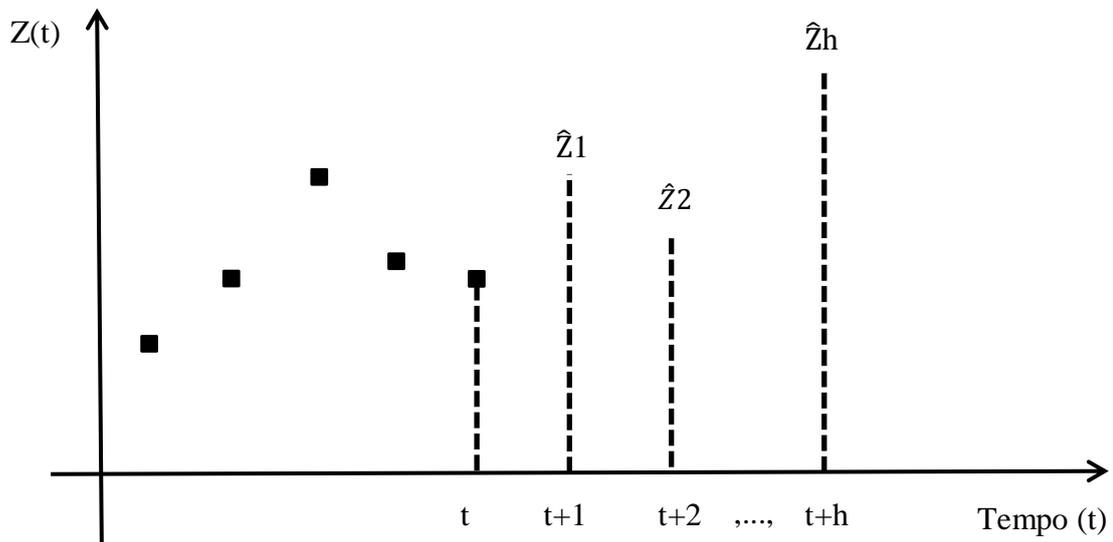


Figura 6 - Observações de uma série temporal com previsões de origem t e horizontes de previsão iguais a um, dois e h passos à frente (adaptado de Morettin e Toloí, (2004))

As séries temporais podem ser compostas por quatro elementos:

1) Tendência (T_t): é caracterizado por um movimento em longo prazo e suave, indicando um padrão crescente ou decrescente, ao longo das observações no tempo. Deve-se ressaltar que a tendência pode ser linear.

2) Sazonalidade (S_t): é caracterizado por um movimento cíclico, que apresenta um padrão comum num pequeno período de tempo, ou seja, de curta duração, em geral, inferior a um ano.

3) Ciclo (C_t): é caracterizado por um padrão “ondulado” e descreve uma tendência a longo prazo, que geralmente, aparece depois de alguns anos.

4) Variações aleatórias (ε_t): compreende as mudanças irregulares na série temporal, que não são causadas por qualquer outro componente. São aleatórios e não previsíveis.

De acordo com Oliveira et al. (2010), os métodos de decomposição utilizados assumem que uma série temporal é constituída por um conjunto de componentes não observáveis. Dessa forma, o procedimento consiste em analisar cada uma das componentes presentes na série individualmente (tendência, sazonalidade, ciclo e aleatoriedade), permitindo que o comportamento da série temporal seja mais bem compreendido e a extrapolação para o futuro possa ser realizada.

Assim, uma série temporal pode ser representada, genericamente, por suas componentes nos seguintes modelos:

Modelo Aditivo:

$$Z_t = T_t + S_t + C_t + \varepsilon_t, \quad (6)$$

e o modelo multiplicativo:

$$Z_t = T_t \cdot S_t \cdot C_t \cdot \varepsilon_t \quad (7)$$

De modo geral, toda a série temporal pode ser decomposta, o que permite analisar suas componentes e detectar as principais características da mesma.

Para Rocha (2011), os métodos de previsão de séries temporais baseiam-se na ideia de que as observações passadas contêm todas as informações sobre o comportamento da série e possam ser usados para prever fenômenos no futuro, ou seja, os acontecimentos que influenciaram a série são recorrentes no tempo, e o processo estocástico gerador das observações passadas produzirá, em continuidade, as observações do futuro.

Conforme Silva (2012), a partir da compreensão do mecanismo associado à série temporal, é possível descrever efetivamente o comportamento da série, encontrar sua periodicidade e tentar obter razões para seu comportamento. A previsão de valores futuros pode ser realizada a longo, médio ou curto prazo, sendo importante para tomada de decisões. Todos esses objetivos estão interligados e podem ser utilizados para reduzir ao máximo os erros de previsão.

Para Pereira (1984), um modelo funcional deve ser simples e com um número mínimo de parâmetros que, se possível, possam ser interpretados facilmente e identificados com algum aspecto da realidade, ou seja, um modelo que permita manipulação matemática fácil e que atenda às inferências necessárias a seu respeito.

A seguir são apresentados alguns testes utilizados nas séries antes de proceder à modelagem.

2.2.1 Teste de estacionariedade Dickey-Fuller

O teste Dicky-Fuller foi desenvolvido para detectar a presença de raiz unitárias nos polinômios autorregressivos de séries temporais. O teste pressupõe que a série é gerada por um processo autoregressivo de ordem AR(p). O número de raízes unitárias (ordem de integração) é dado pelo número de vezes que a série deve ser diferenciada para se tornar estacionária. Há grande interesse em detectar a presença de raízes unitárias na série devido a importantes implicações nas modelagens subsequentes, de acordo com Maia e Cribari-Neto (2006), Alves e Bacchi (2004).

Segundo Nascimento (2013), o conceito de estacionariedade é importante, pois quando a série está estacionária, as propriedades estatísticas como média, variância e autocorrelação observadas no passado são as mesmas no futuro.

O teste apresenta duas variações, o teste Dickey-Fuller (1979) e o Dickey-Fuller Aumentado (1981). O mais usual é o teste Dickey-Fuller Aumentado (DFA) descrito a seguir segundo Margarido e Junior (2006), Silva, et. al. (2011) e Bueno 2008 e Dickey-Fuller (1979, 1981):

Hipótese do teste:

$H_0 = \phi_1 = 1$: a série não estacionária;

$H_1 = \phi_1 < 1$: a série é estacionária.

O teste ADF é realizado a partir da estimação de uma autorregressão de Z_t em função de Z_{t-1} e dos termos defasados de ΔZ_t por mínimos quadrados.

A estatística do teste:

$$\hat{\alpha} = \frac{\sum_{t=1}^N Z_{t-1} Z_t}{\sum_{t=1}^N Z_{t-1}^2} - 1 \quad (8)$$

Em seguida, estima-se a variância amostral:

$$S^2 = \frac{1}{N-1} \sum_{t=1}^N (\Delta Z_t - \hat{\alpha} Z_{t-1})^2 \quad (9)$$

Calcula, a seguir, o desvio-padrão do coeficiente:

$$S(\hat{\alpha}) = \frac{S}{\sqrt{\sum_{t=1}^N Z_{t-1}^2}} \quad (10)$$

O valor calculado da estatística:

$$\hat{\tau} = \frac{\hat{\alpha}}{S(\hat{\alpha})} \quad (11)$$

O critério é de rejeição da hipótese nula se $\hat{\tau} < \tau$, em que τ é os valores críticos obtidos por meio de simulação de Monte Carlo.

2.2.2 Testes para tendência

O primeiro passo recomendado para a análise de uma série histórica é a construção de seu gráfico, pois poderá revelar características importantes da série, como tendência, sazonalidade, variabilidade, observações atípicas, entre outras características. Além dessa inspeção gráfica, é possível utilizar testes de hipótese estatísticos para verificar a presença de tendência na série em estudo, de acordo com Morettin e Tolo (2004). A seguir é apresentado o teste de sequências testes.

2.2.2.1 Teste de sequências (Wald-Wolfowitz)

Segundo Morettin e Toloi (2004), seja a série temporal Z_t , $t = 1, \dots, N$, considerando N observações e “ m ” a mediana desses valores. Para cada valor Z_t , atribui-se o símbolo A se este for maior ou igual à mediana, e B , se for menor. Assim, tem-se $N = (n_1 \text{ pontos } A) + (n_2 \text{ pontos de } B)$. As hipóteses consideradas são:

H_0 : não há tendência;

H_1 : há tendência;

A estatística usada é: $T_1 =$ número de sequências diferentes observadas

Rejeita-se a hipótese nula H_0 se há poucas sequências, ou seja, T_1 for pequeno. Para um dado nível de significância α , rejeita-se H_0 se $T_1 < W_\alpha$, onde W_α é o α -quantil da distribuição de T_1 que é tabelado.

Para n_1 ou n_2 maior que 20, pode-se usar à distribuição normal dada por $T_1 \sim N(\mu, \sigma^2)$ onde:

$$\mu = \frac{2n_1n_2}{N} + 1 \quad (12)$$

$$\sigma = \sqrt{\frac{2n_1n_2(2n_1n_2 - N)}{N^2(N - 1)}} \quad (13)$$

A estatística de teste é dada por:

$$Z_{\text{calc.}} = \frac{T_1 - \mu}{\sigma} \quad (14)$$

A decisão é tomada, comparando-se o valor de $Z_{\text{calc.}}$ com o valor de $Z_{\text{tab.}}$ extraído da tabela da distribuição normal padrão, de acordo com o nível de significância α .

2.2.3 Testes para sazonalidade

Sazonalidade é um fenômeno que se repete em períodos regulares como aumento da venda de aquecedores no inverno, de sorvete no verão, de passagens aéreas no período do verão, de vendas no comércio no período de natal, de acordo com Morettin e Tolo (2004).

Ainda, segundo os autores, as séries sazonais são caracterizadas por apresentarem correlação alta em “lags sazonais”, isto é, lags que são múltiplos de período “S”. A sazonalidade pode ser determinante quando os movimentos intraperiódicos são constantes ou estocásticas quando os movimentos não são constantes.

Abaixo são apresentados alguns testes para auxiliar a detectar a presença de sazonalidade nas séries.

2.2.3.1 Teste de Kruskal-Wallis

Uma das possibilidades de identificar a sazonalidade em séries é por meio do teste de Kruskal-Wallis descrito conforme Morettin e Tolo (2004). Considerando que os dados são coletados em períodos com espaçamentos iguais de tempo, cada coluna K é considerada uma amostra de tamanho n_j , ou seja, as observações são:

$$Y_{ij}, j = 1, \dots, n_j, N = \sum_{j=1}^k n_j \quad (15)$$

As observações Y_{ij} são substituídas pelos correspondentes postos ou ordens R_{ij} , obtidos ordenando todas as N observações, sendo $R_{.j}$ a soma dos postos associados à j-ésima amostra.

$$R_{.j} = \sum_{i=1}^{n_j} R_{ij}, j = 1, \dots, k. \quad (16)$$

As hipóteses consideradas são:

H_0 : não existe sazonalidade se $T_1 < T_{1c}$

H_1 : existe sazonalidade se $T_1 \geq T_{1c}$

Estatística de teste:

$$T_1 = \frac{12}{N(N+1)} \sum_{j=1}^k R_{.j}^2 - 3(N+1) \quad (17)$$

O valor crítico T_{1c} (valor tabelado da χ^2) é tal que $P_h(T_1 \geq T_{1c}) = \alpha$ e α é o nível de significância do teste. Para n_j suficientemente grande $K \geq 4$, sob H_0 a distribuição T_1 pode ser aproximada por uma variável χ^2 com $K - 1$ graus de liberdade.

2.2.3.2 Teste de Friedman

A ordenação dos dados é feita dentro de blocos que são considerados independentes.

As hipóteses consideradas são:

H_0 : não existe sazonalidade se $T_2 < T_{1c}$

H_1 : existe sazonalidade se $T_2 \geq T_{1c}$

A estatística do teste de Friedman de acordo com Morettin e Toloí (2004) é:

$$T_2 = \frac{12}{p \cdot k(k+1)} \sum_{j=1}^k R_{.j}^{*2} - 3p(k+1) \quad (18)$$

Onde p = número de blocos, k = número de tratamentos e $R_{.j}^{*2}$ denota a soma dos postos da j -ésima coluna.

O valor crítico T_{1c} é um valor tabelado da χ^2 , a distribuição T_2 pode ser aproximada por um χ^2 com $K - 1$ graus de liberdade um nível de significância estabelecido.

A seguir são apresentados alguns conceitos importantes referentes à classe de modelos de séries temporais desenvolvidos por Box e Jenkins.

2.2.4 Modelos Box-Jenkins

De acordo com Batista (2009), dentre as classes de modelos paramétricos a classe de modelos autorregressivos integrados e de médias móveis (ARIMA), ou ainda, modelos de Box-Jenkins vêm sendo largamente utilizados.

Para Reisen et al. (2008), a metodologia proposta por Box-Jenkins tem sido a mais utilizada para modelagem e previsão de séries temporais e vem sendo amplamente utilizada em diversas áreas do conhecimento como na hidrologia.

Esses modelos, genericamente conhecidos por ARIMA ou Autorregressivos Integrados de Médias Móveis são modelos matemáticos que visam captar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal e, com base nesse comportamento, realizar previsões futuras, segundo Danfá (2009).

A filosofia da modelagem Box e Jenkins se utiliza de duas ideias: o princípio da parcimônia e a construção de modelos através de ciclo iterativo. O princípio da parcimônia estabelece a escolha de um modelo com o menor número de parâmetros possíveis, para adequada representação matemática. O ciclo iterativo é uma estratégia de seleção de modelos a ser empreendidas até que tenhamos um modelo satisfatório. (SOUZA e CARMARGO, 1996, p. 27).

Os autores Box et al. (1994) subdividem os modelos ARIMA em quatro categorias: (i) modelos autorregressivos, identificados como modelos AR(p), que modelam as estruturas de autocorrelação da variável em relação a valores passados; (ii) modelos de médias móveis, chamados de modelos MA(q), que englobam a estrutura de autocorrelação relacionada aos erros de previsão anteriores; (iii) modelos autorregressivos e de médias móveis, simbolizados por ARMA(p,q) e (iv) modelos autorregressivos integrados e de média móvel, chamados de modelos ARIMA (p,d,q), que usam diferenciações para tornar a série estacionária.

Para Lúcio et al. (2010), a metodologia Box-Jenkins supõe que o procedimento de filtragem do ruído branco pode ser decomposto em três etapas: (1) média móvel, (2) autorregressivo estacionário e (3) diferenciação, caso não seja estacionário. Os termos autorregressivos correspondem a defasagens na série transformada (série estacionária induzida por diferenciação) e as médias móveis correspondem a defasagens dos erros aleatórios. O termo integrado refere-se ao processo de diferenciação da série original.

Ainda, segundo Lúcio et al. (2010), uma das ferramentas utilizadas pela metodologia Box-Jenkins é a função de autocorrelação, que pode indicar o grau de dependência temporal

existente, medindo o quanto os pares ordenados de observações estão relacionados, e tem seus valores variando entre -1 e +1. Também, pode-se recorrer à função de autocorrelação parcial, que mede a intensidade da relação entre duas observações da série temporal controlando para as demais.

“A classe de modelos ARIMA, será capaz de descrever de maneira satisfatória séries estacionárias e séries não estacionárias mas que não apresentem comportamento explosivo”, de acordo com Morettin e Toloí (2004, p.4).

A identificação do modelo ARIMA é talvez a parte mais crítica do processo iterativo da metodologia proposta por Box-Jenkins. Nessa fase, devem ser determinadas as ordens simples (p,q) e sazonal (P,Q) do modelo, assim como as ordens de integração (d,D). Conforme Morettin e Toloí (2004), essa escolha é realizada, principalmente, com base nos gráficos de autocorrelações (ACF) e autocorrelações parciais (PACF).

De acordo com Box et al. (1994), a forma de trabalho indicada para a busca de um modelo estocástico que represente uma série temporal é um processo iterativo que consiste de três fases: identificação, estimação e diagnóstico, resumidas a seguir:

- na fase de identificação é pesquisada qual a classe de modelos é adequada ao estudo por meio de um exame detalhado da série, onde é verificada a condição de estacionariedade, são reconhecidas as estruturas comportamentais como tendência, sazonalidade, periodicidades, e ainda são observadas as autocorrelações;

- na fase da estimação é verificada a adequabilidade do modelo considerado a partir de parâmetros estimados, após a identificação das características da série, optando-se pelo processo apropriado aos dados (processo univariado, múltiplo, entre outros);

- na fase de diagnóstico é feita a conferência do ajuste do modelo por meio da análise de resíduos, testes estatísticos e critérios de seleção/adequação de modelos.

Na Figura 7, é apresentado um esquema de análise de séries temporais.

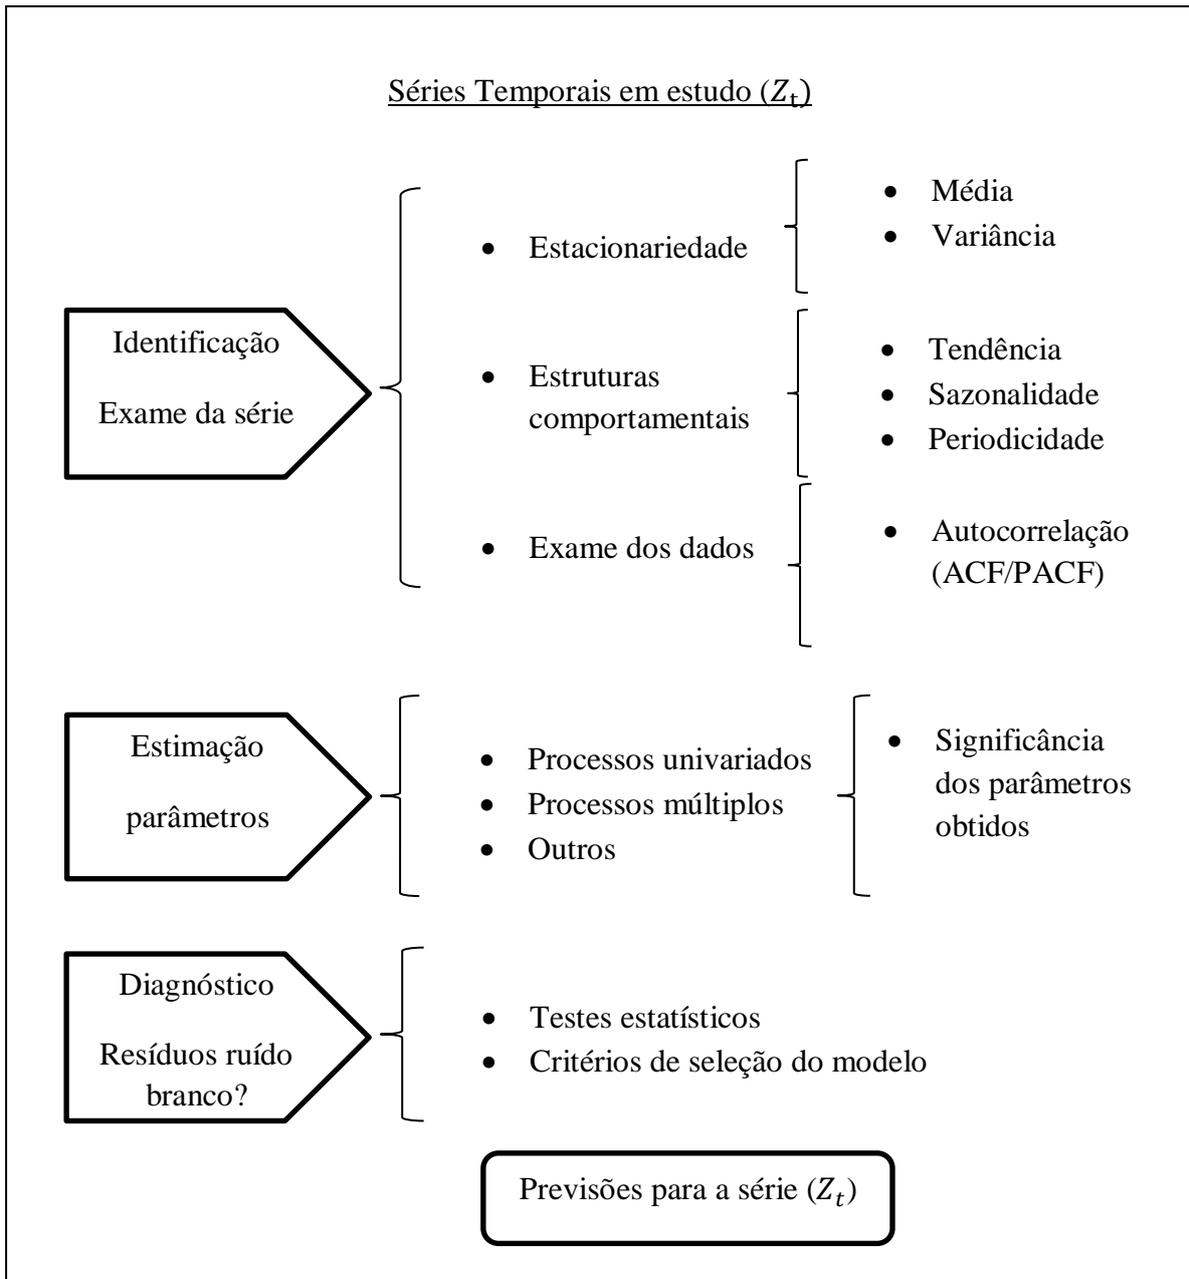


Figura 7 - Aplicação dos métodos de análise de séries temporais

Fonte: (BARBIERO, 2003, p.38)

Segundo Werner e Ribeiro (2003), quando uma série temporal apresenta média e variância dependentes do tempo, é porque ela não é estacionária. A não-estacionariedade de uma série implica em que:

a) há inclinação nos dados e eles não permanecem ao redor de uma linha horizontal ao longo do tempo e/ou

b) a variação dos dados não permanece essencialmente constante, isto é, as flutuações aumentam ou diminuem com o passar do tempo, indicando que a variância está se alterando.

Como a maioria dos procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias, será necessário transformá-las caso ainda não sejam. O processo mais simples de transformação consiste em tomar diferenças sucessivas da série original até obter uma série estacionária.

O número (d) de diferenças simples necessárias para tornar a série estacionária é denominado ordem de integração. De acordo com Batista (2009), se a série torna-se estacionária após d diferenças, é chamada integrada (I) de ordem d.

Sendo assim, o modelo ARMA integrado passa a ser denominado de modelo ARIMA. A inclusão do termo ordem de integração permite que sejam utilizados os modelos ARIMA (p,d,q) dados pela equação:

$$\Delta^d Z_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t - \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}} \quad (19)$$

em que os parâmetros ϕ_1, \dots, ϕ_p , são os parâmetros referentes à parte autorregressiva e $\theta_1, \dots, \theta_q$, são os parâmetros de médias móveis, ε_t é o erro que não pode ser estimado pelo modelo e d representa o número de diferenças aplicadas na série.

Segundo Bueno (2008), para um bom ajuste do modelo de Box-Jenkins, é fundamental que a estrutura residual seja ruído branco, isto é, média zero, variância constante e erros não correlacionados com qualquer realização da própria série (autocorrelação igual a zero).

De acordo com Pedroso, et al. (2006), os modelos Box-Jenkins são baseados em processos estocásticos e devem apresentar algumas características para que os mesmos possam ser estimados:

- as observações deverão ser espaçadas em intervalos iguais no tempo e a série deverá ter no mínimo 50 observações;

- a série deve ser estacionária, ou seja, são mantidas as mesmas características estocásticas ao longo da série, como, por exemplo, a mesma média, variância e covariância. Assim, a média de partes da série não deve ser, significativamente, diferente da média de toda a amostra;

- a série pode ainda ser não estacionária homogênea, ou seja, a amostra pode se tornar homogênea por processo de diferenciação ou integração.

Para Figueredo (2008), os modelos AR, MA e ARMA são modelos de séries lineares estacionárias que se caracterizam por se desenvolverem no tempo ao redor de uma média constante. Já os modelos ARIMA e SARIMA, são modelos lineares não-estacionários homogêneos que, através do processo de diferenciação, tornam-se estacionários por não apresentarem comportamento explosivo em seus dados.

2.2.4.1 Modelo Autorregressivo

O modelo autorregressivo (AR) de ordem p é gerado pela combinação das observações passadas, mais o erro aleatório (ε_t), segundo Morettin (2008). O modelo é explicado pelas observações passadas, sendo representado pela equação:

$$Z_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t, \quad (20)$$

onde Z_t corresponde às observações históricas da série e consideramos $d=q=0$;

ϕ_p correspondem aos parâmetros autorregressivos;

ε_t representa os erros que não podem ser explicados pelo modelo.

De acordo com Figueredo (2008), a condição para que uma série AR(p) seja estacionária é que $|\phi| < 1$, se $\phi \geq 1$ o processo passa a ser não estacionário, com seus valores explodindo com o tempo.

2.2.4.2 Modelo de Médias Móveis

O modelo de médias móveis (MA) é explicado pelos erros de previsão de observações passadas. De acordo com Morettin (2008), o processo de medias móveis (MA) de ordem q é definido conforme a equação:

$$Z_t = \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}, \dots, -\theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}} + \varepsilon_t, \quad (21)$$

onde, θ_q correspondem as ordens do modelo (MA);

ε_t representa os erros que não podem ser explicados pelo modelo, e $p=d=0$.

Todo o processo de modelagem (MA) considera que a série em estudo seja estacionária.

2.2.4.3 Modelo Autorregressivo e de Médias Móveis

O modelo ARMA é a simples combinação dos processos autorregressivos (AR) e de médias móveis (MA), segundo Bueno (2008). Definindo assim o modelo misto ARMA (p,q), que modelam séries que não podem ser explicadas puramente pelos modelos AR ou MA. Os modelos ARMA relacionam os valores futuros com as observações passadas e podem ser representadas por:

$$Z_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2}, \dots, + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t - \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}, \dots, -\theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}}, \quad (22)$$

Os modelos (AR), (MA) e (ARMA) possuem uma característica em comum que considera modelos onde a série é estacionária $d = 0$.

2.2.4.4 Modelo SARIMA

Em estudos de variáveis ambientais é comum encontrar sazonalidade nas séries segundo Reisen et al. (2008), o que remete à necessidade de utilizar modelos que incorporem essa importante característica temporal. Nesse contexto, foram ampliados os modelos ARIMA para os modelos SARIMA (p,d,q)(P,D,Q) representados por:

$$\nabla^D \Delta^d Z_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t - \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} + \dots - \theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}} \quad (23)$$

$$+ \underbrace{\Phi_1 Z_{t-1s} + \Phi_2 Z_{t-2s} + \dots + \Phi_P Z_{t-P}}_{\text{autorregressivo sazonal (P)}} - \underbrace{\Theta_1 \varepsilon_{t-1s} - \Theta_2 \varepsilon_{t-2s} + \dots - \Theta_Q \varepsilon_{t-Q}}_{\text{médias móveis sazonal (Q)}}$$

em que (p,d,q) são as ordens do modelo referentes a parte ordinal ou simples, enquanto que (P,D,Q) são referentes às ordens do modelo da parte sazonal. Os parâmetros Φ_1, \dots, Φ_P são os parâmetros referentes à parte autorregressiva; $\Theta_1, \dots, \Theta_Q$, são os parâmetros de médias móveis referentes à parte sazonal; ε_t é o erro que não pode ser estimado do modelo; d representa número de diferenças da parte ordinal e D representa o número de diferenças da parte sazonal.

A utilização dos modelos SARIMA em estudos ambientais tem apresentado resultados consistentes na modelagem e previsão de séries temporais, mostrando assim ser uma ferramenta útil e que deve ser considerada quando se pretende realizar um ajuste de modelo, segundo Reisen et al. (2008).

2.2.4.5 Modelo ARMAX

O modelo ARMAX é um modelo múltiplo que possibilita a análise de mais de uma variável correlacionada à previsão de Z_t , sendo a variável endógena dependente e as variáveis explicativas exógenas independentes, de acordo com Silva (2011).

Segundo Martínez e Zamprogno (2003) e Ozaki e Admi (2012), o modelo ARMAX (autorregressivo com médias móveis e entrada de variáveis exógenas) baseia-se em um modelo ARMA, onde é possível combiná-lo com uma estrutura de regressão (variáveis explicativas) na forma:

$$Z_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \underbrace{\beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_r Y_{t-r}}_{\text{variável independente}} + \varepsilon_t - \underbrace{\theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} + \dots - \theta_q \varepsilon_{t-q}}_{\text{médias móveis (q)}} \quad (24)$$

onde Z_t é a variável dependente, y_t é a variável independente, ε_t é ruído branco, ϕ_i e θ_i são os parâmetros desconhecidos, β_i é o coeficiente da variável exógena e ε_t é a sequência de resíduos do modelo. Esta estrutura pode considerar a inclusão de mais variáveis explicativas (exógenas). Quando a série é não estacionária, sendo necessário aplicar diferenças na série, o modelo ARMAX passa a se denominar ARIMAX. Para Almeida (2008), quando se inclui ao modelo ARIMA a variação sazonal e variáveis externas explicativas, o novo modelo denomina-se de SARIMAX.

Conforme Chechi e Sanches (2013) e Lizzi (2012), o modelo SARIMAX é uma extensão do modelo ARIMA/SARIMA onde podem se incluir variáveis explicativas por meio de estrutura de regressão.

Desse modelo podem derivar outros modelos como ARIX (p,d,0,r[]), IMAX (0,d,p,r[]) ARMAX (p,0,q,r[]), ARX (p,0,0,r[]), MAX (0,0,q,r[]), de acordo com Andrade (2009).

Ainda, segundo este autor, as etapas para estimação de um modelo ARIMAX/SARIMAX são as mesmas do modelo ARIMA/SARIMA, com a diferença que, além da estimação das ordens dos coeficientes dos modelos, é preciso estimar os coeficientes das variáveis exógenas.

2.2.4.6 Modelos para Estimativa da Volatilidade ARCH/CARCH

O uso de modelos de séries temporais tem se mostrado de grande importância quando aplicados a dados ambientais e, em muitos casos, tem se tornado interesse do pesquisador, além de investigar o comportamento da série, estudar a sua volatilidade, segundo Zozolotto (2010).

Uma medida de dispersão da variável ao redor de seu valor esperado em um determinado período de tempo pode ser denominada como volatilidade. Assim sendo, é de extrema importância a sua estimativa para diferentes períodos, sejam eles diários, semanais ou anuais. A volatilidade, por não poder ser observada, deve ser devidamente medida para que se possa tomar posições coerentes, de acordo com Silveira (2008).

A volatilidade pode ser definida como a variância condicional de uma observação, isto é variação de uma observação em dado instante de tempo, dependente das observações passadas. Uma característica importante da volatilidade é que ela não é diretamente observável. Entre os diversos modelos utilizados para estudar a

volatilidade de uma série de dados, os mais usuais são os modelos ARCH e GARCH. (ZOZOLOTTO 2010, p. 33).

Pode-se estimar a volatilidade a partir de resíduos de modelos ajustados, dentre eles a classe de modelos ARIMA, que modelam a dependência temporal presente na série e apuram os erros médios condicionais da equação estimada que são os insumos necessários aos cálculos da volatilidade, de acordo com Gaio et al. (2007).

Segundo Silva et al. (2005), e Lima et al. (2009), o modelo proposto por Engle (1982) pode ser descrito por meio dos erros de um modelo linear autorregressivo (AR):

$$Z_t = \underbrace{\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}}_{\text{autorregressivo (p)}} + \varepsilon_t, \quad (25)$$

O modelo ARCH (q), em que q denota a ordem do modelo, expressa a variância condicional do modelo (25) para a média condicional como uma função das inovações quadráticas passadas, em que $\varepsilon_t = N(0, \sigma_t^2)$, onde:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2, \quad (26)$$

e σ_t^2 é a variância condicional do conjunto de informações. Para Bueno (2008) as restrições são que $\omega > 0$ e $\alpha_i \geq 0$, para todo $i = 1, 2, \dots, q$ e $\sum_{i=1}^q \alpha_i < 1$, são necessárias para garantir a estacionaridade e a positividade da variância condicional.

De acordo com Morettin e Toloí (2004) e Oliveira et al. (2008), os modelos autorregressivos com heterocedasticidade condicional generalizado GARCH, propostos por Bollerslev (1986), são também muito utilizados para a modelagem da volatilidade de séries temporais, ou seja, eles são utilizados quando a volatilidade da série não é constante.

O modelo GARCH permite especificar uma expressão para a variância condicional e modelar movimentos persistentes na volatilidade de maneira parcimoniosa. Pode ser usado para descrever a volatilidade com menos parâmetros do que de um modelo ARCH apresentando as mesmas vantagens e desvantagens, segundo Morettin e Toloí (2004).

A generalização do modelo ARCH (q), proposta por Bollerslev (1986), tem por finalidade ampliar o conjunto de informação utilizado e obter uma formulação mais parcimoniosa. No modelo heterocedástico condicional autorregressivo GARCH (p,q), o

modelo para a variância condicional é formalizado de acordo com Silva et al. (2005), Oliveira et al. (2008), Oliveira e Monini (2009), Mól et al. (2014) e Bueno (2008), e é dado por:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2, \quad (27)$$

o modelo segue as seguintes restrições $\omega, \alpha_i > 0, \beta_i > 0$ e $\alpha_i + \beta_i < 1$.

Nas palavras de Bueno (2008, P. 240), “Diferente dos modelos ARMA, a FAC nos dá a ordem máxima autorregressiva do GARCH representada pelo termo $\hat{\varepsilon}_{t-j}^2$, e a FACP dá a ordem p das médias móveis do GARCH do termo σ_{t-j}^2 ”.

Silva et al. (2005) afirmam que a persistência da volatilidade da série é medida pela soma de α_i e β_i , sendo que quanto mais próxima de 1 for esta soma, maior é a persistência ou o tempo de efeito da volatilidade.

A seguir é apresentado o modelo de Alisamento Exponencial de Holt-Winters (AEHW), utilizado para ajuste e previsão neste estudo devido a características sazonais existentes na variável UR. Cabe ressaltar que existem outros modelos dentro da classe de alisamento exponencial, que não serão abordados neste trabalho. Dentre os modelos, podemos citar: Médias Móveis Simples (MMS), Alisamento Exponencial Simples (AES) e Alisamento Exponencial Biparamétrico de Holt (AEH)

2.2.5 Modelos de Alisamento Exponencial de Holt-Winters (AEHW)

Uma das grandes classes de modelos de previsão que estuda o padrão de qualquer ruído contido em séries de tempo e através dele prevê valores futuros é o de alisamento exponencial. A grande popularidade atribuída ao método é devida a sua simplicidade e eficiência, segundo Morettin e Toloí (1987).

Lúcio et al.(2010) defendem que o método de AEHW é um dos mais utilizados para a previsão de curto prazo, devido a sua simplicidade, baixo custo de operação, boa precisão e capacidade de ajustamento automático rápido a mudanças na série. Tal modelo considera na série até três coeficientes de alisamento: nível, tendência, sazonalidade e um elemento residual não previsível designado por erro aleatório.

Para Nascimento (2013), o método de AEHW é uma técnica determinística, que faz parte de um conjunto de técnicas de alisamentos exponenciais indicados para séries que apresentam tendências e/ou sazonalidade. O método distingue-se dos demais, pois seu objetivo não é ajustar uma reta aos dados e sim uma reta a cada instante de tempo.

O modelo (AEHW) pode ter duas variações de construção, o modelo multiplicativo e o modelo aditivo de acordo com o comportamento das componentes da série. Segundo Nascimento (2013), quando a amplitude da série em estudo varia de acordo com a sua evolução ou aumenta à medida que o nível da série aumenta, o modelo mais adequado é o multiplicativo. Nos casos em que a série apresenta comportamento homogêneo, o modelo aditivo apresenta melhores resultados.

Cada um dos procedimentos (aditivo ou multiplicativo) requer a determinação de três constantes de alisamento (A, C e D), associadas a cada uma das componentes para sazonalidade, nível e tendência.

Os valores das constantes (A, C e D) são obtidos de modo que se obtenha a mínima soma dos quadrados dos erros de ajustamento das constantes de suavização e uma das vantagens do método é a facilidade de manuseio.

De acordo com Veríssimo et al. (2012) e Morettin e Tolo (2004), o modelo aditivo caracteriza-se pelo padrão sazonal não se alterar a medida que o nível da série muda. A equação geral do modelo é dado por:

$$Z_t = \mu_t + T_t + F_t + \varepsilon_t, \quad (28)$$

para $t=1, \dots, N$ onde N é tamanho da série.

As três equações de suavização são apresentadas abaixo:

$$\hat{F}_t = D(Z_t - \bar{Z}_t) + (1-D)\hat{F}_{t-s} \quad 0 < D < 1; \quad (29)$$

$$\bar{Z}_t = A(Z_t - \hat{F}_{t-s}) + (1-A)(\bar{Z}_{t-1} + \hat{T}_{t-1}), \quad 0 < A < 1; \quad (30)$$

$$\hat{T}_t = C(\bar{Z}_t - \bar{Z}_{t-1}) + (1-C)\hat{T}_{t-1}, \quad 0 < C < 1, \quad (31)$$

onde A é a constante de suavização do nível, C é a constante de suavização da tendência e D é a constante da componente sazonal, \hat{T}_t é a componente da tendência, \hat{F}_t é a componente do sazonal e \bar{Z}_t é a componente de nível.

A equação de previsão(h) para o modelo aditivo é dada por:

$$\hat{Z}_t(h) = \hat{Z}_t + \hat{T}_t h + \hat{F}_{t+h-s} \quad (32)$$

com $h = 1, 2, \dots, s$.

O modelo multiplicativo se caracteriza por ter a sazonalidade da série afetada pela tendência sendo o resultado do produto das componentes individuais e é representado pela seguinte equação, segundo Veríssimo et al. (2012) e Morettin e Tolo (2004):

$$Z_t = \mu_t T_t + F_t + \varepsilon_t \quad (33)$$

para $t=1, \dots, N$ onde N é tamanho da série.

As três equações de suavização para nível tendência e sazonalidade são similares às anteriores, conforme se pode ver a seguir:

$$\hat{F}_t = D \left(\frac{Z_t}{\hat{Z}_t} \right) + (1-D) \hat{F}_{t-s}, \quad 0 < D < 1, t = s+1, \dots, N; \quad (34)$$

$$\bar{Z}_t = A \left(\frac{Z_t}{\hat{F}_{t-s}} \right) + (1-A) (\bar{Z}_{t-1} + \hat{T}_{t-1}), \quad 0 < A < 1, t = s+1, \dots, N; \quad (35)$$

$$\hat{T}_t = C(\bar{Z}_t - \bar{Z}_{t-1}) + (1-C) \hat{T}_{t-1}, \quad 0 < C < 1, t = s+1, \dots, N; \quad (36)$$

onde: A é a constante de suavização do nível, C é a constante de suavização da tendência, D é a constante de suavização da componente sazonal, \hat{T}_t é a componente da tendência, \hat{F}_t é a componente do sazonal e \bar{Z}_t é a componente de nível, s corresponde ao valor do intervalo sazonal e N o número de observações.

A equação de previsão do modelo multiplicativo é dada por:

$$\hat{Z}_t(h) = (\hat{Z}_t + \hat{T}_t h) \hat{F}_{t+h-s} \quad (37)$$

com $h = 1, 2, \dots, s$.

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

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

2.3 Critérios de seleção dos melhores modelos

Como um dos principais objetivos da análise de séries temporais é gerar previsões de valores futuros da série, é importante utilizar-se de alguns critérios de eficiência do modelo que considerem o grau de precisão de suas previsões futuras, segundo Souto et al. (2007).

Um bom modelo é o modelo que mais se aproxima dos dados reais e, para Sousa (2012), não existem modelos perfeitos, pois não há como identificar e controlar todas as variáveis envolvidas no fenômeno estudado, obtendo-se valores, aproximados para os resultados projetados pelo modelo ajustado.

Existem vários critérios disponíveis na literatura, sendo que alguns são apresentados a seguir.

2.3.1 Critérios de seleção dos Modelos de Box Jenkins

Os critérios a serem utilizados para verificar o ajuste do modelo autorregressivo integrado e de médias móveis são: AIC e BIC, relatados abaixo.

O critério de AIC (*Akaike Information Criteria*) proposto por Akaike (1974):

$$AIC = \ell n(\hat{\sigma}_e^2) + \frac{2(p+q)}{n} \quad (38)$$

e o critério BIC (*Bayesian Information Criterion*) desenvolvido por Akaike (1978):

$$BIC = \ell n(\hat{\sigma}_e^2) + \frac{(p+q)\ell n(n)}{n}, \quad (39)$$

onde $\hat{\sigma}_e^2$ é variância estimada dos erros; n é o tamanho da amostra e (p,q) é o número de parâmetros de cada componente AR e MA. Os critérios levam em conta a variância do erro, o tamanho da amostra n e os valores de (p,q) .

Nesse sentido, vários modelos concorrentes são ajustados e, a partir dos valores dos critérios citados, é possível escolher o modelo mais adequado para realizar previsões h passos à frente. Quanto menores forem estes valores, melhor é a adequação do modelo para realizar previsões.

Além disso, a condição de ruído branco dos resíduos é considerada, ou seja, faz-se necessário que os erros do modelo devem ter média zero e variância constante, além de serem descorrelacionados ao longo do tempo, indicando que o modelo está tão bem ajustado restando apenas à parte aleatória que não pode ser explicada pelo modelo.

2.3.2 Critérios de avaliação do melhor modelo Holt-Winters

Os critérios de avaliação da qualidade das previsões mais utilizados para os modelos de alisamento exponencial são o Erro Quadrático Médio (EQM) e *Sum of Square for Forecast Error* (SSE) e o MAD (*mean absolute deviation*), descritos na Tabela 1, de acordo com Tidre et al. (2013), Esquivel et al. (2012) e Barbosa e Chaves (2012).

Tabela 1 – Critérios de avaliação de previsão modelo Holt-Winters

Critério	Equação
Erro quadrático médio	$EQM = \frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n}$
Soma dos quadrados das diferenças	$SSE = \sum_{t=1}^n (Z_t - \hat{Z}_t)^2$
Média absoluta dos erros	$MAD = \frac{\sum_{t=1}^n Z_t - \hat{Z}_t }{n}$

onde: Z_t é o valor da série no instante t ;
 \hat{Z}_t é o valor previsto para o instante t ;
 n é o número período de tempos.

2.3.3 Critérios de comparação de modelos

Para comparação dos modelos, além dos critérios citados no item 2.3.2 será utilizado o Erro Absoluto Médio Percentual (MAPE).

De acordo com Feliciano (2009), o MAPE e MAD são as medidas de seleção mais utilizadas para a comparação de modelos. A diferença dos métodos encontra-se na origem dos dados: o MAPE não depende de escala dos dados, podendo ser utilizado para comparar modelos com diferentes conjuntos de dados, já o MAD é útil para comparar diferentes modelos aplicados ao mesmo banco de dados:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right|}{n} \cdot 100\% \quad (40)$$

onde: Z_t é o valor da série no instante t , \hat{Z}_t é o valor previsto para o instante t e n é o número de período de tempos.

2.4 Teste de Autocorrelação

O teste de autocorrelação é empregado para verificar a dependência ou independência dos dados da série temporal e consiste em analisar a relação entre variáveis defasadas e variáveis posteriores com base em diferentes intervalos de defasagem, evidenciando se os coeficientes são significativamente diferentes de zero, de acordo com Bruni (2004).

Para Leroy et al. (2006), a análise dos resíduos do modelo ajustado é de extrema importância, pois se os resíduos são autocorrelacionados, os coeficientes do modelo não explicam a dinâmica da série. Ainda, segundo os autores, o modelo estimado deve ter características de ruído branco com erros independentes e identicamente distribuídos.

2.4.1 Teste Ljung-Box

De acordo com Morettin e Tolo (2004), Bruni (2004), Souza e Camargo (1996) e Luna et al. (2006), as hipóteses de teste são:

H_0 : os resíduos são ruído branco;

H_1 : os resíduos não são ruído branco.

Se o modelo é adequado, os resíduos estimados deverão ser não-correlacionados. A autocorrelação estimada (41) e a estatística de teste Ljung-Box (42) são dadas respectivamente por:

$$\hat{r}_k = \frac{\sum_{t=k+1}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-k}}{\sum_{t=1}^n \hat{\varepsilon}_t^2} \quad (41)$$

Sendo, \hat{r}_k as autocorrelações calculadas e $\hat{\varepsilon}_t$ os resíduos estimados,

$$Q(k) = n(n+2) \sum_{j=1}^k \frac{\hat{r}_j^2}{(n-j)} \quad (42)$$

onde \hat{r}_j a j -ésima autocorrelação estimada, n é número de observações, k é o número de *lags* do teste. A estatística terá distribuição Qui-quadrado com $K - p - q$ graus de liberdade, em que p e q são os números de parâmetros ajustados do modelo, sendo que, em geral, as 15 primeiras autocorrelações são analisadas.

Rejeita-se a hipótese nula se $Q(\text{calculado}) > \chi_k^2$ (tabelado) com um nível de significância α .

2.4.2 Teste Box-Pirce

Segundo Bruni (2004) e Santos et al. (2012), as hipóteses de teste são as mesmas do teste Ljung e Box descritas no item 2.4.1.

A estatística de teste é dada por:

$$Q(k) = n \sum_{j=1}^k \hat{r}_j^2 \quad (43)$$

onde \hat{r}_j a j -ésima autocorrelação estimada, n é número de observações, k é o número de *lags* do teste.

Assim, quando $Q(\text{calculado}) > \chi_k^2$ (tabelado) para o nível de significância α rejeita-se a hipótese nula de que as autocorrelações são iguais à zero, ou seja, os resíduos não são considerados ruído branco.

3 METODOLOGIA

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

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

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

Para realização deste estudo, foram considerados os dados da série histórica correspondente à média semanal da umidade relativa do ar, compreendidos no período de 01 de outubro de 2001 a 22 de janeiro de 2014. Os dados correspondem a Estação Climatológica de Santa Maria - RS (OMM: 83936), os quais foram obtidos no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) mantido pelo Instituto Nacional de Meteorologia (INMET), totalizando 6657 observações coletados em três períodos diariamente (12:00h, 18:00h e 00:00h). Essas observações foram transformadas em médias diárias e posteriormente em médias semanais. As variáveis temperaturas máxima e mínima pertencem ao mesmo intervalo de tempo da série UR, e são as médias diárias que foram transformadas em médias semanais.

Para realizar uma comparação do modelo mais apropriado foram reservadas as 21 últimas médias semanais da série histórica em estudo.

Para análise dos dados foram consideradas as seguintes etapas:

- 1) Realização um levantamento de estudos referentes à umidade relativa do ar a fim de obter maior conhecimento sobre o assunto;
- 2) Execução de uma revisão bibliográfica sobre os modelos de séries temporais considerados;
- 3) Considerando que os dados em análise foram coletados, diariamente, às 00h, 12:00h e 18:00h, foi feita uma média diária e com a média diária uma média semanal de segunda-feira a domingo. Para os dados de temperaturas máxima e mínima diária também foram feitas médias semanais;

4) Como os dados foram coletados em forma de porcentagem, eles foram transformados para valores decimais;

$$Z_t = \frac{UR}{100} \quad (44)$$

- 5) Proceder uma análise descritiva dos dados;
- 6) Realizar uma análise gráfica da série original (verificar indícios de tendência e sazonalidade);
- 7) Através de testes estatísticos confirmar ou descartar a presença de tendência e sazonalidade;
- 8) Empregar transformações numéricas na série caso necessário, afins de tornar a série estacionária, para o modelo ARIMA e ARMAX;
- 9) Construir gráficos da função de autocorrelação (FAC) e autocorrelação parcial (FACP), para obter uma indicação de modelos a serem estimados;
- 10) Ajustar os modelos ARIMA, Holt-Winters e ARMAX;
- 11) Escolher os melhores modelos por meio dos critérios de seleção AIC e BIC, para os modelos Box-Jenkins;
- 12) Utilizar os critérios de seleção EQM, MAD e SSE para escolha do melhor modelo de Alisamento Exponencial de Holt-Winters;
- 13) Analisar a normalidade dos resíduos dos modelos através de testes estatísticos;
- 14) Verificar a condição de ruído branco (média zero, variância constante e erros descorrelacionados);
- 15) Ajustar modelos ARCH/GARCH aos resíduos ao quadrado dos modelos ARIMA e ARMAX, afins de identificar a volatilidade presente na série e a sua influência em cada modelo.
- 16) Realizar previsões h passos à frente com os modelos ARIMA, ARMAX e Holt-Winters;
- 17) Comparar o resultado dos ajustes e das previsões dos modelos ARIMA, ARMAX e Holt-Winters com os valores da série histórica reservados para esse fim;
- 18) Identificar o modelo que melhor se ajusta a série de dados.

Para realizar o ajuste dos modelos foram utilizados os softwares STATISTICA 9.1, Eviews e o R conforme “script” no apêndice.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Neste capítulo são apresentados os resultados dos testes estatísticos e dos modelos de séries temporais descritos no capítulo 2.

4.1 Características Estatísticas da Série

Para um melhor entendimento da variável UR, são apresentadas, na Tabela 2, algumas medidas descritivas, onde pode-se observar uma média elevada da UR, característica do clima local, com alta concentração de umidade no períodos de abril a agosto, considerado período de inverno e, as baixas concentrações, nos meses de dezembro e janeiro, período de verão. A UR manteve-se acima dos 50% em todos os períodos da série em estudo. A assimetria negativa indica que a curva possui uma cauda mais longa à esquerda. O valor do coeficiente de curtose demonstra uma distribuição platicúrtica, ou seja, os dados se concentram em maior número em torno da média que a distribuição normal.

Tabela 2 - Medidas descritivas da UR de Santa Maria – RS, 2001 a 2014

Medida Descritiva	Resultado
Média	0,76037
Mediana	0,76952
Desvio Padrão	0,07682
Coefficiente de variação	10,103%
Valor máximo	0,92476
Valor mínimo	0,53000
Curtose	-0,13351
Assimetria	-0,51288

Inicialmente, pode-se observar, na Figura 8, o comportamento da série original buscando identificar suas componentes, como tendência e/ou sazonalidade.

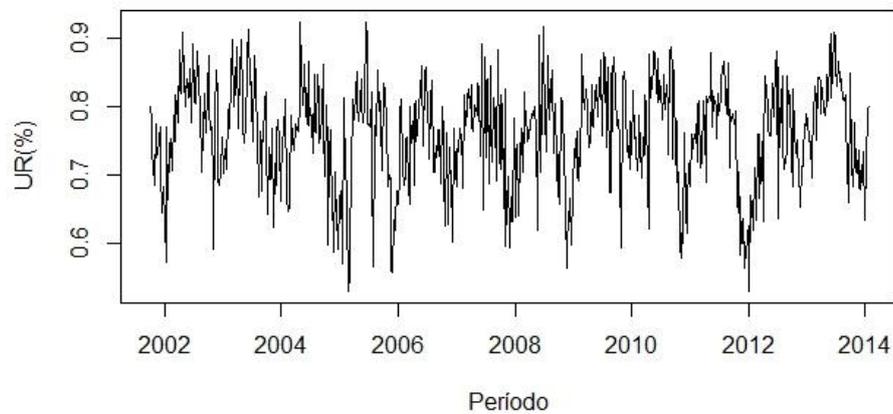


Figura 8 - Série Original da Umidade Relativa do Ar em Santa Maria – RS

Analisando a Figura 8, verifica-se que a série possui indícios de sazonalidade, não demonstrando a presença de tendência, o que indica não ser necessário aplicar diferenciações na série original; entretanto, para confirmar a análise gráfica foram aplicados testes estatísticos para verificar a condição de estacionariedade e sazonalidade.

A decomposição da série original também permite identificar componentes importantes da série e confirmar se há presença de sazonalidade e/ou tendência. Na Figura 9, pode-se observar a decomposição da série em estudo nas suas componentes ciclo, sazonalidade, tendência e variações aleatórias.

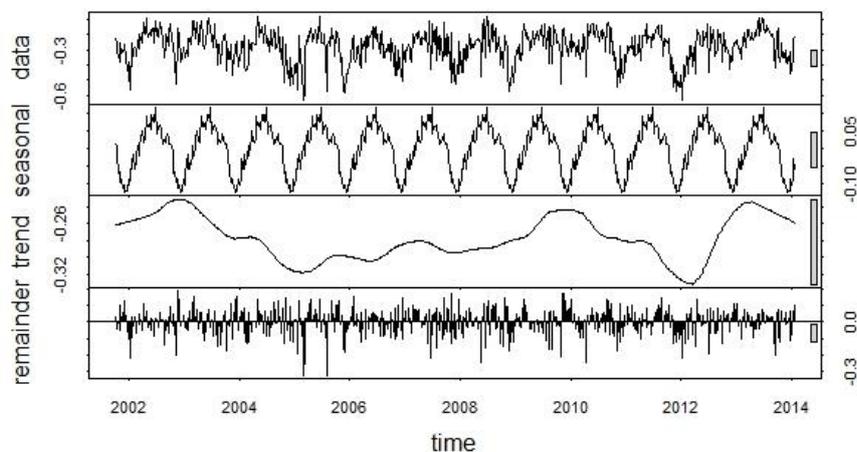


Figura 9 - Decomposição da série temporal em componentes de ciclo, sazonalidade, tendência e aleatoriedade

Observa-se, na Figura 9, que a série não possui tendência significativa, mas há de se considerar a presença de sazonalidade. A série demonstra um comportamento definido ao longo do tempo e, portanto, pode ser ajustada num modelo de série temporal.

Após a etapa inicial de análise descritiva dos dados foram realizados testes estatísticos para confirmar as hipóteses de estacionariedade e sazonalidade levantadas na análise gráfica.

De acordo com o teste Dickey-Fuller, descrito em (2.1.1), encontrou-se $\hat{\tau} = -5,2621$ e $\tau = -2,86$, para o nível de significância $\alpha = 5\%$, rejeitando-se a hipótese nula H_0 de que a série em estudo possui raiz unitária (não estacionária), aceitando a hipótese alternativa H_1 de estacionariedade dos dados.

Para o teste de sequências, tendo em vista n_1 e n_2 serem maior que 20 utilizou-se a aproximação para a normal $T_1 \sim N(\mu, \sigma^2)$, conforme descrito no item (2.2.2.1), em que $Z_{\text{cal.}} = 1,2522$, e $Z_{\text{tab.}} = 1,96$, ao nível de significância $\alpha = 5\%$.

De acordo com o teste, se $Z_{\text{cal.}} < Z_{\text{tab.}}$ aceita-se a hipótese nula H_0 de que não há indícios de tendências significativas na série em estudo, confirmando o teste Dickey-Fuller de estacionariedade dos dados.

Para avaliar a sazonalidade foi realizado o teste Kruskal-Wallis sendo rejeitada a hipótese nula H_0 (p-valor $< 0,001$) e aceita a hipótese alternativa H_1 de presença de efeito sazonal na série, ao nível de significância $\alpha = 5\%$.

Confirmando o resultado do teste Kruskal-Wallis, o teste de Friedman também rejeitou a hipótese nula H_0 (p-valor $< 0,001$), confirmando a presença de sazonalidade na série em estudo.

4.2 Modelagem ARIMA

Os gráficos das funções de autocorrelação (FAC) e de autocorrelação parcial (FACP), que estão expressos na Figura 10, apresentam as correlações seriais no domínio do tempo. Com base em suas frequências estimadas é possível verificar sazonalidades e ciclos na série.

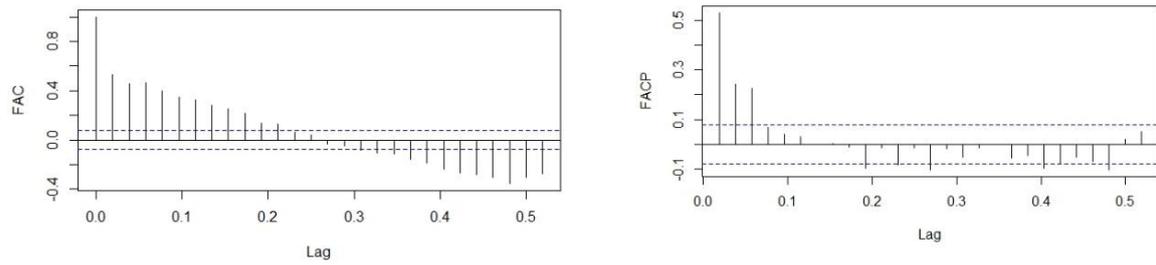


Figura 10 - Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP)

Ao se analisar os gráficos das FAC e FACP, percebe-se características de um modelo estacionário, autorregressivo de ordem 3 ou 4 e de médias móveis de ordem 1 ou 0. A FAC em nível permite identificar a presença de sazonalidade corroborando com os testes realizados de Friedman e Kruskal-Wallis, além do gráfico da decomposição (Figura 9), que indicam que um modelo do tipo SARMA deve ser considerado. Essa análise é sumária para dar início ao processo de modelagem, sendo que vários modelos de ordem diferentes vão ser considerados e testados.

Na Tabela 3, estão expostos alguns modelos concorrentes ajustados para a série UR, com os respectivos valores de AIC e BIC, os parâmetros do modelo, a média e a variância dos resíduos referentes a cada modelo significativo.

Tabela 3 - Modelos concorrentes SARMA e os respectivos critérios

SARMA (p,q)(P,Q)	Parâmetros	Critérios de seleção		Média/Variância dos resíduos
		AIC	BIC	
(3,0)(1,2) ₁₂	$\phi_1 = 0,3389$	-1681,52	-1646,08	$\mu \cong 0,0001$ $\sigma^2 = 0,0379$
	$\phi_2 = 0,1471$			
	$\phi_3 = 0,2312$			
	$\Phi_1 = 0,0315$			
	$\theta_1 = -0,0617$			
	$\theta_2 = -0,0524$			
	$c = 0,7619$			
(3,0)(1,1) ₁₂	$\phi_1 = 0,3477$	-1682,08	-1651,07	$\mu \cong 0,0001$ $\sigma^2 = 0,0037$
	$\phi_2 = 0,1462$			
	$\phi_3 = 0,2315$			
	$\Phi_1 = 0,3413$			
	$\theta_1 = -0,3841$			
	$c = 0,7619$			
(2,0)(1,1) ₁₂	$\phi_1 = 0,4027$	-1650,35	-1623,77	$\mu \cong 0,0001$ $\sigma^2 = 0,0041$
	$\phi_2 = 0,2418$			
	$\Phi_1 = 0,3464$			
	$\theta_1 = -0,3628$			
	$c = 0,7619$			

Considerando os três melhores modelos significativos ajustados, analisou-se a condição de ruído branco (média zero, variância constante, erros não correlacionados). Na análise dos resíduos dos modelos SARMA, observou-se que a média dos modelos pode ser considerada como zero conforme Tabela 3.

Os testes de autocorrelação dos resíduos Ljung-Box (p-valor = 0,6936) e Box-Pierce (p-valor = 0,6943), do melhor modelo SARMA(3,0)(1,1)₁₂ de acordo com os critérios de seleção AIC e BIC, indicam que os erros do modelo ajustado são descorrelacionados ao longo do tempo, aceitando a hipótese nula H_0 .

Os testes de normalidade dos resíduos Jarque-Bera (p-valor = 0,06005) e Shapiro-Wilk (p-valor = 0,07497) demonstram que os resíduos do modelo SARMA(3,0)(1,1)₁₂, seguem distribuição normal e concluem a última etapa da escolha do modelo.

Considerando a análise residual e os critérios AIC e BIC, o modelo SARMA(3,0)(1,1)₁₂, atendeu a todas as condições de ruído branco e normalidade dos resíduos sendo o escolhido para o ajuste do modelo e previsões.

Nessa etapa do trabalho, foram obtidas as previsões da UR para um horizonte de 21 passos à frente, ou seja, semanas que não foram consideradas no ajuste do modelo.

As previsões para o modelo ajustado $SARMA(3,0)(1,1)_{12}$ podem ser observadas na Tabela 4.

Tabela 4 - Valores previstos ($h=21$) segundo o modelo $SARMA(3,0)(1,1)_{12}$

Período	Valores previstos	Série real	Período	Valores previstos	Série real
621	0,79893	0,78524	632	0,76508	0,68048
622	0,79008	0,71381	633	0,76417	0,73571
623	0,78770	0,66000	634	0,76263	0,68000
624	0,78303	0,83191	635	0,76236	0,69762
625	0,78087	0,85048	636	0,76251	0,73381
626	0,77667	0,71857	637	0,76281	0,63524
627	0,77422	0,68381	638	0,76212	0,64381
628	0,77039	0,73381	639	0,76208	0,71572
629	0,76913	0,77762	640	0,76141	0,79904
630	0,76725	0,70571	641	0,76148	0,80142
631	0,76571	0,72238			

Na Figura 11 é demonstrada a série real, ajustada e os valores previstos para os limites de previsão com intervalo de confiança de 95%.

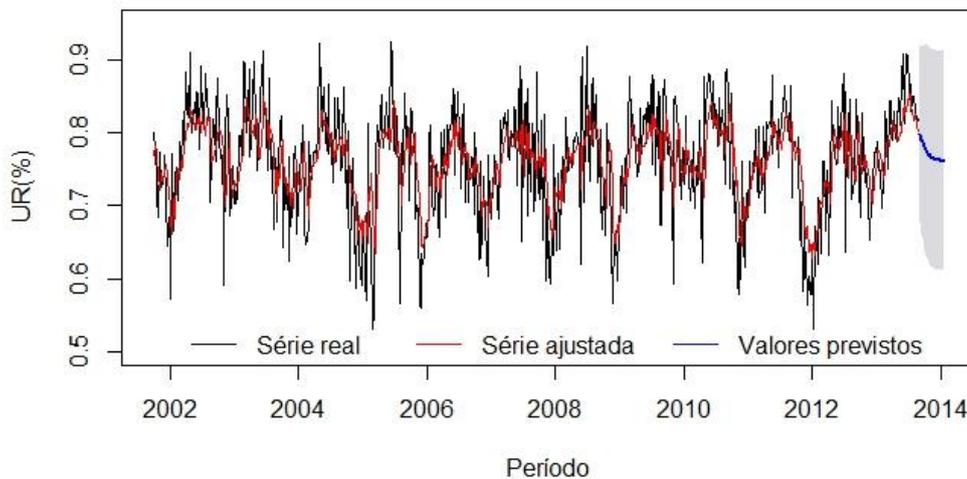


Figura 11 – Modelo $SARMA(3,0)(1,1)_{12}$ ajustado à série observada

4.2.1 Modelagem SARMA-ARCH/GARCH

Os testes Ljung-Box e Box-Pierce realizados nos resíduos do modelo SARMA(3,0)(1,1)₁₂, demonstram que os resíduos do modelo ajustado são ruído branco. Dessa forma, pode-se considerar que o modelo SARMA(3,0)(1,1)₁₂ é capaz de retirar a autocorrelação da série UR.

Já os mesmos testes Ljung-Box (p-valor < 0,0001) e Box-Pierce (p-valor < 0,0001), nos resíduos do modelo ao quadrado ε_t^2 , rejeitam a hipótese de ruído branco. Assim, há indícios de presença de volatilidade, sendo que modelos da classe ARCH ou GARCH podem ser ajustados aos resíduos ao quadrado (ε_t^2) do modelo SARMA(3,0)(1,1)₁₂, afim de captar a heterocedasticidade presente na série e verificar a sua influência nos valores futuros.

Os gráficos das funções de autocorrelação e autocorrelação parcial (Figura 12), corroboram com os testes estatísticos no indicativo de que os resíduos ao quadrado do modelo SARMA apresentam volatilidade.

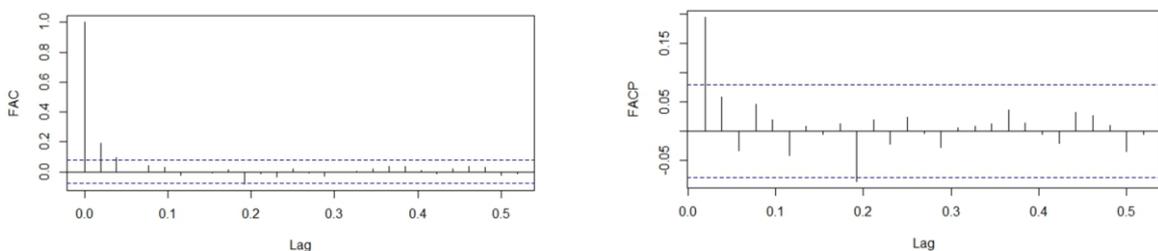


Figura 12 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) dos ε_t^2 do modelo SARMA(3,0)(1,1)₁₂

Para modelar a volatilidade do modelo SARMA utilizou-se os modelos ARCH/GARCH, conforme descrito no item 2.2.4.5 da revisão bibliográfica. Nos gráficos FAC e FACP (Figura 12), podem observar-se evidências de um ou dois parâmetros autorregressivo q (α_i) e de um ou nenhum parâmetro significativo de médias móveis p (β_j) do modelo ARCH ou GARCH.

Na Tabela 5, encontram-se os parâmetros do modelo ajustado aos resíduos ao quadrado do modelo SARMA(3,0)(1,1)₁₂, indicando um modelo ajustado ARCH(1).

Tabela 5 – Parâmetros do modelo ARCH ajustados aos ε_t^2 do modelo SARMA(3,0)(1,1)₁₂

ARCH(1)	Parâmetros	t-prob
ω	0,0005	$\cong 0,0001$
α_1	0,3952	$\cong 0,0001$

As restrições de $\omega, \alpha_i > 0$ e $\alpha_i < 1$, foram atendidas pelo modelo ajustado ARCH(1). Os testes de Ljung-Box (p-valor = 0,7625) e Box-Pierce(p-valor = 0,7630), aplicados aos resíduos do modelo ARCH(1), comprovam que o modelo atende aos pressupostos de ruído branco.

O parâmetro α_1 (Tabela 5) é igual a 0,3952, indicando que a volatilidade da UR não apresenta uma persistência alta, deste modo, a variabilidade retorna ao seu patamar normal num curto espaço de tempo.

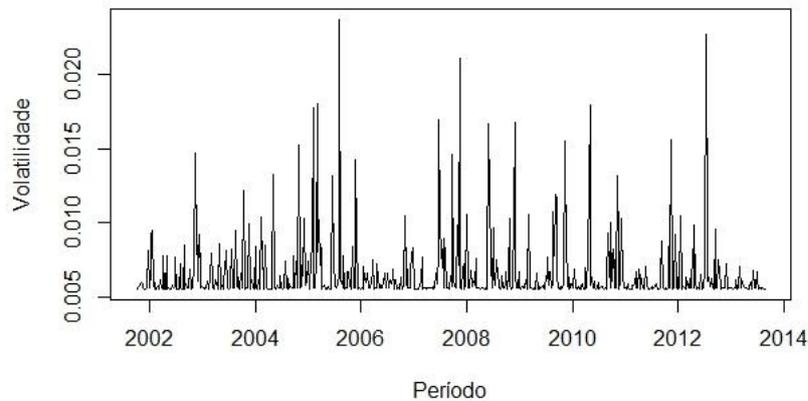


Figura 13 - Volatilidade Modelo SARMA-ARCH

As oscilações da UR (Figura 13), em torno da média condicional, podem estar sendo causadas em grande parte pela interferência de variáveis exógenas como a temperatura (mínimas e máximas) e precipitação. Observando esta característica, optou-se por ajustar um modelo ARMAX afim de verificar se a volatilidade da série pode ser melhor captada pelo modelo.

4.3 Ajuste do modelo ARMAX

Para o ajuste do modelo ARMAX e identificar a influência dessas variáveis na UR utilizaram-se as variáveis exógenas explicativas temperatura média (máxima e mínima) semanal.

Dentre os diversos modelos testados, na Tabela 6, estão apresentados os três modelos com melhor desempenho nos critérios de seleção AIC e BIC.

Tabela 6 - Modelos concorrentes ARMAX e os respectivos critérios

ARMAX (p,q,r[λ])	Parâmetros	Critérios de seleção		Média/Variância dos resíduos
		AIC	BIC	
(3,0,[1,1])	$\phi_1 = 0,2185$ $\phi_2 = 0,1648$ $\phi_3 = 0,2012$ $c = 0,93334$ T. max.= -0,008 T. min.= 0,0021	-1773,64	-1742,63	$\mu \cong 0,0001$ $\sigma^2 = 0,0032$
(2,0,[1,1])	$\phi_1 = 0,2611$ $\phi_2 = 0,2117$ $c = 0,9450$ T. max.= -0,0081 T. min.= 0,0016	-1750,72	-1724,14	$\mu \cong 0,0001$ $\sigma^2 = 0,0034$
(4,0,[1,1])	$\phi_1 = 0,2060$ $\phi_2 = 0,1556$ $\phi_3 = 0,1888$ $\phi_4 = 0,0595$ $c = 0,9316$ T. max.= -0,0079 T. min.= 0,0022	-1773,83	-1738,98	$\mu \cong 0,0001$ $\sigma^2 = 0,0033$

Considerando os três melhores modelos significativos ajustados, analisou-se a condição de ruído branco (média zero, variância constante, erros não correlacionados). Na análise dos resíduos do modelo ARMAX(3,0,[1,1]), observou-se que a média do modelo pode ser considerada como zero conforme Tabela 6.

Os testes de autocorrelação dos resíduos Ljung-Box (p-valor = 0,7762) e Box-Pirce (p-valor = 0,7732), do melhor modelo ARMAX de acordo com os critérios de seleção AIC e BIC, indicam que os erros do modelo ajustado não são correlacionados ao longo do tempo.

Os testes de normalidade dos resíduos Jarque-Bera (p-valor = 0,16005) e Shapiro-Wilk (p-valor = 0,1863) comprovam que os resíduos do modelo ARMAX(3,0,[1,1]), seguem distribuição normal e concluem a última etapa da escolha do modelo que melhor se ajusta à série de dados para realizar previsões.

Considerando a análise residual e os critérios AIC e BIC, o modelo ARMAX(3,0,[1,1]) atendeu a todas as condições de ruído branco e normalidade dos resíduos, sendo o escolhido para o ajuste do modelo e previsões.

Nessa etapa do trabalho, foram obtidas as previsões da UR para um horizonte de 21 passos à frente, ou seja, semanas que não foram consideradas no ajuste do modelo, conforme a metodologia proposta.

As previsões para o modelo ajustado ARMAX(3,0,[1,1]) podem ser observadas na Tabela 7.

Tabela 7 - Valores previstos (h=21) modelo ARMAX(3,0,[1,1])

Período	Valores previstos	Série real	Período	Valores previstos	Série real
621	0,76050	0,78524	632	0,74576	0,68048
622	0,70728	0,71381	633	0,72986	0,73571
623	0,81932	0,66000	634	0,73659	0,68000
624	0,81512	0,83191	635	0,73723	0,69762
625	0,78177	0,85048	636	0,71128	0,73381
626	0,75596	0,71857	637	0,70464	0,63524
627	0,73569	0,68381	638	0,73448	0,64381
628	0,74089	0,73381	639	0,71596	0,71572
629	0,75438	0,77762	640	0,74304	0,79904
630	0,74398	0,70571	641	0,68833	0,80142
631	0,74432	0,72238			

Na Figura 14 é demonstrada a série ajustada e os valores previstos para os limites de previsão com intervalo de confiança de 95%.

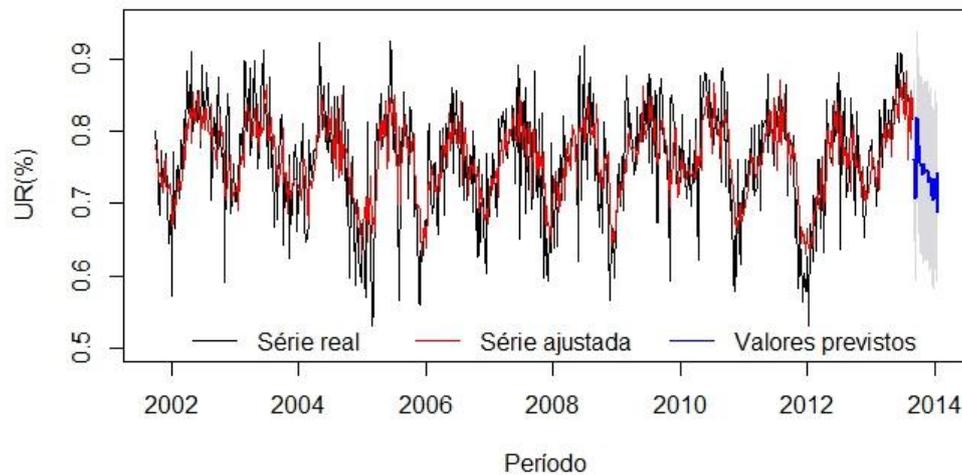


Figura 14 – Modelo ARMAX(3,0,[1,1]) ajustado à série observada

4.3.1 Modelagem ARMAX-ARCH/GARCH

Os resíduos do modelo ARMAX(3,0,[1,1]) ajustados na seção anterior apresentaram as propriedades de ruído branco de acordo com os testes Ljung-Box e Box-Pierce. Dessa forma, pode-se considerar que o modelo ARMAX(3,0,[1,1]) é capaz de retirar a autocorrelação da série UR.

Já os mesmos testes Ljung-Box (p-valor = 0,0029) e Box-Pierce (p-valor = 0,0030), nos resíduos ao quadrado ε_t^2 , rejeitam a hipótese de ruído branco, indicando a presença de volatilidade e que modelos da classe ARCH ou GARCH, podem ser ajustados aos resíduos ao quadrado (ε_t^2) do modelo ARMAX(3,0,[1,1]), afim de captar a heterocedasticidade presente na série e verificar a sua influência nos valores futuros.

Os gráficos das funções de autocorrelação e autocorrelação parcial (Figura 15) corroboram com os testes estatísticos no indicativo de que os resíduos ao quadrado do modelo ARMAX(3,0,[1,1]) apresentam uma pequena volatilidade nos *lags* iniciais.

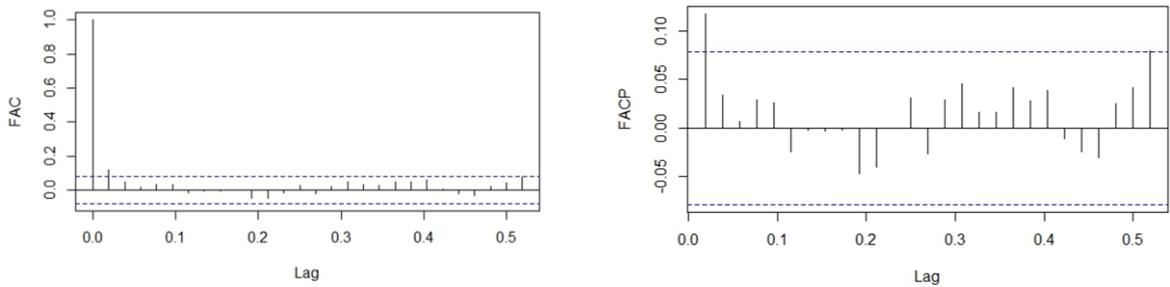


Figura 15 – Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) dos ε_t^2 do modelo ARMAX(3,0,[1,1])

Para modelar a volatilidade do modelo ARMAX(3,0,[1,1]) foi utilizado os modelos ARCH ou GARCH, conforme descrito no item 2.2.4.6 da revisão bibliográfica. Os gráficos de FAC e o FACP (Figura 15) demonstram evidências de um parâmetro significativo autorregressivo q (α_i) e de um ou nenhum parâmetro significativo de médias móveis p (β_i) do modelo ARCH ou GARCH.

Na Tabela 8, pode-se evidenciar o parâmetro do modelo significativo encontrado ARCH (q).

Tabela 8 – Parâmetros modelo ARCH ajustados aos ε_t^2 do modelo ARMAX(3,0,[1,1])

ARCH(1)	Parâmetros	t-prob
ω	0,00003	$\cong 0,0001$
α_1	0,2496	$\cong 0,0001$

As restrições de $\omega, \alpha_i > 0$ e $\alpha_i < 1$ foram atendidas pelo modelo ajustado ARCH(1). Os testes de Ljung-Box (p-valor = 0,9876) e Box-Pierce (p-valor = 0,9876), aplicados aos resíduos do modelo ARCH(1), demonstram que o modelo atende aos pressupostos de ruído branco, indicando que os resíduos são descorrelacionados ao longo do tempo.

O valor do parâmetro do modelo ARCH(1) é igual 0,2496, indicando que a volatilidade da UR não apresenta uma persistência alta, deste modo, a variabilidade retorna ao seu patamar normal num curto espaço de tempo.

A inclusão das variáveis explicativas temperaturas média (máxima e mínima) semanal diminuiu de forma significativa a volatilidade da série, tendo em vista que a soma dos

parâmetros do modelo ARMAX-ARCH ser, consideravelmente, menor que a soma dos parâmetros do modelo SARMA-ARCH.

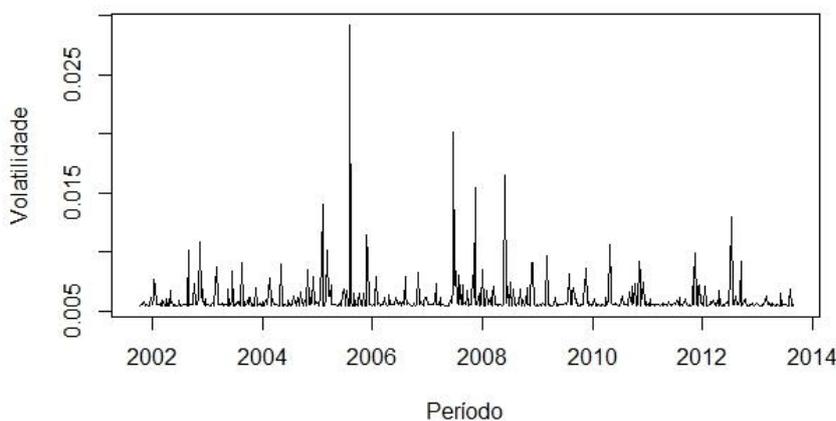


Figura 16 - Volatilidade modelo ARMAX-ARCH

As oscilações na volatilidade em torno da média condicional podem ser consideradas pequenas como se pode visualizar na Figura 16, sendo que, em sua grande maioria, não ultrapassam a casa de 0,015, ou seja, 1,5% já que a UR é coletada em porcentagem. Os picos de variabilidade nos anos de 2005, 2007 e 2008 podem ter sido causados, em grande parte, por intercalar semanas de baixa e alta precipitação, variável está não usada no modelo por apresentar, em alguns períodos, quantitativos de chuvas registradas iguais a zero milímetro.

4.4 Alisamento Exponencial de Holt-Winters (AEHW)

Dentre os modelos de alisamento exponencial o que melhor se ajusta a dados sazonais, característica presente na série, é o modelo AEHW. Seguindo as características da série, também foi utilizado esse modelo para ajuste da previsão e comparação com os modelos da classe ARIMA.

Foram ajustados dois modelos de (AEHW), o aditivo e multiplicativo e, posteriormente, foi feita a comparação utilizando os critérios de seleção conforme item (2.3.2).

No ajuste dos modelos, os valores das constantes de suavização que melhor se ajustaram ao modelo aditivo foram: $A=0,2493845$ (constante de suavização do nível); $C=0,0000$ (constante de suavização da tendência) e $D=0,08384394$ (constante de suavização da sazonalidade) e, para o multiplicativo, foi: $A=0,2377823$ (constante de suavização do nível); $C=0,0000$ (constante de suavização da tendência) e $D=0,08741191$ (constante de suavização da sazonalidade).

Os resultados das previsões do modelo aditivo e multiplicativo 21 passos à frente estão na Tabela 9 assim como os respectivos valores da série real correspondente a cada período.

Tabela 9 - Valores Previstos ($h=21$) modelos Holt-Winters

Período	Modelo Aditivo	Modelo Multiplicativo	Série real	Período	Modelo Aditivo	Modelo Multiplicativo	Série real
621	0,83424	0,83313	0,78524	632	0,69983	0,69412	0,68048
622	0,84389	0,84283	0,71381	633	0,73256	0,72658	0,73571
623	0,82210	0,82099	0,66000	634	0,69029	0,68281	0,68000
624	0,79992	0,79685	0,83191	635	0,70683	0,69929	0,69762
625	0,77901	0,77756	0,85048	636	0,71458	0,70699	0,73381
626	0,81989	0,81812	0,71857	637	0,75215	0,74679	0,63524
627	0,79545	0,79331	0,68381	638	0,74107	0,73489	0,64381
628	0,74209	0,73799	0,73381	639	0,74596	0,73864	0,71572
629	0,73724	0,73262	0,77762	640	0,76408	0,76114	0,79904
630	0,70989	0,70224	0,70571	641	0,75478	0,75015	0,80142
631	0,73283	0,72714	0,72238				

Utilizando os critérios de seleção EQM, MAD e SSE, o modelo multiplicativo ajustou-se de forma mais adequada à série histórica em relação ao modelo aditivo. Os resultados dos respectivos testes podem ser visualizados na Tabela 10.

Tabela 10 – Critérios de seleção modelo Holt-Winters

Modelo	EQM	MAD	SSE
Holt-Winters Aditivo	0,00499	0,05278	0,10468
Holt-Winters Mutiplicativo	0,00485	0,05149	0,10171

Na Figura 17, podem ser observados os valores reais e previstos, além do intervalo de previsão ($h=21$) do modelo Holt-Winters multiplicativo.

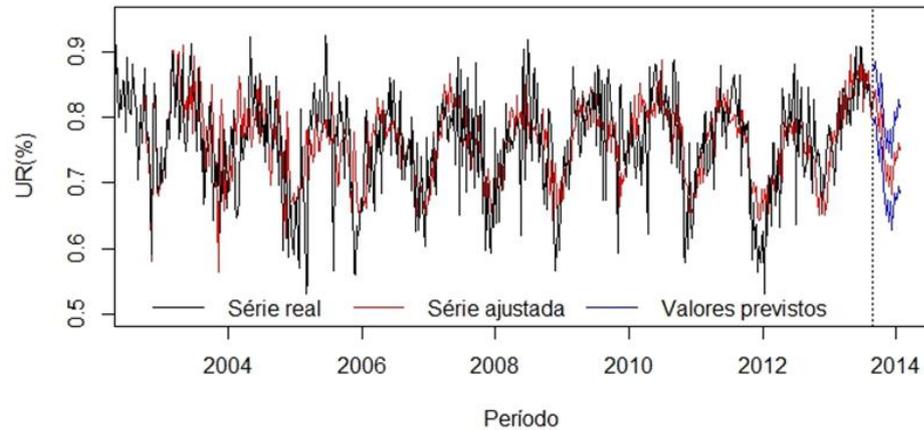


Figura 17 - Holt-Winters multiplicativo

4.5 Comparação dos modelos ajustados SARMA, Holt-Winters e ARMAX

Um dos objetivos de uma modelagem de séries temporais é fazer previsões de valores futuros. Para tanto, se faz necessário verificar a eficiência e o bom ajuste do modelo. Conforme proposto na metodologia, foram reservados as últimas vinte e uma observações da série original para verificar a qualidade do ajuste do modelo e comparar os modelos propostos dentro de cada classe considerada.

Os critérios a serem utilizados para comparação estão descritos na seção 2.3.2 e 2.3.3, da revisão bibliográfica. Na Tabela 11, estão expostos os resultados encontrados para os modelos que melhor se ajustaram à série de dados.

Tabela 11 - Comparação dos Modelos utilizando os critérios de seleção

Modelo	MAPE(%)	EQM	MAD	SSE
Holt-Winters multiplicativo	7,25413	0,00485	0,05149	0,10171
SARMA(3,0)(1,1) ₁₂	8,77223	0,00493	0,06159	0,10342
ARMAX(3,0,[1,1])	6,52960	0,00362	0,04643	0,07620

Considerando os resultados dos critérios propostos, o modelo $ARMAX(3,0,[1,1])$, apresentou melhor desempenho em todos os critérios utilizados em relação ao modelo $SARMA(3,0)(1,1)_{12}$ e o Holt-Winters multiplicativo, demonstrando que as previsões se aproximam de forma mais adequada à série real em estudo.

5 CONSIDERAÇÕES FINAIS

O objetivo deste trabalho não foi apenas analisar o desempenho dos modelos, mas demonstrar a importância da variável UR e suas principais implicações, bem como empregar os modelos propostos a variável coletada em porcentagem.

Ao final do presente estudo, observou-se que a série histórica de UR em Santa Maria - RS possui sazonalidade, com elevados valores de umidade no período de abril a agosto e, reduzidos valores, nos meses de dezembro e janeiro. Tais oscilações podem ocasionar sérios problemas de saúde, como os respiratórios, e representam um grande problema para a conservação de alimentos, sementes e o desenvolvimento das plantas. Enfim, isso interfere em dois dos principais setores da sociedade: a saúde e a agricultura.

As classes de modelos aqui utilizadas e comparadas para dados de uma variável climatológica demonstraram bom desempenho e ajuste. Verificou-se que os modelos podem ser empregados para taxas e proporções, desde que sejam seguidos todos os pressupostos exigidos pelos modelos. Destaca-se a ampla possibilidade de utilização destas (e de outras) técnicas adequadas de séries temporais nas mais diversas áreas em que se tem por objetivo descrever um processo temporal ou quando se deseja fazer previsões, podendo ser utilizadas como ferramenta de apoio nas tomadas de decisão.

Em relação à comparação do desempenho dos modelos, conforme os resultados obtidos, pode-se considerar que o modelo ARMAX com a inclusão das variáveis exógenas temperatura média (mínima e máxima) ajustou-se de forma adequada à série de dados e apresentou melhores resultados de previsão. O modelo Holt-Winters também se aproximou de forma adequada à série de dados estudada e devido a sua fácil manipulação deve ser levado em consideração. Não se descarta o modelo SARMA ou outros modelos estatísticos que possam produzir melhores resultados em outras séries de dados.

Verificou-se, por meio dos modelos SARMA-ARCH e ARMAX-ARCH, que, apesar da UR possuir uma variabilidade considerável, os modelos conseguiram captar de forma adequada as características da série, demonstrando que a volatilidade da série não possui grandes influências nas observações futuras.

Em estudos futuros, pretende-se verificar a relação entre os problemas de saúde associados a períodos de altas UR.

REFERÊNCIAS

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v.19, p.716-723, 1974.

AKAIKE, H. A Bayesian analysis of the minimum AIC procedure. **Annals of the Institute of Statistical Mathematics**, v.30, p.9-14, 1978.

ALMEIDA, E. S. **Previsão de carga a curto prazo: uma comparação de modelos**. 2008, 98f. Dissertação (Mestrado em Engenharia de Produção) Universidade Estadual do Norte Fluminense (UENF), Rio de Janeiro, 2008.

ALVES, L. R. A.; BACCHI, M. R. P. Oferta da exportação de açúcar no Brasil. **Revista de Economia e Sociologia Rural**, v.42, n.1, p. 09-33, 2004.

ANDRADE, N. S.; CARVALHO, P. S.; RUSSO, S. L.; Análise das variações de temperaturas na plataforma de Nossa Senhora da Glória via Box e Jenkins. **Revista GEINTEC**, v.1, p. 47-54, 2011.

ANDRADE, W. L. S. **Estimação de Modelos ARIMA/ARIMAX e Aplicação em Inferência de Propano**. 2009, 127f. Dissertação (Mestrado em Engenharia Elétrica e Computação), Universidade Federal do Rio Grande do Norte (UFRN), Natal 2009.

ANTONINI, J. C. A.; SILVA, E. M.; OLIVEIRA, L. F. C.; SANO, E. E. Modelo Matemático para a Temperatura média diária do ar do Estado de Goiás. **Pesquisa Agropecuária Brasileira**, Brasília, v.44, n.3, p.333-338, 2009.

ASSIS, E. S. Estudo integrado da ilha de calor em áreas urbanas e sua contribuição ao planejamento: O caso de Belo Horizonte, MG. **Fórum Patrimônio, Mudanças climáticas e o impacto das cidades**, v.4, n.1, 2011.

BACK, A. J. Aplicação de análise estatística para identificação de tendências climáticas. **Revista pesquisa Agropecuária Brasileira**, v. 36, n. 5, p. 717-726, 2001.

BARBOSA, C. M.; CHAVES, C. A. Um estudo sobre gerenciamento da demanda nos sistemas de planejamento e controle da energia de produção. **VIII Congresso Nacional de Excelência em Gestão**, de 08 a 09 de junho, São Paulo, 2012.

BARBIERO, C. C. M. **Séries Temporais: Um Estudo de previsão para a receita operacional da ECt – Empresa Brasileira de Correios e Telégrafos.** 2003, 108f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina (UFSC), Florianópolis, 2003.

BARBIERO, M. **Avaliação das percepções quanto ao ambiente térmico em indústrias metalúrgicas: Um estudo de caso.** 2004, 139f. Dissertação (Mestrado em Engenharia) - Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2004.

BARCELLOS, C.; MONTEIRO, A. M. V.; CORVALAN, C.; GURGEL, H. C.; CARVALHO, M. S.; ARTAXO, P.; HANCON, S.; RAGONI, V. Mudanças climáticas e ambientais e as doenças infecciosas: cenários e incertezas para o Brasil. **Epidemiologia e Serviços de Saúde** v.18, n.3, p.285-304, 2009.

BARDIN, L.; PEDRO JÚNIOR, M. J.; MORAES, J. F. L. Estimativa das temperaturas máximas e mínimas do ar para a região do Circuito das Frutas, SP. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, p.618-624, 2010.

BATISTA, A. L. F. **Modelos de séries temporais e redes neurais na previsão de vazão.** 2009, 79f. Dissertação de Mestrado (Mestrado em Engenharia de Sistemas) – Universidade Federal de Lavras (UFLA), Lavras, 2009.

BEZERRA, M. I. L.; SANTOS, J. S.; AGUIAR, A. P. Ilhas de Calor: Importância da Vegetação na Amenização Climática em João Pessoa/PB. **Revista Brasileira de Geografia Física** v.06, n.05, 1499-1516, 2013.

BISCARO, G. A. **Meteorologia Agrícola Básica**, 1º Edição, Editora União Ltda, - Cassilândia - Mato Grosso do Sul, p.1-83, 2007.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**, 3ed. Prentice Hall: New Jersey, 1994, 589 p.

BOX, G. P.; JENKINS, G. M.; REINSEL, G. **Time series analysis: forecasting and control**, 4th Edition. Hardcover, John Wiley & Sons, 2008.

BOX, G. P.; JENKINS, G. M. **Time series analysis, forecasting and control.** San Francisco: Holden-Day, 1976.

BRUNI, A. L. A eficiência informacional do mercado ADRS brasileiros: Uma análise com testes de autocorrelação, raiz unitária e cointegração. **Revista Gestão e Planejamento**, v.5 n.9, p. 53-65, 2004.

BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 2008, 299 p.

Bollerslev, T.; Generalized Autoregressive Conditional Heteroskedasticity. **Journal of Econometrics**, v.31, n.3, p.307-327, 1986.

CAMARGO, M. G.; FURLAN, M. M. D. P. Resposta fisiológica do corpo às temperaturas elevadas: exercício, extremos de temperatura. **Revista Saúde e Pesquisa**, v.4, n.2, p. 278-288, maio/ago. 2011.

CAMARGO, M. G. **Análise da percepção térmica dos carteiros do cdd-londrina em relação ao uniforme utilizado em ambiente quente**. 2007, 157f. Dissertação (Mestre em Desenho Industrial) - Universidade Estadual Paulista , Bauru, 2007.

CARGNELUTTI FILHO, A.; MALUF, J. R. T.; MATZENAUER, R. Coordenadas geográficas na estimativa das temperaturas máxima e média descendais do ar no Estado do Rio Grande do Sul. **Ciência Rural**, v.38, p.2448-2456, 2008.

CARTER, R.; CHEUVRON, S. M.; SAWKA M. N. Doenças provocadas pelo calor. **Sports Science Exchange**. Gatorade Sports Science Institute, v. 19, n.3, 2007. Disponível em: <http://www.gssi.com.br>. Acesso em 20/05/2014.

CAVALCANTI, E. P.; SILVA, V. P. R.; SOUSA, F. A. S. Programa computacional para a estimativa da temperatura do ar para a Região Nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.10, p.140-147, 2006.

CHECHI, L.; SANCHES, F. O. Análise de uma série temporal de precipitação para Erechim (RS) e um possível método de previsão climática. **Ambiência Guarapuava**, v.9, p. 43-45, 2013.

CONTI, J. B. Considerações Sobre as Mudanças Climáticas Globais. **Revista do Departamento de Geografia (USP)**, p. 82-88, 2005.

CONTI, J. B. A questão climática do nordeste brasileiro e os processos de desertificação. **Revista Brasileira de Climatologia**, v.1 n.1, p. 7-14, 2005.

DANFÁ, S. **Distribuição espacial da precipitação pluvial e sua erosividade para Guiné-Bissau**. 2009, 104f. Dissertação (Mestrado em Engenharia Agrícola) Universidade Federal de Lavras do Sul (UFLA), Lavras, 2009.

DELGADO, C. R.; SEDIYAMA G. C.; ANDRADE R. G.; MENEZES S. J. M. C. Modelos para prognósticos da umidade relativa do ar em escala horária no município de Muriaé, MG. **I Seminário de Recursos Hídricos da Bacia Hidrográfica do Paraíba do Sul: o Eucalipto e o Ciclo Hidrológico**, Taubaté, Brasil, 07-09 novembro 2007, IPABHi, p. 295-300, 2007.

DICKEY, D. A.; FULLER, W. A. Distribution of the estimators for autoregressive time series with a unit Root. **Journal of the American Statistical Association**, v.74, n.366, p. 427-431, 1979.

DICKEY, D. A.; FULLER, W. A. Likelihood ratio statistics for autoregressive time series with a unit root. **Econometrica**, v.49, n.4, p. 1057-1072, 1981.

DIEBOLD, F. The past, present, and future of macroeconomic forecasting. **J. Econ. Perspect.**, Nashville, v.12, p.175-192, 1998.

EMPRESA BRASILEIRA DE ESTUDOS AGROPECUÁRIOS (Embrapa), **Princípios da Secagem de Alimentos**, ISSN 1571-5111, p. 9-51, 2010.

Engle, R. F.; Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Revista Econometria**, v.50, n.4, p. 987-1007, 1982.

ESQUIVEL, R. M.; SENNA, V.; GOMES. G. S. S. Análise espectral singular: comparação de previsão em séries temporais. **Revista do Mestrado em Administração e Desenvolvimento Empresarial**, v.16, n.2, p. 87-101, 2012.

ESPINOSA, M. M.; PRADO, S. M.; GHELERRE, M. Uso de modelo SARIMA na previsão de focos de calor para os meses de junho a outubro no Estado do Mato Grosso. **Ciência em Natura**, v.32, n.2, p 7-21, 2010.

FELICIANO, R. A. **Uma proposta de gerenciamento integrado de demanda e distribuição, utilizando sistemas de apoio à decisão (SAD) com Bussiness Intelligence (BI)**. 2009, 179f. Dissertação (Mestrado em Engenharia) Politécnica Universidade de São Paulo, São Paulo, 2009.

FERREIRA, G. F.; ASSIS, E. S. Influência das cidades sobre os padrões locais de vento e analisada a partir de simulação dinâmica do clima. **Fórum Patrimônio; Ambiente, construção e patrimonial sustentável**, Belo Horizonte, v.4, n.1, 2010.

FIGUEREDO, C. J. **Previsão de Séries Temporais Utilizando a Metodologia Box & Jenkins e Redes Neurais para Inicialização de Planejamento e Controle de Produção**. 2008, 174f. Dissertação (Mestrado em Métodos Numéricos em Engenharia) Universidade Federal do Paraná (UFPR), Curitiba, 2008.

GAIO, L. E.; PESSANHA, G. R. G.; OLIVEIRA, D. R.; ÁZARA, L. N. Análise da volatilidade do índice Bovespa: Um estudo empírico utilizando modelos da Classe ARCH. **Revista Contemporânea de Economia e Gestão**, v.5, n.1, p.07-16, 2007.

GHINI, R.; HAMANDA, E.; BETTIOL, W. Impactos das mudanças climáticas sobre doenças de importantes culturas no Brasil. **Empresa Brasileira de Estudos Agropecuários (Embrapa Meio Ambiente)**, Jaguariúna, ISBN 978-85-85771-51-5, 2011, 356 p.

GHINI, R.; HAMADA, E.; PEDRO JÚNIOR, M. J.; MARENGO, J. A.; GONÇALVES, R.R.V. Risk analysis of climate change on coffee nematodes and leaf miner in Brazil. **Pesquisa. Agropecuária Brasileira**, v.43, n.2, p. 187-194, 2008.

GIL, A. C. **Como Elaborar Projetos de Pesquisa**, 4 ed, São Paulo: Atlas, p 41-56, 2002.

GIODA, A.; GIODA, F. R. A influência da qualidade do ar nas doenças respiratórias, **Revista Ambiente e Saúde**, v.7, n.1, p. 15-23, 2006.

GUYTON, A. C.; HALL, J. E. **Tratado de fisiologia médica**. 11. ed.. Rio de Janeiro, RJ: Guanabara Koogan, 2006.

INMET, 2014. Dados da rede **Instituto Nacional de Meteorologia**. Disponível em: <http://www.inmet.gov.br/>, acesso em 02/02/2014.

LEROY, F. L. D.; ALBUQUERQUE, A. P.; MOARES, M. Projeção de preços futuros de usinas: Uma abordagem econométrica. **Revista da Faculdade de Ciências Administrativas de Curvelo**, Encontro Norte-Nordeste de finanças, Recife, p. 34-60, 2006.

LIMA, F. G.; KIMURA, H.; NETO, A. A.; PERERA, L. C. J. Previsão de preços de commodities com modelo ARIMA-GARCH e redes neurais com ondoletas: velhas e novas tecnologias – novos resultados. **Revista de Administração**, v.2, n.2, p. 188-202, 2009.

LIZZI, E. A. S. **Predição do número de casos mensal dos casos de dengue por modelos de séries temporais**. 2012, 131f. Dissertação (Mestrado em Saúde na Comunidade) Universidade de São Paulo (USP), Ribeirão Preto, 2012.

LÚCIO, P. S.; SILVA, F. D. S.; FORTES, L. T. G.; SANTOS, L. A. R.; FERREIRA, D. B.; SALVADOR, M. A. S.; BALBINO, H. T.; SARMANHO, G. F.; SANTOS, L. S. F. C.; LUCAS, E. W. M.; BARBOSA, T. F.; DIAS, P. L.S. Um modelo estocástico combinado de previsão sazonal para a precipitação no Brasil. . **Revista Brasileira de Meteorologia**, v.25, n.1, p. 70-87, 2010.

MAGALHÃES, B. G.; ZANELLA M. E. Comportamento Climático da região Metropolitana de Fortaleza. **Revista Mercator**, v.10, p 129-145, 2011.

MAIA, A. L. S.; CRIBARI-NETO, F. Dinâmica inflacionária brasileira: resultados de auto regressão quantílica. **Revista Brasileira de Economia**, v.60, n.2, p. 153-165, 2006.

MARGARIDO, M. A; JUNIOR, H. M. Teste para mais de uma raiz unitária: uso do *software* SAS® na elaboração de uma rotina para o teste Dickeypantula. **Revista Pesquisa & Debate**, v.17, n.1, p. 149-170, 2006.

MARINS, J. C. B.; Mecanismos físicos de perda de calor e fatores associados relacionados ao exercício. **Revista Mineira de Educação Física**, v.6, n.2, p. 5-20, 1998.

MARTÍNEZ, R. O.; ZAMPROGNO, B. Comparação de algumas técnicas de previsão em análise de séries temporais. **Revista Colombiana de Estatística**, v.26, n.2, p. 129-157, 2003.

MEDEIROS, S. S.; CECÍLIO, R. A.; MELO JÚNIOR. J. C. F.; SILVA JÚNIOR. J. L. C. Estimativa e espacialização das temperaturas do ar mínimas, médias e máximas na região Nordeste o Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.9, p.247-255, 2005.

MINISTÉRIO DO MEIO AMBIENTE (MMA), **Ciclo Hidrológico**, Disponível em <http://www.mma.gov.br/agua/recursos-hidricos/aguas-subterraneas/ciclo-hidrologico>, acesso em 04/02/2014.

MINISTÉRIO DA SAÚDE. **Mudanças climáticas e ambientais e seus efeitos na saúde: Cenários de Incertezas para o Brasil**. Ministério da Saúde, Organização Pan-Americana de Saúde, Brasília 2008, 40p.

MÓL, A. L. R.; FELIPE, I, J, S.; JÚNIOR, F. M. G.; Volatilidade dos índices de ações Mid-Large e SMALL CAP: Uma investigação a partir dos modelos ARIMA-GARCH. **Revista Gestão, Finanças e Contabilidade**, v.4, n.1, p. 4-29, 2014.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Edgard Blucher LTDA, 2004, 535 p.

MORETTIN, P. A.; TOLOI, C. M. C. **Previsão de Séries Temporais**. 2º edição, São Paulo: Editora Atual Editora LTDA, 1987, 436p.

MORETTIN, P. A. **Econometria Financeira-Um curso em séries temporais financeiras**. Editora São Paulo: Edgard Blucher LTDA, 2008, 319 p.

MUCELIN, C. A.; BELLINI, M. Lixo e Impactos Ambientais Perspectivas no Ecossistema Urbano. **Sociedade & Natura**, v.20, n.1, p. 111-124, 2008.

NASCIMENTO, H. H. S. **Planejamento de mercado de energia elétrica no novo modelo do setor elétrico brasileiro pela aplicação de análise de componente principal como métodos de combinação de previsão**. 2013, 100f, Dissertação (Mestre em Engenharia Elétrica) Universidade Federal do Mato Grosso do Sul (UFMS), Campo Grande, 2013.

OLIVEIRA, A.G. **A questão do valor do clima: reflexões em torno de um valor conceitual para a precipitação pluviométrica na produção agrícola**. 2010. 150 f, Tese (Doutorado em Geografia), Universidade Federal de Uberlândia (UFU), Uberlândia, 2010.

OLIVEIRA, F. L. C.; MIRANDA, C.V.C.; FERREIRA, P.G.; CALILI, R.F.; SOUZA, R.C. Critérios de identificação da ordem do modelo autorregressivo periódico – PAR(P). **42º Simpósio Brasileiro de Pesquisa Operacional (XLII SBPO)**, Bento Gonçalves, 2010.

OLIVEIRA, M. A.; MONTINI, A. A.; BERGMANN, D. R. Previsão de retornos de ações dos setores financeiros, de alimentos, industrial e de serviço, por meio de RNA e Modelos ARIMA-GARCH. **Revista de Administração Mackenzie**, v.9, n.1, p. 130-156, 2008.

OLIVEIRA, M. A.; MONINI, A. A. Um estudo sobre o efeito da dimensão dos parâmetros de modelos arimagarch na predição de séries temporais por redes neurais feedforward. **IX Congresso de Redes Neurais/Inteligência Computacional**, Ouro Preto, 25 a 28 de outubro de 2009.

OZAKI, V. A.; ADAMI, A. C. O. Modelagem estatística dos prêmios do seguro rural. **Revista Política Agrícola**, v.21, n.1, p. 60-75, 2012.

PALMIERI, A. M. **Desenvolvimento de Sistemas automatizado de baixo custo para a coleta e armazenamento de dados das variáveis climáticas: aplicações no ambiente agrícola**. 2009, 101 f. Dissertação (Mestrado em Ciências) – Escola Superior de Agricultura, Universidade de São Paulo, São Paulo, 2009.

PEDROSO, T. R.; SOUZA, A. M.; JACOBI, L. F. Previsão e monitoramento do preço das ações do Bradesco, **XIII SIMPEP**, p 1-12, 2006.

PEREIRA, B. B. Séries Temporais Multivariadas. **In: 6º Simpósio Nacional de Probabilidade e Estatística**, Rio de Janeiro, 1984. Rio de Janeiro: Universidade Federal do Rio de Janeiro – UFRJ, 1984. p. 219, 1984.

PINTO, H. S.; ZULLO, Jr. J.; AVILA, A. M. H. Setembro 2008. **Umidade do ar: Saúde no Inverno**. Disponível em: <http://www.cpa.unicamp.br/artigos-especiais/umidade-do-ar-saude-no-inverno.html>, acesso em 02/02/2014.

REISEN, V. A.; MOLINARES, F. A. A.; TEIXEIRA, E. C. Modelagem de Séries Temporais Sazonais na Presença de Outliers Estudo de Caso da Vazão Máxima Mensal do Rio Jucu, ES, Brasil. **Revista Brasileira de Recursos Hídricos**, v.13, n.2, 2008.

RIBEIRO, C. V., GOLDSCHMIDT, R. R., CHOREN, R. **Método para previsão de séries temporais e suas tendências de desenvolvimento**. 2009, 26f. Monografia (Ciência da Computação) – Instituto Militar de Engenharia (IME), Rio de Janeiro, 2009.

ROCHA, J. V. C. **Modelagem de dados meteorológicos da cidade de Recife utilizando a metodologia de séries temporais**. 2011, 124f. Dissertação (Mestrado em desenvolvimento de Processos Ambientais) Universidade Católica de Pernambuco (UCP), Recife, 2011.

SANTOS, C. M.; FARIAS, T. A.; MOURA, F. R.; MATEUS, R. R. Mercado futuro do café: um estudo de caso. **Revista ReCont: Registro Contábil**, v.3, n.1, p.62-84, 2012.

SANTOS, A. V.; COSTA, J. H. F. **Análise de modelos de séries temporárias para a previsão mensal do ICMS do Estado do Maranhão**, Cadernos IMESC 6, p.5-10, 2008.

SANTOS, J. S.; SILVA, V. P. R.; ARAÚJO, L. E.; LIMA, E. R. V.; COSTA, A. D. L.; Análise das Condições do Conforto Térmico em Ambiente Urbano: Estudo de Caso em Campus Universitário. **Revista Brasileira de Geografia e Física**, v.02, p. 336-353, 2011.

SILVA, M. I. S.; GUIMARÃES, E. C.; TAVARES, M. Previsão da temperatura média mensal de Uberlândia, MG, com modelos de séries temporais. **Revista Brasileira de Engenharia agrícola e Ambiental**, v.12, p.480-485, 2008.

SILVA, K. O.; MORAES, S. O.; MIRANDA, J. H.; PALMIERI, A. M. Sistema Automatizado para Aquisição de Dados de Umidade Relativa do Ar, Engenharia. Agrícola. **Jaboticabal**, v.27, n.3, p.630-638, 2007.

SILVA, L. C. **Utilizando o ARMAX para estimar a influência do PIB, SELIC e Inflação no faturamento de empresas do setor siderúrgico com ações na bolsa**. Monografia 82f. Bacharelado (Administração), Universidade de Brasília (UNB), Brasília 2011.

SILVA, M. A. V. **Meteorologia e Climatologia**. INMET: Recife Março de 2006, 449 p. (versão digital 2) disponível em www.agritempo.gov.br. Acesso em 01/02/2014.

SILVA, P. M. **Integração de Técnicas Computacionais como Contribuição para o Mapeamento dos Índices de Sensibilidade Fluvial a Derrames de Óleo na Região de Coari (AM)**. 2012, 154 f. Tese (Doutorado em Engenharia Civil), Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, 2012.

SILVA, M. P.; ROSADO, P. L.; BRAGA, M. J.; CAMPOS, A. C. Oferta da exportação de carne de frango no Brasil, de 1992 a 2007. **Revista de Economia e Sociologia Rural**, v.49, n.1, p. 31-54, 2011.

SILVA, W. S.; SÁFADI, T.; JÚNIOR, L. G. C.; Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH: os casos do café e da soja. **Revista de Economia e Sociologia Rural**, v.43, n.1, p.119-134, 2005.

SILVEIRA, T. K. G. **Modelo de previsão da volatilidade estocástica**. 2008, 107f. Monografia (Bacharel em Engenharia de Produção) Universidade de São Paulo (USP), São Paulo, 2008.

SOEBIYANTO, R. P.; ADIMI, F.; KIANG, R. K. Modeling and predicting seasonal influenza transmission in warm regions using climatological parameters. **PLoS ONE**, v.5, p.1-10, 2010.

SOUSA, W. R. N. **Estimativa de tendência de séries temporais de imagens de sensoriamento remoto para evolução de processos de desertificação**. 2012, 85f. Dissertação (Mestrado em Ciência da Computação) Universidade do Estado do Rio Grande do Norte (UERN)/Universidade Federal do Semiárido (UFERSA), Mossoró, 2012.

SOUTO, E.; SILVA, C.; DOURADO, G.; GOMES, R.; SOUSA, T.; KELMER, J.; SADOK, D. Uma abordagem simples para a previsão do consumo de energia em redes de sensores sem

fo. **25º Simpósio Brasileiro de Redes de Computadores e Sistemas Sem Fio**, Belém do Pará, de 28 maio a 01 junho de 2007.

SOUZA, R. C.; CAMARGO, M. E. **Análise de Séries Temporais: Os Modelos ARIMA**, Ed. SEDIGRAF, 1996, 242p.

TIDRE, P. V.; BIASE, N. G.; SILVA, M. I. S. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil. **Revista Eletrônica Matemática e Estatística em Foco**, v.1, n.1, p. 57-63, 2013.

TUBILIS, A.; NASCIMENTO, F.L.J. **Meteorologia descritiva: fundamentos e aplicações brasileiras**, Botucatu, UNESP, Faculdade de Ciências Agrônomicas 1992, 375p.

VERÍSSIMO, A. J.; ALVES, C. C.; HENNING, E.; AMARAL, C. E.; CRUZ, A. C.; Métodos estatísticos de suavização exponencial Holt-Winters para a previsão da demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, v.8, n.4, p. 154-171, 2012.

ZOZOLOTTO, H. C. **Aplicação de modelos de volatilidade estocástica em dados de poluição do ar de duas grandes cidades: Cidade do México e São Paulo**. 2010, 106f. Dissertação (Mestrado em Saúde na Comunidade) Universidade de São Paulo (USP), Ribeirão Preto, 2010.

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 & Produção**, v.10, n.1, p.47-67, 2003.

WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. **Revista Produção**, v.16, n.3, p.493-509, 2006.

APÊNDICE

```
#####
### Dissertação de Mestrado
### Análise de Séries Temporais
### Acadêmico: Cleiton Tibulo
### Orientador(a): Prof Roselaine Ruviaro Zanini
### Variável: UR(%).
### Data: 2014
#####

library(forecast) # carrega pacote;
library(stats)# carrega pacote;
library(tseries)# carrega pacote;
library('fGarch')# carrega pacote;

### Entre com a série de interesse na forma de um vetor;
data<-read.table("UR.txt",h=T)# colocar o nome do arquivo entre aspas;
attach(data)
v # conferir vetor v;
V<-v/100 # para colocar no intervalo (0,1), as variáveis estão em %;
V # conferir vetor V, dados transformados.

### Estatística descritiva:
mean(V) # média;
median(V) # mediana;
moda(V) # moda;
var(V) # variância;
sd(V) # desvio-padrão;
range(V)# valor máximo e mínimo;
sd(V)/mean(V)*100 # coeficiente de variação em %;
kurtosis(V) # curtose;
skewness(V) # assimetria.
```

```
### Transformar o vetor em uma série temporal;
```

```
R<-ts(V,start=c(2001,40),frequency=52)
```

```
R # Conferir a série temporal.
```

```
### Gráfico da Série Original
```

```
plot(R)# gráfico a serie temporal;
```

```
plot(R, xlab="Período", ylab="UR(%))# nome dos eixos;
```

```
title("")# Título do gráficos ente " " .
```

```
### Teste de Estacionariedade
```

```
adf.test(R)# teste Dickey-Fuller;
```

```
kpss.test(R)# teste Kpss, verificar há estacionariedade.
```

```
### Gráficos da série
```

```
plot(diff(R,xlab="Período",ylab="Umidade relativa do ar(%)" ))# série diferenciada;
```

```
monthplot(R, xlab="Período", ylab="Umidade Relativa do Ar(%))# sazonalidade;
```

```
plot(decompose(R))# decomposição nas componentes de sazonalidade, tendência e aleatoriedade.
```

```
### Função de Auto Correlação e Auto Correlação parcial
```

```
acf(R, main="",ylab="FAC")# função de autocorrelação;
```

```
pacf(R, main="",ylab="FACP")# função de autocorrelação parcial;
```

```
acf(diff(R,1),main="Série Diferenciada (d=1)", ylab="FAC")# função de autocorrelação com d=1;
```

```
pacf(diff(R,1),main="Série Diferenciada (d=1)", ylab="FACP") # função de autocorrelação parcial com d=1.
```

```
### Holt-Winters aditivo
```

```
hwc<-HoltWinters(R, seasonal="additive")
```

```
summary(hwc)
```

```
plot(hwc,xlab="Período",ylab="UR(%)",main="", type="l", lty=15,col=10)# gráfico da série ajustada;
```

```
lines(R,col=1,type="l")# gráfico a série real;
```

```
title(" ")# Título do gráfico;
```

```

f<- cbind(hwc,hwr)# valores de alpha, beta e gama;
f # imprime os valores de alpha, beta e gama;
s<- predict(hwc,n.ahead=21, prediction.interval = T, level=0.95)# previsão h= 21 plot(hwc,s,
xlab="Período",ylab="UR(%)",main="")# gráfico a série ajustada e série real e as previsões;
summary(s)# imprime os sumário das previsões;
# previsões h passos a frente;
residuals (hwc)# resíduos do modelo aditivo;
fitted(hwc)# valores da série ajustada do modelo aditivo.

### Holt-Winters multiplicativo
hwcm<-HoltWinters(R,seasonal="multiplicative")
summary(hwcm)
plot(hwcm,xlab="Período",ylab="UR(%)",main="", type="l", lty=15,col=10)# plota a série
ajustada;
lines(R,col=3,type="l")# gráfico da série real;
title(" ")# Título do gráfico;
e<-cbind(hwcm) # valores de alpha, beta e gama;
e# imprime os valores de alpha, beta e gama;
p<- predict(hwcm,n.ahead=21, prediction.interval = 20, level=0.95)# previsão;
plot(hwcm,p, xlab="Período",ylab="UR(%)",main="") # plota a série ajustada e série real e as
previsões;
summary(p)# imprime os sumário das previsões;
p # previsões h passos a frente;
residuals (hwcm)# resíduos do modelo multiplicativo;
fitted(hwcm)# valores da série ajustada do modelo multiplicativo.

### Modelo SARIMA(p,d,q)(P,D,Q)
rm(sarima)# deleta memória salvos em sarima;
rm(resid1)# deleta memória resid1;
sarima<-Arima(R,order = c(p,d,q), seasonal = list(order = c(P,D,Q), period = 12))
summary(sarima) # verifica o modelo ajustado;
resid1<- resid(sarima)# resíduos do modelo;
tsdiag(sarima)# teste diagnóstico do modelo SARMA(p,d,q)(P,D,Q);
plot(resid1, xlab="Período", ylab="Resíduos") #plota o gráfico dos resíduos;

```

```

mean(resid1) # média dos resíduos;
var(resid1) # variância dos resíduos.

### Teste Jarque e Bera e Shapiro-Wilk, normalidade dos resíduos
jarque.bera.test(resid1) # teste (Jarque e Bera);
shapiro.test(resid1) # teste (Shapiro-Wilk);
hist(resid1,xlab="Resíduos",ylab="Frequência",main="") # histograma dos resíduos.

### Teste Ljung-Box, teste de ruído branco dos resíduos
Box.test(resid1,type="Ljung-Box")# teste de ruído branco;
Box.test(resid1,type="Box-Pierce")# teste de ruído branco.

### Função de Autocorrelação e Autocorrelação parcial dos resíduos
acf(resid1, main="", ylab="FAC") # fac resíduos;
pacf(resid1, main="", ylab="FACP") # facp resíduos.

### Modelo Ajustado
fit.sarima<-fitted.Arima(sarima) # valores ajustados;
plot(fit.sarima,xlab="Período",ylab="UR(%)",type="l",lty=15,col=10) # plota os valores
ajustados;
lines(R,col=1,type="l")
fit.sarima# imprime os valores ajustados.

### Previsão h passos a frente
pred.sarima<-forecast(sarima, h=21, level=c(95)) #previsão com 95% de confiança;
summary(pred.sarima) # sumário das previsões;
plot(pred.sarima,main="",xlab="Período",ylab="UR(%)",ylim=c(0.45,0.90)) # plota a serie
com as previsões e intervalo de previsão determinado em level=c(95);
lines(fit.sarima, col=10, lty=1, type="l")
legend( 2001,0.60,legend=c("Série real","Série ajustada","Valores previstos"),lty=c(1,1,1),
col=c(1,2,4), bty="n")# legenda.

### Modelo GARCH ajustado aos resíduos SARMA (p,d,q)(P,D,Q)
a<-(resid1)^2# eleva os resíduos do modelo SARMA ao quadrado;

```

```

a# resíduos ao quadrado;

# Testes de ruído branco dos resíduos ao quadrado
Box.test(a,type="Ljung-Box")# teste de ruído branco;
Box.test(a,type="Box-Pierce")# teste de ruído branco.

# Função de autocorrelação e autocorrelação dos resíduos ao quadrado
acf(a, main="", ylab="FAC") # ACF dos resíduos ao quadrado;
pacf(a, main="", ylab="FACP") # PACF dos resíduos ao quadrado.

# Ajuste do modelo GARCH
ajuste1 <- garch(a, order = c(0, 1))# modelo GARCH;
summary(ajuste1) # sumário do modelo ajustado;
ajuste1# parâmetros do modelo;
plot(ts(ajuste1$resid)) # plota os resíduos do modelo ajustado;
par(mfrow = c(2, 1))# plota os dois gráficos na mesma tela;
acf(ajuste1$resid, na.action = na.pass) # AFC dos resíduos do modelo ajustado;
pacf(ajuste1$resid, na.action = na.pass) # PAC dos resíduos do modelo ajustado;
srg <- ajuste1$fitted.values[,1]# modelo ajustado em um vetor
srg# imprime os valores do modelo ajustado;
plot(srg,xlab="Período",ylab="Volatilidade")# gráfico do modelo ajustado.
#Análise dos resíduos modelo GARCH
residgarch1<-(ajuste1$resid)#resíduos modelo GARCH;
residgarch1#imprime resíduos;
Box.test(residgarch1,type="Ljung-Box")# teste de ruído branco dos resíduos;
Box.test(residgarch1,type="Box-Pierce")# teste de ruído branco dos resíduos.

### Modelo SARMAX
# Entrar com os dados variáveis explicativas (exógenas);
data<-read.table("temperatura média máxima.txt",h=T)# série de dados explicativa;
attach(data)
t# temperatura média máxima;
data<-read.table("temperatura média mínima.txt",h=T)# série de dados explicativa;
attach(data)

```

```

f# temperatura mínima;
T<-ts(t,start=c(2001,40),frequency=52)# temperatura média máxima;
T# Imprime temperatura média máxima;
F<-ts(f,start=c(2001,40),frequency=52)# temperatura média mínima;
F# Imprime temperatura média mínima;
m<-matrix(T)# matrix de T;
m# Imprime matrix m;
n<-matrix(F)# matrix de F;
n# Imprime matrix n;
z<-cbind(m,n)# cria a matrix conjunta z;
z# Matrix da temperatura média (máxima e mínima).

### Modelagem SARMAX
k<-Arima(R, order=c(p,d,q), seasonal=list(order=c(P,D,Q), period=12),xreg=z)
summary(k) # verifica o modelo ajustado;
resid2<- resid(k)# resíduos do modelo;
resid2# imprime os resíduos;
plot(resid2, xlab="Período", ylab="Resíduos") #plota o gráfico dos resíduos;
mean(resid2) # média dos resíduos;
var(resid2) # variância dos resíduos.

### Teste Jarque e Bera e Shapiro-Wilk, normalidade dos resíduos
jarque.bera.test(resid2) # teste (Jarque e Bera) de normalidade dos resíduos;
shapiro.test(resid2) # teste (Shapiro-Wilk) de normalidade dos resíduos.

### Teste Ljung-Box, teste de ruído branco dos resíduos
Box.test(resid2,type="Ljung-Box")# teste de ruído branco;
Box.test(resid2,type="Box-Pierce")# teste de ruído branco.

### Histograma dos resíduos
hist(resid2,xlab="Resíduos",ylab="Frequência",main="") # Histograma dos resíduos.

### Função de Autocorrelação e Autocorrelação parcial dos resíduos.
acf(resid2, main="", ylab="FAC") # FAC dos resíduos;

```

```
pacf(resid2, main="", ylab="FACP") # FACP dos resíduos.
```

```
#### Modelo ajustado
```

```
fit1<-fitted.Arima(k) # valores ajustados dentro do intervalo observado;
```

```
plot(fit1,xlab="Período",ylab="UR(%)",type="l",lty=15,col=10,ylim=c(0.50,0.90)) # plota os valores ajustados dentro do intervalo observado;
```

```
lines(R,col=1,type="l")# linha da série real;
```

```
fit1# imprime os valores ajustados.
```

```
### Previsão h passos a frente
```

```
pred.sarimax<-forecast(k, h=21, xreg=w , level=c(95))# previsão com 95% de confiança;
```

```
pred.sarimax# valores previstos;
```

```
summary(pred.sarimax) # sumário das previsões
```

```
plot(pred.sarimax,main="",xlab="Período",ylab="UR(%)",ylim=c(0.45,0.90)) # plota a serie com as previsões e intervalo de previsão determinado em level=c(95);
```

```
lines(fit1, col=10, lty=1, type="l")# linha da série ajustada;
```

```
legend( 2001,0.60,legend=c("Série real","Série ajustada","Valores previstos"),lty=c(1,1,1), col=c(1,2,4), bty="n")# legenda.
```

```
### Modelo GARCH ajustado aos resíduos SARMAX
```

```
b<-(resid2)^2# eleva os resíduos do modelo SARMAX ao quadrado;
```

```
b# resíduos ao quadrado;
```

```
# Teste de ruído branco dos resíduos ao quadrado
```

```
Box.test(b,type="Ljung-Box")# teste de ruído branco;
```

```
Box.test(b,type="Box-Pierce")# teste de ruído branco;
```

```
# Função de autocorrelação e autocorelação parcial dos resíduos ao quadrado
```

```
acf(b, main="", ylab="FAC") # ACF dos resíduos ao quadrado;
```

```
pacf(b, main="", ylab="FACP") # PACF dos resíduos ao quadrado;
```

```
# Ajuste do modelo GARCH
```

```
ajuste2 <- garch(b, order = c(0, 1))# modelo GARCH;
```

```
summary(ajuste2) # sumário do modelo ajustado;
```

```
ajuste2# parâmetros do modelo;
plot(ts(ajuste2$resid)) # plota os resíduos do modelo ajustado;
par(mfrow = c(2, 1))# plota os dois gráficos na mesma tela;
acf(ajuste2$resid, na.action = na.pass) # AFC dos resíduos do modelo ajustado;
pacf(ajuste2$resid, na.action = na.pass) # PAC dos resíduos do modelo ajustado;
sg <- ajuste2$fitted.values[,1]# modelo ajustado em um vetor
sg# imprime os valores do modelo ajustado;
plot(srg,xlab="Período",ylab="Volatilidade")# gráfico do modelo ajustado.
# Análise dos resíduos modelo GARCH
residgarch2<-(ajuste2$resid)#resíduos modelo GARCH;
residgarch2#imprime resíduos;
Box.test(residgarch2,type="Ljung-Box")# teste de ruído branco dos resíduos;
Box.test(residgarch2,type="Box-Pierce")# teste de ruído branco dos resíduos.
```