

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM COMPUTACIONAL

**ESTUDO COMPARATIVO ENTRE OS MODELOS ARIMA E
GARMA: UMA APLICAÇÃO A SÉRIE TEMPORAL DE
ÓBITOS POR NEOPLASIAS MALIGNAS DE PELE**

por

Vinícius Pinheiro Nunes

Dissertação para obtenção do Título de
Mestre em Modelagem Computacional

Rio Grande, Fevereiro, 2018

Vinícius Pinheiro Nunes

”Estudo comparativo entre modelos os ARIMA e GARMA: uma aplicação a série temporal de óbitos por neoplasias malignas de pele”

Dissertação apresentada ao Programa de Pós Graduação em Modelagem Computacional da Universidade Federal do Rio Grande - FURG, como requisito parcial para obtenção do Grau de Mestre. Área concentração: Modelagem Computacional.

Aprovada em

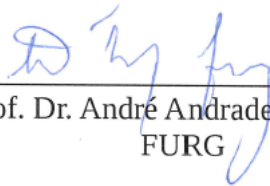
BANCA EXAMINADORA



Prof^a. Dr^a. Viviane Leite Dias de Mattos
Orientadora - FURG



Prof^a. Dr^a. Cátia Maria dos Santos Machado
Coorientadora - FURG



Prof. Dr. André Andrade Longaray
FURG



Prof^a. Dr^a. Andrea Cristina Konrath
UFSC

Rio Grande- RS

2018

Dedico este trabalho a minha mãe Ana Circe Pinheiro Nunes e as minhas amigas Ana Paula Fiuza, Gyanna Marramon de Brum e Ingrid Hardok Fuchs.

AGRADECIMENTOS

À minha mãe Ana Circe Pinheiro Nunes por todo amor, carinho e paciência durante todo este período.

À minha orientadora Viviane Leite Dias de Mattos pelos conhecimentos passados durante o mestrado, por estar sempre disponível para tirar minhas dúvidas, e pela amizade construída ao longo dessa jornada.

À minha coorientadora Catia Maria dos Santos Machado pelos conhecimentos passados durante o mestrado, pelas contribuições nesta dissertação e pela amizade construída ao longo deste período.

Às minhas amigas Gyanna Marramon de Brum, Ana Paula Fiuza, Karolyne Nish e Ingrid Hardok Fuchs pela paciência durante este período.

Aos membros da banca Andrea Cristina Konrath e André Andrade Longaray por terem aceitado o convite e pelas importantes considerações realizadas.

À Universidade Federal do Rio Grande (FURG) e ao programa de pós-graduação em Modelagem Computacional (PPGMC) pela oportunidade de realizar esta pesquisa.

E à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de Mestrado - demanda social.

Enfim, a todos aqueles que, de certa forma, possam ter contribuído e não foram mencionados nesses agradecimentos.

RESUMO

Este estudo tem como objetivo realizar a modelagem da série de óbitos por neoplasias malignas de pele, ocorridos na Região Sul do Brasil, entre 1996 e 2014, agregados em períodos trimestrais e mensais, utilizando os modelos ARIMA e GARMA, a fim de compará-los para identificar qual apresenta melhor ajuste aos dados e previsões mais próximas da realidade. A coleta dos dados foi realizada no site do Departamento de Informática do Sistema Único de Saúde. Foi realizada a análise gráfica das séries trimestral e mensal a fim de identificar possíveis presenças de tendência e sazonalidade. Foi avaliada a estacionariedade pelos testes ADF e KPSS, e sucessivas diferenças quando não obtida essa característica. Na sequência, foi analisado o correlograma a fim de identificar possíveis modelos ARIMA candidatos. Após a identificação desses modelos, foram utilizados os critérios de informação de Akaike, Akaike corrigido e Bayesiano para definir o modelo de melhor ajuste e mais parcimonioso. Na sequência, foi realizada a análise de diagnóstico dos resíduos do modelo escolhido utilizando o teste Q' de Ljung-Box e teste de normalidade de Jarque-Bera. Após todos pressupostos atendidos, foram obtidas as previsões para o modelo e avaliada a qualidade das previsões pelo erro percentual médio absoluto, erro percentual médio, raiz do erro quadrático médio e U de Theil. A modelagem da série utilizando os modelos GARMA-Poisson e GARMA- Binomial Negativa (BN) foi análoga à modelagem dos modelos ARIMA. Os resultados obtidos evidenciaram a presença de tendência crescente, ausência de sazonalidade e comportamento não estacionário para as séries trimestral e mensal. O modelo ARIMA com melhor ajuste, previsões e mais parcimonioso para a série trimestral foi o ARIMA (4,1,0) com constante e para a série mensal foi o modelo ARIMA (0,1,1). Quanto aos modelos GARMA, para a série trimestral, os melhores foram os modelos GARMA-Poisson (2,0) e GARMA-BN (2,0), enquanto para a série mensal, os modelos GARMA-Poisson (4,0) e GARMA-BN (4,0). Tanto os modelos ARIMA, quanto os GARMA, se mostraram mais adequados para estimar e prever a série em períodos trimestrais, quando comparado aos mensais. No que se refere a comparação entre as duas classes de modelos, o GARMA-Poisson e o GARMA-BN apresentaram resultados bastante superiores aos obtidos pelo ARIMA para ambas as periodicidades.

Palavras-chaves: Modelo ARIMA. Modelo GARMA-Poisson. Modelo GARMA-Binomial Negativa. Neoplasias malignas de pele. Ajustes e previsões.

ABSTRACT

This study aims to model the series of deaths from malignant skin neoplasms occurring in the Southern Region of Brazil, between 1996 and 2014, aggregated in quarterly and monthly periods, using the ARIMA and GARMA models, in order to compare them to identify the one that best fits the data and forecasts that are closer to reality. The data collection was carried out on the website of the Department of Informatics of the Unified Health System. A graphic analysis of the quarterly and monthly series was carried out in order to identify possible presence of trends and seasonality. The stationarity was evaluated by the ADF and KPSS tests, and successive differences when this characteristic was not obtained. The correlogram was then analyzed to identify possible candidate ARIMA models. After the identification of these models, the Akaike, Akaike corrected and Bayesian information criteria were used to define the best and most parsimonious model. Subsequently, the diagnostic analysis of the residues of the chosen model was performed using the Ljung-Box Q' test and Jarque-Bera normality test. After all assumptions were met, the predictions were obtained for the model and the quality of the predictions were evaluated by the absolute mean percentage error, mean percentage error, root mean square error and U of Theil. The modeling of the series using the GARMA-Poisson and GARMA-Binomial Negative (BN) models was analogous to the modeling of ARIMA models. The results obtained evidenced the presence of a growing trend, absence of seasonality and non-stationary behavior for the quarterly and monthly series. The ARIMA model with better fit, predictions and more parsimonious for the quarterly series was the ARIMA (4,1,0) with constant and for the monthly series was the model ARIMA (0,1,1). The GARMA-Poisson (2.0) and GARMA-BN (2.0) models were the best for the quarterly series, while GARMA-Poisson (4.0) and GARMA-BN (4.0). Both ARIMA and GARMA models were more adequate to estimate and predict the series in quarterly periods when compared to the monthly ones. Regarding the comparison between the two classes of models, GARMA-Poisson and GARMA-BN presented results much higher than those obtained by ARIMA for both periodicities.

Keywords: ARIMA model. Negative Binomial GARMA model, Poisson GARMA model. Malignant skin neoplasms. Adjustments and forecasts.

ÍNDICE

1	INTRODUÇÃO	16
1.1	Problema de pesquisa	17
1.2	Justificativa	18
1.3	Hipóteses	18
1.4	Objetivos	19
1.4.1	Objetivo Geral	19
1.4.2	Objetivos Específicos	19
1.5	Estrutura do Trabalho	19
2	Séries Temporais	20
2.1	Componentes não observáveis de uma série temporal	20
2.2	Processos estocásticos	21
2.2.1	Estacionariedade	21
2.2.2	Ergodicidade	22
2.3	Ruído Branco	22
3	MODELOS LINEARES PARA SÉRIES TEMPORAIS ESTACIONÁRIAS	23
3.1	Modelos Autorregressivos	23
3.2	Modelos de Médias Móveis	24
3.3	Modelos Autorregressivos de Médias Móveis	24
3.4	Estacionariedade	25
3.5	Invertibilidade	26
3.6	Função de Autocorrelação e Função de Autocorrelação Parcial	26
4	MODELOS LINEARES PARA SÉRIES TEMPORAIS NÃO ESTACIONÁRIAS	28
4.1	Metodologia de Box-Jenkins	28
4.2	Identificação de modelos ARIMA	29
4.2.1	Determinação da ordem d do modelo ARIMA	30
4.2.2	Determinação da ordem p e q do modelo ARIMA	30
4.3	Estimação de modelos ARIMA	31
4.3.1	Critérios de seleção de modelos	32
4.4	Análise de Diagnóstico	33
4.5	Previsões	34
4.5.1	Medidas de precisão ou acurácia	34
5	Modelos GARMA	36
5.1	Modelo Geral	36
5.2	Modelo GARMA-Poisson	37
5.3	Modelo GARMA-Binomial Negativa	38
6	Metodologia	39
6.1	Tipo de estudo	39
6.2	Descrição do espaço geográfico analisado	39

6.3	Descrição da variável analisada	39
6.4	Descrição do período analisado	40
6.5	Fonte das informações	40
6.6	Procedimentos metodológicos	41
7	RESULTADOS	43
7.1	Apresentação e análise descritiva das séries temporais	43
7.2	Análise da estacionariedade das séries temporais	44
7.3	Identificação e estimação de modelos ARIMA	48
7.4	Análise de diagnóstico dos resíduos dos modelos ARIMA	52
7.5	Qualidade dos ajustes e das previsões obtidas pelos modelos ARIMA	56
7.6	Identificação e estimação de modelos GARMA	59
7.7	Análise de diagnóstico dos resíduos dos modelos GARMA	62
7.8	Qualidade dos ajustes e previsões obtidas pelos modelos GARMA	66
7.9	Comparação dos resultados obtidos pelos modelos ARIMA e GARMA	70
8	Considerações Finais	72
9	REFERÊNCIAS	74

LISTA DE FIGURAS

Figura 4.1: Ciclo iterativo da metodologia de Box-Jenkins	29
Figura 7.1: Série temporal trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	43
Figura 7.2: Série temporal mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	44
Figura 7.3: Função de autocorrelação (FAC) da série temporal trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	45
Figura 7.4: Função de autocorrelação (FAC) da série temporal mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	45
Figura 7.5: Série temporal trimestral em primeira diferença dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014 . . .	46
Figura 7.6: Série temporal mensal em primeira diferença dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014. . . .	47
Figura 7.7: Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) da série trimestral em primeira diferença dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014. . . .	48
Figura 7.8: Função de autocorrelação (FAC) e Função de autocorrelação parcial (FACP) da Série temporal mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	49
Figura 7.9: Resíduos do modelo ARIMA(4,1,0) com constante da Série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	53
Figura 7.10: Resíduos do modelo ARIMA(0,1,1) da Série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	53
Figura 7.11: Função de autocorrelação(FAC) e função de autocorrelação parcial(FACP) dos resíduos do modelo ARIMA(4,1,0) com constante da Série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	54
Figura 7.12: Função de autocorrelação(FAC) e função de autocorrelação parcial(FACP) resíduos do modelo ARIMA(0,1,1) da Série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	54

Figura 7.13:Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo ARIMA(4,1,0) com constante da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	55
Figura 7.14:Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo ARIMA(0,1,1) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	55
Figura 7.15:Gráfico do ajuste do modelo ARIMA(4,1,0) com constante e dos valores reais da série trimestral e óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.	56
Figura 7.16:Gráfico do ajuste do modelo ARIMA(0,1,1) e dos valores reais da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.	57
Figura 7.17:Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Poisson (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	62
Figura 7.18:Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Poisson (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	62
Figura 7.19:Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Binomial Negativa (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	63
Figura 7.20:Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Binomial Negativa (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	63
Figura 7.21:Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Poisson(4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	64
Figura 7.22:Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Poisson (4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	64
Figura 7.23:Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Binomial Negativa(4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	65

Figura 7.24:Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Binomial Negativa (4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.	65
Figura 7.25:Gráfico do ajuste do modelo GARMA-Poisson (2,0) e dos valores reais da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.	66
Figura 7.26:Gráfico do ajuste do modelo GARMA-BN (2,0) e dos valores reais da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.	67
Figura 7.27:Gráfico do ajuste do modelo GARMA-Poisson (4,0) e dos valores reais da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.	67
Figura 7.28:Gráfico do ajuste do modelo GARMA-BN (4,0) e dos valores reais da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.	68

LISTA DE TABELAS

Tabela 6.1: Codificação definida para as neoplasias malignas de pele.	40
Tabela 7.1: Critérios de informação dos modelos estimados para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	49
Tabela 7.2: Modelos estimados com bons ajustes para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014. . .	50
Tabela 7.3: Critérios de informação dos modelos estimados para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	51
Tabela 7.4: Modelos estimados com bons ajustes para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014. . .	52
Tabela 7.5: Previsões para os trimestres de 2015 obtidas a partir do modelo ARIMA(4,1,0) com contante estimado para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	58
Tabela 7.6: Previsões para os seis meses de 2015 obtidas a partir do modelo ARIMA(0,1,1) estimado para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	58
Tabela 7.7: Modelo GARMA-Poisson estimado com bom ajuste para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014	59
Tabela 7.8: Modelos GARMA-Binomial Negativa (BN) estimados com bons ajustes para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	60
Tabela 7.9: Modelos GARMA-Poisson estimados com bons ajustes para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014	60
Tabela 7.10 Modelos GARMA-Binomial Negativa (BN) estimados com bons ajustes para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	61
Tabela 7.11 Previsões para os trimestres de 2015 obtidas a partir do modelo GARMA- Poisson (2,0) estimado para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	69
Tabela 7.12 Previsões para os trimestres de 2015 obtidas a partir do modelo GARMA- BN (2,0) estimado para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	69
Tabela 7.13 Previsões para os seis meses de 2015 obtidas a partir do modelo GARMA- Poisson (4,0) estimado para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	70

Tabela 7.14	Previsões para os seis meses de 2015 obtidas a partir do modelo GARMA-BN (4,0) estimado para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.	70
-------------	--	----

LISTA DE SÍMBOLOS

t	Instante de tempo
p	Ordem autorregressiva
q	Ordem de médias móveis
k	Número de diferenças da ordem integrada
Var	Variância
E	Esperança
k	Defasagens
n	Tamanho amostral da Série temporal
m	Número de parâmetros estimados
log	logaritmo neperiano
Cov	Covariância
C	Ciclo
S	Sazonalidade
T	Tendência
B	Operador de defasagem
Y	Série temporal
\tilde{Y}	Série temporal com a média populacional extraída
\hat{Y}	Valor estimado para Y
\bar{Y}	Média amostral da série temporal
g	Função de ligação
A	Função associada aos termos Autorregressivos
M	Função associada aos termos de médias móveis

Símbolos gregos

ϕ	Parâmetro autorregressivo
θ	Parâmetro de médias móveis
ϑ	Parâmetro canônico
φ	Parâmetro de dispersão
μ	Média populacional
∇	Operador de diferença
ε	Resíduo
ρ	Autocorrelação
ψ	Filtro linear
ε	Resíduo
γ	Covariância
η	Preditor linear
τ	Componente adicional do preditor linear

LISTA DE ABREVIATURAS

ADF	Dickey Fuller Aumentado
AIC	Critério de informação de Akaike
AICc	Criterio de informação de Akaike corrigido
AR	Autoregressivo
ARMA	Autoregressivo de médias móveis
ARIMA	Autoregressivo integrado de médias móveis
BIC	Critério de informação Bayesiano
BN	Binomial Negativa
CID-9	Classificação Estatística Internacional de Doenças e Problemas Relacionados com a Saúde- 9º Revisão
CID-10	Classificação Estatística Internacional de Doenças e Problemas Relacionados com a Saúde- 10º Revisão
DF	Dickey Fuller
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
FE	Erro de previsão
GARMA	Autorregressivo de médias móveis generalizado
HCV	Vírus da hepatite C
I	Integrado
IBGE	Instituto Brasileiro de Geografia e Estatística
<i>iid</i>	Independente e identicamente distribuído
INCA	Instituto Nacional de Câncer José Alencar Gomes da Silva
KPSS	Kwiatkowski Phillips Schmidt Shin
MA	Médias móveis
MAE	Erro absoluto médio
MAPE	Erro percentual médio absoluto
ME	Erro médio
MLG	Modelos Lineares generalizados
MPE	Erro percentual médio
MSE	Erro quadrático médio
OMS	Organização Mundial da Saúde
PP	Phillips Perron
PR	Paraná
RS	Rio Grande do Sul
RMSE	Raiz do erro quadrático médio
SC	Santa Catarina
SARS	Surto de síndrome respiratória aguda severa

1 INTRODUÇÃO

O avanço computacional ocorrido nas últimas décadas proporcionou uma importante descoberta de novas técnicas estatísticas, o aperfeiçoamento das já existentes, e ainda o desenvolvimento de softwares úteis na análise de dados utilizando essas técnicas. Assim, essa evolução resultou no crescimento do uso da estatística em estudos e pesquisas de teor científico realizadas em diferentes áreas do conhecimento.

A escolha do tipo de análise que será realizada é uma etapa fundamental da pesquisa e está intimamente relacionada aos objetivos e as especificidades apresentadas pelas variáveis que serão analisadas. Nos estudos pelos quais pretende-se analisar variáveis cujas observações se encontram dispostas em função do tempo, Box et al. (2015) indicam a análise de séries temporais. De acordo com Morettin e Toloi (2006), este tipo de análise possibilita evidenciar comportamentos sazonais, tendências, ciclos e mudanças de nível ocorridas na evolução dos dados. Possibilita também estimar modelos explicativos capazes de descrever o comportamento da sequência de observações, e ainda obter previsões a partir do modelo estimado.

A modelagem de séries temporais pode ser realizada de forma univariada, analisando o comportamento temporal de uma única variável, ou de forma multivariada, utilizando mais de uma variável na análise em questão. Quanto ao processo de coleta, o levantamento dos dados pode ocorrer de modo contínuo, infinito não numerável, sem que haja a interrupção na medição da variável. Ou também de modo discreto, finito ou infinito numerável, realizados em períodos específicos, eventualmente equidistantes, ou ainda partir da agregação de observações entre períodos (SOUZA; CAMARGO, 1996).

Os modelos aplicados nas séries de tempo se diferenciam dos modelos de regressão linear e dos modelos lineares generalizados (MLG) pela capacidade de analisar a dependência temporal existente nos dados. Essa dependência pode ser compreendida como a influência que as observações passadas exercem sobre o presente, e, a partir da modelagem dessa dependência, torna-se possível identificar modelos que explicam o comportamento dos dados.

No que se refere a análise univariada, as séries temporais podem ser analisadas utilizando os modelos autorregressivos de médias móveis (ARMA), descrito em sua forma geral por Whittle (1951). De forma mais ampla, os modelos estimados podem conter apenas termos autorregressivos (AR), termos de médias móveis (MA) ou também termos AR e MA. Porém, salienta-se que a utilização dessa classe de modelos torna-se adequada apenas em processos estacionários, os quais ocorrem quando o processo gerador da série é considerado invariante ao longo do tempo, e sob suposição de normalidade.

Contudo, sabe-se que frequentemente as séries temporais encontradas não são consideradas estacionárias. Para suprir essa necessidade, Box e Jenkins (1970), propuseram uma metodologia na qual inclui ao modelo ARMA um componente de integração, $I(d)$, capaz de "estacionarizar" processos não estacionários a partir da realização de sucessivas diferenças. Dessa forma, os modelos autorregressivos integrados de médias móveis (ARIMA) se popularizaram devido a

generalidade e simplicidade apresentada pela metodologia de Box-Jenkins.

Se o interesse é estudar séries de contagem, o mais adequado seria utilizar modelos baseados em distribuições de probabilidade para dados discretos, como é o caso das distribuições Poisson e a Binomial negativa. Nesse sentido, os MLG's introduzidos por Nelder e Wedderburn (1972), permitiram estender o uso dos modelos de regressão linear a distribuições pertencentes a família exponencial, na qual se incluem essas duas distribuições. No entanto, como já foi dito anteriormente, os MLG's não são capazes de analisar a dependência temporal presente nas séries temporais.

A análise dessa dependência temporal na estrutura de um MLG tornou-se possível mediante ao modelo Autorregressivo de Médias Móveis Generalizado (GARMA) propostos por Benjamin, Rigby e Stasinopoulos (2003). Essa nova classe de modelos trouxe maior flexibilidade aos modelos ARMA tendo como vantagem a possibilidade de analisar séries discretas, que não apresentam normalidade, com o uso das distribuições condicionais Poisson e Binomial Negativa.

Considerando-se um contexto epidemiológico, os modelos ARIMA e GARMA podem ser bastante úteis no combate, prevenção, controle e previsão de doenças ou agravos ligados a saúde. Nesse contexto, esse estudo propõe-se a analisar o comportamento dessas duas classes de modelos aplicadas a série temporal de óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

As neoplasias malignas de pele são as que mais acometem a população brasileira. Segundo estimativas do Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA) para o período de 2014 a 2017, esses tipos de neoplasias representavam cerca de um terço de todos os tipos de câncer esperados (INCA, 2014; INCA, 2015). Além disso, a Região Sul brasileira se destaca com as maiores taxas de incidência comparado às demais regiões, por isso a relevância em estudar a evolução dos óbitos por neoplasias malignas de pele nessa região.

1.1 Problema de pesquisa

Considerando a proposta apresentada, esse estudo pretende responder algumas questões quanto ao comportamento dos modelos ARIMA e GARMA na modelagem da série de óbitos por neoplasias malignas de pele ocorridos entre 1996 e 2014, na Região Sul do Brasil. Os principais questionamentos são os seguintes:

- Qual dessas classes de modelos apresenta melhor ajuste e menores erros de previsão para a série temporal analisada, considerando os óbitos de forma agregada, em períodos trimestrais?
- Qual dessas classes de modelos apresenta melhor ajuste e menores erros de previsão para a série temporal analisada, considerando os óbitos de forma agregada, em períodos mensais?
- Houve diferença entre a qualidade dos ajustes e das previsões comparando as diferentes formas de agregação das observações (trimestrais e mensais) ?

1.2 Justificativa

A proposta desta pesquisa, além de analisar as ocorrências de óbitos por neoplasias malignas de pele na região Sul brasileira, também pretende comparar as duas classes de modelos citadas. A modelagem utilizando a metodologia de Box-Jenkins, pela qual compreende os modelos ARIMA pode ser realizada a partir de diversos softwares estatísticos, pagos ou gratuitos. Já os modelos GARMA, por serem mais recentes, apenas podem ser modelados utilizando linguagem de programação. Consequentemente, isso se torna um fator limitante ao uso da classe de modelos proposta por Benjamin, Rigby e Stasinopoulos (2003), visto que os modelos ARIMA são de aplicação mais simples e menos trabalhosa.

Conforme verificado na literatura, a metodologia de Box-Jenkins foi utilizada no estudo de Akhtar e Rozi (2009), cujo objetivo era realizar previsões no curto prazo quanto à soroprevalência do vírus da hepatite C (HCV) em doadores de sangue do sexo masculino em Karachi, no Paquistão, entre 1998 e 2005. Também foi utilizada por Earnest et al. (2005) como ferramenta no monitoramento e previsão do número de leitos ocupados, durante uma epidemia ou surto de síndrome respiratória aguda severa (SARS), ocorrido no ano de 2003, em um hospital terciário em Cingapura.

O uso dos modelos ARIMA também foi verificado em estudos mais recentes como o de Liu et al. (2011), que consideram os modelos ARIMA na vigilância da incidência de febre hemorrágica com síndrome renal na China. E também no estudo de ZHANG et al. (2017), para estimar e prever a prevalência de cárie na primeira infância na China continental. Vale ressaltar, que os quatro estudos citados foram realizados após a publicação do modelo de Benjamin, Rigby e Stasinopoulos (2003) e utilizaram séries discretas como objeto de análise. Portanto, poderiam ter sido analisados utilizando os modelos GARMA com distribuições condicionais Poisson e Binomial Negativa, não fosse a maior complexidade de aplicação dessa classe de modelos.

1.3 Hipóteses

Com base no que foi apresentado, esse estudo se justifica ao testar as seguintes hipóteses:

- Hipótese 1: Os modelos GARMA, comparado aos modelos ARIMA, são mais adequados nos casos em que se pretende analisar séries discretas, devido a possibilidade de se utilizar as distribuições condicionais poisson ou binomial negativa. Por isso, é possível que as estimativas obtidas a partir dessa classe de modelos sejam mais precisas comparada ao ARIMA. Nesse sentido, se os resultados obtidos corroborarem com essa hipótese, esse estudo pode contribuir e estimular o uso dos modelos GARMA em estudos futuros.
- Hipótese 2: Também é possível que os resultados obtidos na comparação entre os modelos ARIMA e GARMA demonstrem que as estimativas obtidas sejam muito próximas ou parecidas. Desse modo, o uso da metodologia de Box-Jenkins apresentaria vantagem devido a simplicidade e facilidade de sua aplicação.

Diante disso, utilizar essas duas classes de modelos, aplicando-as a série de óbitos por neoplasias malignas de pele ocorridos na região Sul do Brasil, pode contribuir com respostas para essas hipóteses apresentadas, e também para alertar a população e os órgãos competentes quanto a necessidade de implementar melhorias nas políticas públicas voltadas à prevenção e ao controle dessa doença, que é um problema de saúde pública no país.

1.4 Objetivos

1.4.1 Objetivo Geral

Este estudo tem como objetivo realizar a modelagem da série de óbitos por neoplasias malignas de pele, ocorridos na Região Sul do Brasil, entre 1996 e 2014, agregados em períodos trimestrais e mensais, utilizando os modelos ARIMA e GARMA, a fim de compará-los para identificar qual apresenta melhor ajuste aos dados e previsões mais próximas da realidade.

1.4.2 Objetivos Específicos

- Identificar os componentes presentes no processo gerador das séries trimestral e mensal;
- realizar a modelagem das séries trimestral e mensal utilizando os modelos ARIMA, a fim de evidenciar aquele que apresenta as melhores estimativas e previsões no curto prazo;
- realizar a modelagem das séries trimestral e mensal utilizando os modelos GARMA, a fim de evidenciar aquele que apresenta as melhores estimativas e previsões no curto prazo;
- comparar os modelos obtidos a partir das estimações realizadas com as classes ARIMA e GARMA e discutir as principais semelhanças ou diferenças encontradas.

1.5 Estrutura do Trabalho

Este trabalho encontra-se estruturado em oito capítulos elucidando, inicialmente, a temática abordada, os objetivos geral e específicos, e também a justificativa para realização do estudo.

Os capítulos 2, 3, 4 e 5 apresentam a revisão de literatura abordando, respectivamente, conceitos relacionados à análise de séries temporais, modelos lineares para séries temporais estacionárias - ARMA, modelos lineares para séries temporais não estacionárias - ARIMA e modelos autorregressivos de médias móveis (GARMA).

O capítulo 6 apresenta a metodologia utilizada no desenvolvimento do estudo, enquanto o capítulo 7 apresenta e discute os resultados encontrados a partir da aplicação dos métodos apresentados nos capítulos anteriores. O trabalho é finalizado no capítulo 8 apresentando as considerações finais e fazendo algumas recomendações para futuros trabalhos relacionados ao tema.

2 SÉRIES TEMPORAIS

Este capítulo caracteriza aos conceitos relacionados as componentes não observáveis de uma série temporal e o processo gerador de uma série temporal, assim como as restrições impostas acerca desse processo, além do conceito de ruído branco.

2.1 Componentes não observáveis de uma série temporal

De acordo com Morettin e Tolo (2004), as séries temporais podem ser decompostas em quatro componentes não observáveis: a tendência (T_t), a sazonalidade (S_t), o ciclo (C_t) e o termo aleatório ou resíduo (ε_t) do modelo.

A componente de tendência refere-se a um movimento, crescente ou decrescente, dos dados numa determinada direção que dura por um determinado período de tempo. Essa componente é responsável por causar mudanças graduais no longo prazo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

A componente sazonal refere-se a movimentos oscilatórios que costumam ocorrer de forma repetida entre intervalos de mesma periodicidade (semanal, mensal, trimestral, etc.) De modo geral, quando há um movimento periódico de curta duração, normalmente inferiores a um ano. Por isso, séries cujas observações são anuais não sofrem influência da sazonalidade (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; VASCONCELLOS; ALVES, 2000).

A componente cíclica caracteriza-se por movimentos oscilatórios assim como a componente sazonal. A principal diferença está nos comprimentos que ocorrem em periodicidades variáveis. Além disso, os comprimentos médios dos ciclos são de longa duração e ocorrem geralmente em períodos superiores a um ano (VASCONCELLOS; ALVES, 2000).

A componente de resíduos caracteriza-se por variações esporádicas ou aleatórias que ocorrem em decorrência de fatores não explicáveis. Essas variações não são causadas por quaisquer outros componentes e são consideradas não previsíveis (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Conforme Brockwell e Davis (2009), a decomposição clássica possibilita que a série Y_t seja escrita na forma aditiva ou multiplicativa dos componentes não observáveis. Admite-se um modelo aditivo quando os componentes que formam o modelo devem ser somados para explicar o comportamento da série e, de forma análoga, o modelo multiplicativo apresenta as componentes multiplicadas, conforme representados na Eq. 2.1 e 2.2.

$$Y_t = T_t + S_t + C_t + \varepsilon_t \quad (2.1)$$

$$Y_t = T_t \times S_t \times C_t \times \varepsilon_t \quad (2.2)$$

É importante ressaltar que, nem todos os componentes descritos estarão presentes ao decompor uma série temporal. A ocorrência desses componentes se dará em decorrência das

características apresentadas por cada conjunto de observações (VASCONCELLOS; ALVES, 2000).

2.2 Processos estocásticos

Segundo Souza e Camargo (1996), processos estocásticos são denominados sistemas que evoluem no tempo ou espaço em termos probabilísticos. Em outras palavras, pode-se dizer que modelos capazes de descrever a estrutura de probabilidade do conjunto de observações de uma série temporal, considerando-se um fator aleatório inerente a estrutura desse modelo, são ditos processos estocásticos.

Bueno (2008) salienta que o processo gerador de uma série temporal deve obedecer as restrições de estacionariedade e ergodicidade para que possa inferir todas as características a partir desse processo, isto é, para se obter estimativas acerca da série temporal analisada.

2.2.1 Estacionariedade

Gujarati e Porter (2011) definem um processo estacionário como aquele que apresenta média e variância constantes ao longo do tempo e o valor da covariância entre dois períodos dependa apenas da distância, do intervalo ou da defasagem entre períodos e não do tempo real. Matos (2000) salienta que a violação do pressuposto de estacionariedade pode acarretar em resultados espúrios, sendo assim, pode não retratar a realidade de forma verdadeira.

Morettin e Tolo (2006) consideram que há duas formas de estacionariedade: fraca (ampla ou de segunda ordem) e estrita (ou forte). De modo geral, as séries estudadas costumam caracterizar-se como fracamente estacionárias, com as seguintes propriedades:

$$E(Y_t) = \mu \quad (2.3)$$

$$Var(Y_t) = E[(Y_t - \mu)^2] = \sigma^2 \quad (2.4)$$

$$\gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)] \quad (2.5)$$

em que $E(Y_t)$ representa a esperança de Y no instante t , μ representa a média populacional, $Var(Y_t)$ representa a variância de Y no instante t e γ_k representa a covariância na defasagem k .

A estacionariedade é uma condição bastante restritiva imposta às séries temporais, assim, na prática há um número reduzido de séries que satisfaçam essa condição. Diante disso, apresenta-se a não estacionariedade homogênea, definição atribuída aos processos pelos quais são possíveis torná-los estacionários após a realização de sucessivas diferenças (SOUZA e CAMARGO, 1996).

Para compreender melhor esse procedimento realizado para forçar a estacionariedade de

processos considerados não estacionários, define-se o operador de diferença ∇ que deve utilizado sucessivas vezes de modo a tornar o processo estacionário. Por exemplo:

- se uma série for não estacionária homogênea de primeira ordem, será necessário realizar a primeira diferença de Y_t para tornar a série estacionária, ou seja, $\nabla Y_t = Y_t - Y_{t-1}$;
- se uma série for não estacionária homogênea de segunda ordem, será necessário realizar a diferença diferença de Y_t para tornar a série estacionária, ou seja, $\nabla^2 Y_t = \nabla Y_t - \nabla Y_{t-1}$;
- de forma mais genérica, uma série será não estacionária homogênea de d -ésima ordem, se a realização de d diferenças for suficiente para tornar a série estacionária, ou seja $\nabla^d Y_t$.

2.2.2 Ergodicidade

A restrição de ergodicidade será satisfeita se apenas uma realização do mecanismo gerador da série for suficiente para obter todas as estatísticas necessárias. De modo geral, todo processo dito ergódico também é estacionário, pois, em contrapartida, processos não estacionários não são capazes de gerar todas as especificações necessárias para a realização do processo (SOUZA e CAMARGO, 1996).

Bueno (2008) relata que essa propriedade permite usar uma série temporal para calcular as médias em cada instante de tempo, e devido ao fato das médias serem todas iguais, basta uma única e particular realização r , do processo estocástico. Assim, a média temporal dessa realização é definida como:

$$\bar{Y}^{(r)} = \frac{1}{n} \sum_{i=1}^n Y_t^{(r)} \quad (2.6)$$

Conforme provado por Brockwell e Davis (1991), um processo é dito ergódico para a média se as autocovariâncias, quando somadas, resultarem em um valor finito, ou seja, as autocovariâncias devem torna-se nulas de forma rápida quando aumenta o número de defasagens.

2.3 Ruído Branco

O ruído Branco é uma sequência de valores de uma variável aleatória, denominados resíduos (ε_t), os quais são independentes e identicamente distribuídos (*iid*), com média zero e variância constante, $\varepsilon_t \sim iid(0, \sigma^2)$, além de serialmente não autocorrelacionados. Além disso, um ruído branco também é caracterizado como sendo estacionário (CUTHBERTSON; HALL; TAYLOR, 1992).

Os resíduos ε_t com as características apresentadas são chamados de ruídos brancos em analogia à "luz branca", na qual todas as cores estão presentes em quantidades iguais, ou seja, de forma homogênea.

3 MODELOS LINEARES PARA SÉRIES TEMPORAIS ESTACIONÁRIAS

Neste capítulo são apresentados os modelos autorregressivos, os modelos de médias móveis e os modelos autorregressivos de médias móveis nas suas diferentes representações, as condições para que os parâmetros desses modelos sejam estacionários e inversíveis, assim como o comportamento de suas funções de autocorrelação e autocorrelação parcial.

3.1 Modelos Autorregressivos

Segundo Maddala (2001) e Matos (2000), os modelos autorregressivos (AR) são aqueles cujos valores presentes de uma série temporal (Y_t), dependem apenas dos valores passados ($Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$) e dos resíduos ε_t , não correlacionados, distribuídos de forma aleatória com média zero e variância constante. Os p -ésimos períodos passados, suficientes para explicar um período presente, são também chamados de ordem do modelo AR, denominado AR(p). A equação geral do modelo AR pode ser definida como:

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (3.1)$$

em que μ representa a média, p representa o número de defasagens de Y_t , ϕ representa os parâmetros autorregressivos a serem estimados e ε_t representa os resíduos do modelo.

Box et al. (2015) reescrevem a equação 3.1, eliminando a média μ do processo. Assim, na Equação 3.2, μ é omitido e \tilde{Y} representado por $Y - \mu$.

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + \varepsilon_t \quad (3.2)$$

De acordo com Souza e Camargo (1996) e Box et al. (2015), o modelo AR(p) também pode ser expresso na forma do operador de retardo (B) por:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \tilde{Y} = \varepsilon_t \quad (3.3)$$

ou de forma simplificada:

$$\phi(B) \tilde{Y}_t = \varepsilon_t \quad (3.4)$$

Isolando \tilde{Y}_t têm-se:

$$\tilde{Y}_t = \frac{1}{\phi(B)}\varepsilon_t = \phi(B)^{-1}\varepsilon_t \quad (3.5)$$

3.2 Modelos de Médias Móveis

Segundo Hamilton (1994), nos modelos de médias móveis (MA), os valores de Y_t são obtidos por meio de uma soma ponderada dos valores mais recentes dos resíduos. Então, pode-se dizer que o modelo MA(q) é definido como a combinação linear dos resíduos até a q -ésima ordem ($\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$), ou seja, o número de resíduos necessários para explicar Y_t . A equação geral do modelo MA pode ser definida como:

$$Y_t = \mu + \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_2\varepsilon_{t-2}, \dots, -\theta_q\varepsilon_{t-q} \quad (3.6)$$

Em que q representa o número de defasagens de ε_t e θ_q representa os q parâmetros MA a serem estimados.

extraindo μ da Eq. 3.6 pode ser reescrito como:

$$\tilde{Y}_t = \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_2\varepsilon_{t-2}, \dots, -\theta_q\varepsilon_{t-q} \quad (3.7)$$

Na forma do operador B o modelo MA(q) é representado como:

$$\tilde{Y} = (1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q)\varepsilon_t \quad (3.8)$$

ou de forma simplificada:

$$\tilde{Y}_t = \theta(B)\varepsilon_t \quad (3.9)$$

3.3 Modelos Autorregressivos de Médias Móveis

Os modelos autorregressivos de médias móveis (ARMA) se caracterizam pela combinação dos modelos AR e dos modelos MA, descritos nas equações 3.1 e 3.6. Na parte AR, a série é explicada por uma regressão com até p defasagens, enquanto a parte MA modela os resíduos com até q defasagens. Com isso, o modelo ARMA (p, q) é denotado na sua forma geral pela seguinte equação:

$$Y_t = \mu + \phi_1Y_{t-1} + \phi_2Y_{t-2} + \dots + \phi_pY_{t-p} + \varepsilon_t - \theta_1\varepsilon_{t-1} - \dots - \theta_q\varepsilon_{t-q} \quad (3.10)$$

ou ainda:

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (3.11)$$

Na forma do operador B o modelo ARMA (p, q) é definido por Box et al. (2015) como:

$$(1 - \theta_1 B - \phi_2 B^2 - \dots - \theta_p B^p) \tilde{Y} = (1 - \theta_1 B - \phi_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (3.12)$$

ou de forma simplificada por:

$$\phi(B) \tilde{Y}_t = \theta(B) \varepsilon_t \quad (3.13)$$

Isolando \tilde{Y}_t , o modelo resulta em:

$$\tilde{Y}_t = \frac{\theta(B)}{\phi(B)} \varepsilon_t = \theta(B) \phi(B)^{-1} \varepsilon_t \quad (3.14)$$

3.4 Estacionariedade

A condição de estacionariedade dos modelos ARMA está associada a passagem do processo por um filtro linear Ψ_k . Se os pesos de $\Psi_1, \Psi_2, \dots, \Psi_k$ não convergirem rapidamente para zero, a variância da série Y_t também não convergirá, e conseqüentemente, a condição de estacionariedade não será satisfeita. Diz-se então que, para o processo gerado ser estacionário, o módulo da soma dos ϕ' s deve ser menor que um número real finito, assim o filtro se apresentará de forma estável (SOUZA; CAMARGO, 1996).

Nos modelos AR(p), a saída de Y_t é dada a partir do filtro linear cuja função de transferência é dada por $\phi^{-1}(B) = \Psi(B)$, sendo a entrada um ruído branco ε_t . Para que esse modelo satisfaça as condições de estacionariedade, as raízes do polinômio $\Psi^{-1}(B) = \phi(B) = 0$ devem estar fora do círculo unitário (Box et al., 2015).

Nos modelos MA(q) a função de transferência é dada por $\Psi(B) = \theta(B)$, e a condição de estacionariedade é dita trivial, visto que o filtro será estável, pois $\Psi(B)$ apresenta como resultando uma soma finita. Essa conclusão fica mais clara ao lembrarmos que a entrada desse processo é um ruído branco, $\varepsilon_t \sim i.i.d(0, \sigma^2)$, ou seja, como a entrada pelo filtro linear já é estacionária, é evidente que a saída também será estacionária (SOUZA; CAMARGO, 1996; MADDALA, 2001; BOX et al., 2015).

Para os modelos ARMA(p, q) a condição de estacionariedade corrobora com o que já foi descrito para os modelos AR(p) e MA(q). Sendo assim, basta que as raízes de $\phi(B)$ estejam fora do círculo unitário para que esse modelo seja estacionário.

3.5 Invertibilidade

Para estudar a invertibilidade deve-se expressar o modelo na forma inversa de modo que os ε_t sejam expressos em função de \tilde{Y}_t . Assim, os modelos AR(p), MA(q) e ARMA(p, q) escritos dessa forma estão descritos nas Eq. 3.15, 3.16 e 3.17:

$$\varepsilon_t = \tilde{Y}_t \phi(B) \quad (3.15)$$

$$\varepsilon_t = \tilde{Y}_t \theta^{-1}(B) \quad (3.16)$$

$$\varepsilon_t = \tilde{Y}_t \phi(B) \theta^{-1}(B) \quad (3.17)$$

Segundo Bueno (2008), a condição de invertibilidade está associada a dois principais fatores: a capacidade da série ser estimada por meio de um processo recursivo, usando as observações passadas e a singularidade dos resultados. No caso dos modelos AR(p), é possível observar que a invertibilidade é trivial (Eq. 3.15). Nos modelos MA(q), a condição de invertibilidade deve obedecer características parecidas com o que foi imposto à estacionariedade dos modelos AR(p). Nesse caso, as raízes do polinômio $\theta(B) = 0$ devem estar fora do círculo unitário, assim como nos modelo ARMA(p, q), cujas restrições também são impostas apenas aos termos MA.

3.6 Função de Autocorrelação e Função de Autocorrelação Parcial

A Função de autocorrelação (FAC) representa o conjunto de autocorrelações ρ defasada k vezes, ρ_k . Essa função serve para verificar ou mensurar o comprimento e a memória de processos, ou seja, a influência que o tempo $t - k$ exerce sobre o instante t (GUJARATI; PORTER, 2011; SOUZA; CAMARGO, 1996).

As autocorrelações ρ_k podem ser obtidas a partir da padronização das autocovariâncias, de acordo com a Eq. 3.18:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{Cov(Y_t, Y_{t+k})}{\sqrt{Var(Y_t) \cdot Var(Y_{t+k})}}, \quad -1 \leq \rho_k \leq 1 \quad (3.18)$$

Em que: γ_k representa a covariância de Y no instante t com Y no instante $t + k$ e γ_0 representa a própria variância de Y , visto que $k = 0$.

Na prática têm-se apenas a realização amostral de um processo estocástico, assim há apenas a possibilidade de se obter a FAC a partir da amostra, ou seja:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (3.19)$$

em que: $\bar{Y} = \frac{1}{n} \sum_{t=1}^n Y_t$, ou seja, a média de Y .

A função de autocorrelação parcial (FACP), representa o conjunto de autocorrelações parciais, ϕ_{kk} , medidas a partir da correlação entre duas observações seriais Y_t e Y_{t+k} , removendo o efeito exercido pelos termos intermediários $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$, de acordo com a Eq. 3.20.

$$Cor(Y_t, Y_{t+k} \mid Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}) \quad (3.20)$$

De forma geral, a FACP, pode ser obtida a partir da resolução do sistema apresentada na Eq. 3.21, baseado nas equações de Yule-Walker (YULE, 1927; WALKER, 1931), e a FACP amostral, $\hat{\phi}_{kk}$, através da resolução desse sistema considerando as estimativas dos parâmetros associados (MORETTIN; TOLOI, 2004).

$$\begin{bmatrix} 1 & \rho_1 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & 1 \end{bmatrix} \times \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \quad (3.21)$$

De acordo com Morettin e Tolo (2006) e Bueno (2008), no modelo $AR(p)$ a FAC tem extensão infinita e suas autocorrelações decrescem de forma exponencial ou senoidal amortecida, enquanto a FACP apresenta comportamento finito para $k \leq p$, anulando-se de forma brusca após as defasagens $k > p$. Por outro lado, a FAC de um modelo $MA(q)$ tem extensão finita, anulando-se após $k > q$, enquanto a FACP apresenta as mesmas características da FAC de um $AR(p)$. No caso dos modelos $ARMA(p,q)$, tanto a FAC, quanto a FACP possuem extensão infinita, cujo decaimento de ambas ocorre de forma exponencial ou senoidal amortecida, respectivamente após as defasagens $k > p - q$ e $k > q - p$, sem se anular bruscamente.

4 MODELOS LINEARES PARA SÉRIES TEMPORAIS NÃO ESTACIONÁRIAS

Este capítulo inicia evidenciando a existência de séries temporais não estacionárias e mostra todas as etapas utilizadas na metodologia de Box-Jenkins, frequentemente indicada para modelagem de séries com essa propriedade.

4.1 Metodologia de Box-Jenkins

A estacionariedade é uma condição fundamental para realização de inferências sobre os parâmetros estimados tendo como base a realização de um processo estocástico. Porém, na prática, as séries temporais raramente apresentam tal comportamento de forma não estacionária (BUENO, 2008).

Para possibilitar a análise de séries não apenas estacionárias, mas também séries não estacionárias, utilizando os modelos ARMA, Box e Jenkins (1970) incorporaram o operador ∇ na análise desses modelos. Assim, com o uso dos modelos autorregressivos, integrados, de médias móveis (ARIMA), tornou-se possível estender o uso dos modelos ARMA às séries não estacionárias homogêneas de ordem d , a partir da inclusão de um termo integrado ao modelo (BOX et al, 2015). Maddala (2001) considera que este tipo de abordagem se tornou bastante popular, justamente, por essa capacidade de generalização na análise de dados, destacando-se como uma das metodologias mais utilizadas na análise de séries temporais.

Para Souza e Camargo (1996), a metodologia de Box-Jenkins fundamenta-se no princípio da parcimônia e na modelagem baseada em um ciclo iterativo. Segundo Tukey (1961), o princípio da parcimônia está associado a ideia de obter modelos que se utilizam do menor número de parâmetros necessários para explicar o comportamento de uma série temporal. O ciclo iterativo (Fig. 4.1) baseia-se em um fluxograma realizado em quatro etapas: a identificação um modelo adequado para a série, a estimação dos parâmetros desse modelo, análise de diagnóstico dos resíduos do modelo estimado e obtenção de previsões.

Maddala (2001) apresenta a etapa de identificação de modelos de forma subdividida em duas partes. Na primeira parte, o autor descreve a identificação da ordem $I(d)$ do modelo a partir da verificação da estacionariedade da série, e caso necessário, a realização de sucessivas diferenciações até tornar o processo estacionário. Na segunda, o autor descreve a identificação das ordens p e q dos termos AR e MA do modelo ARIMA. inclusa na etapa de identificação de modelos apresentada por Morettin e Tolo (2006). Observa-se, portanto, que Maddala (2001) apenas divide o processo iterativo tornando-o, de certa forma, mais detalhado e compreensível.

É importante salientar que a interrupção do ciclo ocorre após a obtenção de um modelo satisfatório. Esse modelo será considerado satisfatório somente se, após a análise de diagnóstico, os resíduos do modelo satisfizerem algumas condições. Caso contrário, deve-se retroceder a etapa de identificação para que um novo modelo seja estimado e, novamente, realizar a análise

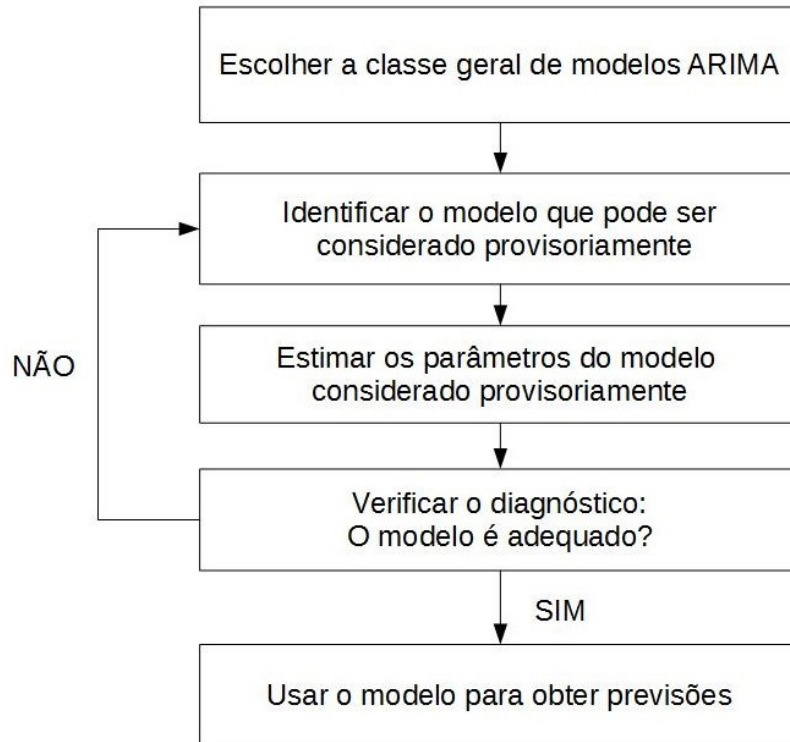


Figura 4.1: Ciclo iterativo da metodologia de Box-Jenkins

da adequação desse novo modelo (MATOS, 2000; GUJARATI; PORTER, 2011; BOX et al., 2015).

4.2 Identificação de modelos ARIMA

A identificação dos modelos $ARIMA(p,d,q)$ é baseada na determinação das ordens de três componentes, também denominados “filtros”: a ordem p , associada aos parâmetros do filtro AR; a ordem q , associada aos parâmetros do filtro MA; e ordem d , associada ao número de diferenciações necessárias para tornar a série estacionária (BOX et al., 2015; MORETTIN; TOLOI, 2006).

Vale ressaltar que, nem todas as séries apresentam esses três filtros. Há a possibilidade da existência de apenas parte desses filtros, assim sendo, a metodologia de Box-Jenkins resulta em diferentes modelos passíveis de análise (VASCONCELLOS; ALVES, 2000). Por isso, a identificação de modelos ARIMA deve ser realizada em dois estágios: primeiro deve-se verificar a estacionariedade da série para que seja possível determinar o número de diferenciações da ordem $I(d)$ e, posteriormente, as ordens p e q do modelo.

4.2.1 Determinação da ordem d do modelo ARIMA

Para determinar a ordem $I(d)$ do modelo ARIMA é preciso analisar a estacionariedade da série temporal. Inicialmente, essa análise pode ser realizada observando-se a evolução da série no decorrer dos períodos analisados, ou também, pelo comportamento observado na FAC (GUJARATI; PORTER, 2011).

Séries estacionárias apresentam um decaimento rápido da FAC à medida que aumenta o número de defasagens. Portanto, caso haja um decaimento lento da FAC à medida que aumenta o número de defasagens, há o indício da não estacionariedade da série (MADDALA, 2001; MORETTIN; TOLOI, 2006).

Outra forma de analisar a estacionariedade de uma série temporal é a partir da realização de testes de raiz unitária. De acordo com Gujarati e Porter (2011), esses testes são bastante úteis pois, séries que apresentam raiz unitária violam os pressupostos de estacionariedade. Nesse sentido, torna-se necessário que se obtenha a ausência de raiz unitária para que a série seja considerada estacionária, ou ainda, que sejam realizadas sucessivas diferenciações até que esse pressuposto seja atingido.

Há na literatura diversos testes de raiz unitária como: Dickey-Fuller (DF), Dickey-Fuller Aumentado (ADF), Phillips-Perron (PP), Kwiatkowski-Phillips-Schmidt-Shin (KPSS), entre outros. De modo geral, com exceção do teste KPSS, os testes citados apresentam as seguintes hipóteses:

H_0 : Há uma raiz unitária/ A série é não estacionária ou possui uma tendência estocástica.

H_1 : Não há uma raiz unitária/ A série é estacionária.

Apesar de ser utilizado com a mesma finalidade dos testes DF, ADF e PP, o teste KPSS apresenta as hipóteses H_0 e H_1 invertidas, isto é:

H_0 : A série é estacionária (Ausência de raízes fora do círculo unitário)

H_1 : A série não é estacionária (Presença de raízes fora do círculo unitário)

Para maiores informações sobre as principais diferenças entre esses testes consultar: Dickey e Fuller (1979), Dickey e Fuller (1981), Phillips e Perron (1988) e Kwiatkowski et. al (1992).

4.2.2 Determinação da ordem p e q do modelo ARIMA

Após a definição do número de diferenças do termo $I(d)$, deve-se identificar o número ideal de parâmetros AR e de parâmetros MA do modelo que será estimado. Para isso, Gujarati e Porter (2011) sugerem a utilização da FAC e da FACP para identificar o número defasagens significativas, isto é, fora dos limites de confiança, resultantes da análise do conjunto de observações de série estacionária em nível ou estacionarizada. Essa tipo de determinação baseia-se no comportamento que essas duas funções apresentam para as diferentes combinações

de modelos ARMA, conforme descrito na Seção 3.6.

É importante destacar que a detecção pela FAC e pela FACP é uma maneira imprecisa de definir as ordens p e q , ideais para modelo. Isso deve-se ao fato desse tipo de análise ser realizada de forma visual e, por isso, pode resultar na escolha de números inferiores ou superiores ao ideal de parâmetros do modelo. Desse modo, sugere-se que essa utilização seja realizada apenas como ponto de partida no processo de escolha, até mesmo porque esse critério não leva em consideração o princípio da parcimônia.

Para sofisticar a escolha das ordens p e q é possível utilizar a ordem do modelo ARIMA, definida a partir da interpretação da FAC e da FACP, estimar diversos modelos com ordens que variam em torno daquela que foi identificada, e na sequência, compará-los. Assim, a escolha das ordens p e q passa a ser realizada conjuntamente à etapa seguinte do ciclo iterativo.

4.3 Estimação de modelos ARIMA

A segunda etapa do ciclo iterativo da metodologia de Box-Jenkins está associada a estimação dos parâmetros do modelo ARIMA(p, d, q).

De acordo com Morettin e Toloi (2006) e Box et al. (2015), o modelo ARIMA(p, d, q) geral pode ser descrito da mesma forma que um ARMA(p, q), substituindo Y_t por w_t , em que esse representa um Y_t após a realização de d diferenças ($w_t = \nabla^d Y_t$) até tornar o processo estacionário:

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (4.1)$$

Na forma do operador B o modelo ARIMA pode ser descrito como:

$$(1 - \theta_1 B - \phi_2 B^2 - \dots - \theta_p B^p) w_t = (1 - \theta_1 B - \phi_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (4.2)$$

ou resumido como:

$$\phi(B) w_t = \theta(B) \varepsilon_t \quad (4.3)$$

A estimação dos parâmetros desse modelo pode ser realizada utilizando o método dos mínimos quadrados ordinários, o método dos mínimos quadrados não lineares, o método de máxima verossimilhança condicional e também de máxima verossimilhança exata (BOX et al. 2015; BUENO, 2008).

De acordo com Bueno (2008), tanto o método de máxima verossimilhança condicional, quanto o método de máxima verossimilhança exata possuem as mesmas propriedades assintóticas, assim como o método dos mínimos quadrados condicionais, quando a condição de

inversibilidade do termo MA é satisfeita. O autor ainda complementa que as estimativas obtidas por esses métodos são todas consistentes, diferentemente da eficiência, que é maior no método de máxima verossimilhança exata.

Após a estimação de modelos com diferentes ordens utilizando algum dos métodos citados torna-se necessário decidir qual desses modelos passará para a etapa de análise de diagnóstico. Sabe-se que, na prática poderá existir mais de um modelo explicativo para as variações ocorridas nos dados. Por isso, Burnham e Anderson (2004) enfatizam a importância de escolher ou selecionar modelos a partir de princípios científicos.

4.3.1 Critérios de seleção de modelos

Há na literatura o critério de informação de Akaike (AIC) e o critério de informação Bayesiano (BIC), desenvolvidos, respectivamente, por Akaike (1973) e Schwarz (1978), entre os possíveis critérios de seleção de modelos, os quais se baseiam nas estimativas da log verossimilhança e ainda penalizam os ajustes pelo número de parâmetros estimados. Esses critérios são definidos pelas Eq. 4.4 e 4.5:

$$AIC = -2 \log(\hat{L}) + 2(m + 1) \quad (4.4)$$

$$BIC = -2 \log(\hat{L}) + (m + 1) \log(n) \quad (4.5)$$

em que $\log(\hat{L})$ representa o logaritmo na base e do estimador de máxima verossimilhança e m representa o número de parâmetros estimados, onde $m = p + q + 1$, se houver constante no modelo ARIMA estimado, e $m = p + q$, se não houver constante no modelo.

Quando o tamanho amostral é pequeno, há uma probabilidade substancial de que o AIC selecione modelos que tenham muitos parâmetros, isto é, modelos com número de parâmetros superior ao ideal, e como se sabe, esse problema vai de encontro ao princípio da parcimônia. Diante disso, Hurvich e Tsai (1989) propuseram uma correção para o AIC, a fim de melhorar seu comportamento no sentido de minimizar a probabilidade de selecionar modelos hiperparametrizados. Assim, o AIC corrigido (AICc) é dado por:

$$AICc = AIC + \frac{2m(m + 1)}{n - m - 1} \quad (4.6)$$

Salienta-se que é possível que os critérios apresentados nas Eq. 4.4, 4.5 e 4.6 selecionem modelos de ordens distintas, visto que as penalizações quanto ao número de parâmetros são calculadas de forma diferente. Porém, de modo geral, o modelo mais parcimonioso será aquele que produzir o menor resultado, de acordo com cada um desses critérios.

4.4 Análise de Diagnóstico

A terceira etapa da metodologia de Box-Jenkins fundamenta-se na realização de uma análise de diagnóstico dos resíduos a fim avaliar a adequação do modelo ajustado. Para que essa análise produza resultados satisfatórios, é desejável que os resíduos sejam *i.i.d*, resultando na ausência de autocorrelação. Além disso, esses resíduos devem seguir uma distribuição Normal.

Conforme Matos (2000), a análise da ausência de autocorrelação pode ser realizada a partir da avaliação da FAC dos resíduos. As autocorrelações residuais devem se encontrar dentro dos limites de confiança estabelecidos. Outra maneira de analisar a autocorrelação dos resíduos é a partir do teste Q' proposto por Ljung e Box (1978). Esse teste é uma variação do teste de Box e Pierce (1970) e pode ser calculado por meio da Eq. 4.7.

$$Q' = n(n - 2) \sum_{k=1}^i \frac{\hat{\rho}_k^2(\hat{\varepsilon})}{n - k} \quad (4.7)$$

A estatística do teste Q' tem aproximadamente distribuição χ^2 com $k - p - q$ graus de liberdade. E as hipóteses desse teste podem ser representadas por:

$$H_0 : \sum_{i=1}^k \rho_i = 0 \text{ (Não há evidências que os resíduos não sejam } i.i.d)$$

$$H_1 : \sum_{i=1}^k \rho_i \neq 0 \text{ (Há evidências que os resíduos não sejam } i.i.d)$$

A hipótese H_0 do teste é que os resíduos são iid, isto é, comportam-se como um ruído branco. Se essa hipótese for rejeitada, deve-se retroceder a etapa 1 para escolha de um novo modelo e realizar novamente os procedimentos sequencias da metodologia de Box-Jenkins.

A normalidade dos resíduos do modelo ajustado pode ser avaliada através de diversos testes de hipóteses, entre os quais estão: Shapiro-Wilk, Anderson-Darling, Lilliefors, Jarque-Bera, Cramer-von Mises, D'Agostino Pearson e Kolmogorov-Smirnov (RAZALI; WAH, 2011). As hipóteses avaliadas a partir desses testes são as seguintes:

$$H_0: \text{ Não há evidências para rejeitar a hipótese de normalidade.}$$

$$H_1: \text{ Há evidências para rejeitar a hipótese de normalidade.}$$

Entre os testes citados, Carradori e Ramos (2014) consideram que testes de Shapiro-Wilk e Anderson-Darling são mais poderosos em distribuições simétricas com caudas curtas; o poder dos testes Jarque-Bera (JB) e D'Agostino-Pearson se equipara com o teste de Shapiro-Wilk em distribuições simétricas com caudas longas; em distribuições assimétricas o teste Shapiro-Wilk é o mais o mais poderoso, seguido do teste Anderson-Darling. De modo geral, os testes Shapiro-Wilk, Anderson-Darling e Jarque-Bera apresentam bons resultados na verificação da normalidade.

4.5 Previsões

A última etapa consiste em obter previsões a partir do modelo estimado, analisando sua qualidade em função da proximidade dessas previsões aos dados reais, ou seja, pela sua precisão.

4.5.1 Medidas de precisão ou acurácia

Após estimação dos parâmetros do modelo escolhido, análise de diagnóstico dos resíduos e obtenção de previsões, é conveniente avaliar a precisão ou qualidade das previsões obtidas. Para isso, Makridakis, Wheelwright e Hyndman (1998) apresentam o erro de previsão (FE) como a medida mais simples para avaliar a qualidade das previsões geradas pelo modelo. Essa medida é calculada, conforme a Eq. 4.8, a partir da diferença entre o valor observado para Y_t e o valor previsto (ou valor estimado), \hat{Y}_t , para o período considerado.

$$FE = Y_t - \hat{Y}_t \quad (4.8)$$

Observa-se que o FE é bastante limitado e restringe-se a medir os erros a um período específico da série analisada. Quando o interesse for avaliar previsões para n períodos de tempo, tem-se outras medidas. Nesse caso, Makridakis, Wheelwright e Hyndman (1998) citam o erro médio (ME), o erro absoluto médio (MAE) e o erro quadrático médio (MSE), respectivamente, representados pelas Eq. 4.9, 4.10 e 4.11:

$$ME = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t) \quad (4.9)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (4.10)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (4.11)$$

Os autores reiteram que é possível que o ME gere resultados pequenos, pois os FE's tendem a se anular ou subestimar a interpretação dessa medida, por poderem assumir resultados tanto positivos quanto negativos. Em contrapartida, o MAE e o MSE solucionam esse problema de subestimação, tendo o MAE a vantagem da fácil interpretação e o MSE a vantagem de ser mais fácil de manipular matematicamente.

Hyndman e Koehler (2006) complementam essas medidas apresentando a raiz do erro quadrático médio (RMSE), definida na Eq. 4.12. Em relação ao MSE, essa medida tem a vantagem de apresentar o resultado na mesma unidade de medida da variável. As críticas feitas pelos autores a essa medida dizem respeito à impossibilidade de comparação de resultados obtidos quando as séries são mensuradas em escalas diferentes.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (4.12)$$

As medidas que apresentam melhor qualidade são o erro percentual médio (MPE) (Eq. 4.13) e o erro percentual médio absoluto (MAPE) (Eq. 4.14). Essas se encontram na forma de percentuais, sendo passíveis de comparação com outras séries por estarem livres de unidade (MAKRIDAKIS, WHEELWRIGHT; HYNDMAN, 1998; HYNDMAN; KOEHLER, 2006).

$$MPE = \frac{1}{n} \sum_{t=1}^n \left[\frac{Y_t - \hat{Y}_t}{Y_t} \right] \times 100 \quad (4.13)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (4.14)$$

A última medida apresentada é a estatística U (Eq. 4.15), desenvolvida por Theil (1966). Essa medida estatística permite uma comparação relativa dos métodos formais de previsão com as previsões ingênuas. É desejável que o resultado do U de Theil seja menor que 1 para que as previsões do método utilizado sejam melhores que as previsões ingênuas.

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left(\frac{\hat{Y}_{t+1} - Y_{t+1}}{Y_t} \right)^2}{\sum_{t=1}^{n-1} \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2}} \quad (4.15)$$

Quando U é igual a 1, considera-se que previsões obtidas não foram nem melhores, nem piores que as previsões ingênuas. E nos casos em que o U de Theil é maior que 1, é interessante que o modelo utilizado seja desconsiderado, pois esse produz previsões piores do que as obtidas pelo método de previsão ingênuas.

5 MODELOS GARMA

O modelo GARMA, proposto por Benjamin, Rigby e Stasinopoulos (2003), é considerado uma extensão dos MLG's na qual as variáveis são condicionais às informações passadas e possuem distribuições pertencentes a uma classe conhecida como família exponencial. Esse modelo é fundamentalmente baseado nos modelos desenvolvidos por Zeger e Qaqish (1988), os quais foram aprimorados por Li(1994).

O modelo desenvolvido por Zeger e Qaqish (1988) introduziu aos modelos autorregressivos exponenciais, que são casos particulares para a utilização das distribuições condicionais Poisson e Gama. Já Li (1994) apresentou grande contribuição ao introduzir uma forma de média móvel ao modelo de Zeger e Qaqish (1988).

O modelo GARMA estendeu o uso dos modelos propostos anteriormente às distribuições da família exponencial. Sendo assim, esse novo modelo trouxe uma nova perspectiva a análise de séries temporais, possibilitando modelar uma variedade de variáveis com dependência temporal através do uso de outras distribuições condicionais como: Poisson e Binomial negativa (BN), que são exemplos mais adequados quando se têm o objetivo de modelar dados de contagem.

O surgimento do modelo GARMA possibilitou uma parametrização mais parcimoniosa, em relação aos modelos puramente autorregressivos ou puramente de médias móveis, ao considerar um misto desses modelos. Além disso, pode acomodar comportamentos não estacionários, que podem surgir devido à influência de variáveis exógenas.

5.1 Modelo Geral

Segundo Benjamin et al. (2003) assume-se que, no modelo GARMA, a distribuição condicional de cada observação y_t , para todo $t= 1, \dots, n$ dado o conjunto de informações passadas $\underline{H}_t = (\underline{x}_t, \dots, \underline{x}_1, y_{t-1}, \dots, y_1, \mu_{t-1}, \dots, \mu_1)$, pertencente à mesma família exponencial. Sua densidade condicional é denotada por:

$$f(y_t | \underline{H}_t) = \exp \left\{ \frac{y_t \vartheta_t - b(\vartheta_t)}{\varphi} + d(y_t, \varphi) \right\} \quad (5.1)$$

Onde ϑ_t e φ são, respectivamente os parâmetros canônico e de dispersão, $b(\cdot)$ e $d(\cdot)$ são funções específicas que definem casos específicos da família exponencial, e \underline{x} é o vetor de variáveis explicativas de tamanho k .

McCullagh e Nelder (1989) definem que os termos $\mu_t = b'(\vartheta_t) = E(y_t | \underline{H}_t)$ e $\text{var}(y_t | \underline{H}_t)$ representam a média condicional e variância condicional de y_t , dado \underline{H}_t . Essa notação é a mesma apresentada pelos MLG's, com observações independentes, porém, nesse caso as distribuições modeladas são as condicionais em vez das marginais.

No MLG padrão, a média condicional, μ_t , apresenta relação com o preditor η_t . Essa relação ocorre através da função de ligação $g(\cdot)$, que é monotônica e duas vezes diferenciável, podendo

ser denotada por $g(\mu_t) = \eta_t$. Já no modelo GARMA o preditor η_t apresenta um componente adicional, τ_t , no qual permite que os termos AR e MA sejam incluídos, assim como valores passados das variáveis explicativas presentes no modelo (BENJAMIN; RIGBY; STASINOPOULOS, 2003). Portanto, o modelo geral para $g(\mu_t)$ é dado por:

$$g(\mu_t) = \eta_t = \underline{x}'_t \underline{\beta} + \tau_t \quad (5.2)$$

Sendo τ_t definido como:

$$\tau_t = \sum_{j=1}^p \phi_j A(y_{t-j}, \underline{x}_{t-j}, \underline{\beta}) + \sum_{j=1}^q \theta_j M(y_{t-j}, \mu_{t-j}) \quad (5.3)$$

onde A e M são funções que representam, respectivamente, os termos AR e MA, e $\underline{\phi}' = (\phi_1, \dots, \phi_p)$ e $\underline{\theta}' = (\theta_1, \dots, \theta_p)$ representam os parâmetros associados aos termos.

Benjamin, Rigby e Stasinopoulos (2003) ressaltam que o modelo apresentado na equação 5.3 é muito geral para a aplicação prática. Por isso, deve-se considerar um modelo mais flexível e parcimonioso, conforme o apresentado na equação 5.4.

$$g(\mu_t) = \eta_t = \underline{x}'_t \underline{\beta} + \sum_{j=1}^p \phi_j \{g(y_{t-j}) - \underline{x}'_{t-j} \underline{\beta}\} + \sum_{j=1}^q \theta_j \{g(y_{t-j}) - \eta_{t-j}\} \quad (5.4)$$

Logo, as equações 5.1 e 5.4 definem conjuntamente o modelo GARMA(p,q). Diante disso, partir de então, será dado ênfase aos casos específicos onde a função distribuição de probabilidade utilizada para y_t dado \underline{H}_t são as distribuições de Poisson e BN.

5.2 Modelo GARMA-Poisson

No modelo GARMA-Poisson a distribuição condicional de Y_t é a Poisson, conforme apresentado na equação 5.5.

$$f(y_t | \underline{H}_t) = \frac{\mu_t^{y_t} e^{-\mu_t}}{y_t!} \quad (5.5)$$

Benjamin, Rigby e Stasinopoulos (2003) definem a função logarítmica como função de ligação, pois ela admite valores naturais. Sendo assim, o modelo GARMA-Poisson é definida conforme a equação 5.6.

$$\log(\mu_t) = \underline{x}'_t \underline{\beta} + \sum_{j=1}^p \phi_j \left\{ \log(y_{t-j}^*) - \underline{x}'_{t-j} \underline{\beta} \right\} + \sum_{j=1}^q \theta_j \left\{ \log \left(\frac{y_{t-j}^*}{\mu_{t-1}} \right) \right\} \quad (5.6)$$

onde $y_{t-j}^* = \max(y_{t-j}, c)$ e $0 < c < 1$, de modo a substituir valores de $y_{t-j} = 0$ por c a fim de permitir o uso da função logarítmica como função de ligação na modelagem de séries que possuam algumas observações iguais a zero.

No modelo GARMA com distribuição condicional Poisson a esperança e a variância condi-

onal são dadas, respectivamente, pela Eq. 5.7 e Eq. 5.8. Observando essas equações é possível verificar que a $E[y_t|\underline{H}_t]$ e a $Var[y_t|\underline{H}_t]$ se equivalem.

$$E[y_t|\underline{H}_t] = \mu_t \quad (5.7)$$

$$Var[y_t|\underline{H}_t] = \mu_t \quad (5.8)$$

5.3 Modelo GARMA-Binomial Negativa

No modelo GARMA-BN a distribuição condicional de Y_t é dada por:

$$f(y_t | \underline{H}_t) = \frac{\Gamma(y_t + v)}{\Gamma(v)\Gamma(y_t + 1)} \left\{ \frac{\mu_t}{\mu_t + v} \right\}^{y_t} \left\{ \frac{\mu_t}{\mu_t + v} \right\}^v \quad (5.9)$$

Para $y_t = 0, \dots, n$ e $v > 0$ onde v é o parâmetro de dispersão.

Benjamin, Rigby e Stasinopoulos (2003) também definem a função logarítmica como função de ligação. Quanto à estrutura, o modelo GARMA-BN é definido da mesma forma que o GARMA-Poisson (Eq. 5.6). A principal diferença do modelo GARMA com distribuição condicional BN, em relação ao GARMA com distribuição condicional Poisson, diz respeito a esperança e a variância condicional representadas, respectivamente, pela Equação 5.10 e Equação 5.11.

$$E[y_t|\underline{H}_t] = \mu_t \quad (5.10)$$

$$Var[y_t|\underline{H}_t] = \mu_t + \frac{\mu_t^2}{v} \quad (5.11)$$

Pode-se observar que ambos os modelos apresentam mesma esperança, mas variâncias diferentes. No modelo GARMA-BN a $Var[y_t|\underline{H}_t] > E[y_t|\underline{H}_t]$, por isso é indicado aos casos em que há superdispersão nos dados.

6 METODOLOGIA

Neste capítulo são apresentadas as características metodológicas acerca do estudo que foi desenvolvido. Apresenta-se definições como: tipo de estudo que foi realizado, descrição do espaço geográfico que foi considerado, descrição detalhada da variável e do período que foi analisado e fonte das informações, assim como os procedimentos metodológicos utilizados a fim de alcançar os objetivos propostos.

6.1 Tipo de estudo

Realizou-se um estudo comparativo entre os modelos ARIMA e GARMA aplicado a um contexto epidemiológico, cujo objetivo foi analisar a série de óbitos por neoplasias malignas de pele, ocorridos na região Sul do Brasil, entre 1996 e 2014, afim de avaliar a qualidade das estimativas e das previsões obtidas a partir dessas duas classes de modelos.

As observações da série foram analisadas em nível agregado, considerando dois tipos de periodicidade: trimestral e mensal, dispostas em intervalos equidistantes. Por isso, esse estudo é caracterizado como ecológico quanto à variável analisada. Segundo Lima-Costa e Barreto (2003), esse termo é utilizado para classificar os estudos epidemiológicos cuja variável é analisada em nível agregado de indivíduos, e nesse contexto, essas agregações se referem às periodicidades e a região considerada.

6.2 Descrição do espaço geográfico analisado

Analisou-se os óbitos ocorridos na Região Sul do Brasil, formada pelos estados do Rio Grande do Sul(RS), Santa Catarina(SC) e Paraná(PR). De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), essa região ocupa uma área equivalente a $576.773,368 \text{ km}^2$ e é considerada a menor entre as cinco regiões do país.

6.3 Descrição da variável analisada

Considerou-se todos óbitos que apresentaram como causa básica as neoplasias malignas de pele. Estes tipos de neoplasias compreendem todos os óbitos relacionados a melanomas malignos de pele (C43) e outros tipos de neoplasias malignas de pele (C44), conforme a Classificação Estatística Internacional de Doenças e Problemas Relacionados com a Saúde-10ª Revisão (CID-10), estabelecida pela Organização Mundial da Saúde (1994). Esses casos estão presentes no Capítulo II da CID-10, a qual se refere a todos os tipos de neoplasias, tumores ou cânceres. De forma geral, foram incluídas todas as neoplasias relacionadas às classificações C43 e C44, que correspondem, de forma detalhada, a todos os casos apresentados na Tabela 6.1.

Tabela 6.1: Codificação definida para as neoplasias malignas de pele.

Codificação	Melanomas malignos de pele(C43)
C43.0	Melanoma maligno do lábio
C43.1	Melanoma maligno da pálpebra, incluindo o canto
C43.2	Melanoma maligno da orelha e do canal auricular externo
C43.3	Melanoma maligno de outras partes e partes não especificadas da face
C43.4	Melanoma maligno do couro cabeludo e do pescoço
C43.5	Melanoma maligno do tronco
C43.6	Melanoma maligno do membro superior, incluindo ombro
C43.7	Melanoma maligno do membro inferior, incluindo quadril
C43.8	Melanoma maligno da pele sobreposta
C43.9	Melanoma maligno de pele, não especificado
Codificação	Outros tipos de neoplasias malignas de pele(C44)
C44.0	Neoplasia maligna da pele do lábio
C44.1	Neoplasia maligna da pele da pálpebra, incluindo o canto
C44.2	Neoplasia maligna da pele da orelha e do canal auricular externo
C44.3	Neoplasia maligna da pele de outras partes e partes não especificadas da face
C44.4	Neoplasia maligna da pele do couro cabeludo e do pescoço
C44.5	Neoplasia maligna da pele do tronco
C44.6	Neoplasia maligna da pele do membro superior, incluindo ombro
C44.7	Neoplasia maligna da pele do membro inferior, incluindo quadril
C44.8	Neoplasia maligna da pele com lesão sobreposta
C44.9	Neoplasia maligna da pele, não especificada

6.4 Descrição do período analisado

Quanto ao período analisado, considerou-se 76 observações de periodicidade trimestral e 228 observações de periodicidade mensal, entre os anos de 1996 a 2014. Salienta-se que foram utilizadas apenas observações a partir do ano de 1996, pois esse ano representa o marco inicial da utilização da CID-10 como critério de classificação em saúde no Brasil. Até então, era utilizada a Classificação Estatística Internacional de Doenças e Problemas Relacionados com a Saúde-9º Revisão (CID-9), dificultando assim a utilização de períodos anteriores devido às diferenças entre as revisões.

6.5 Fonte das informações

A coleta das informações foi realizada por meio da base de dados do Sistema de Informações sobre Mortalidade (SIM), disponibilizada pelo Departamento de Informática do Sistema Único de Saúde (DATASUS), órgão da Secretaria de Gestão Estratégica e Participativa do Ministério da Saúde. Esses dados tratam de informações oficiais brasileiras e estão disponíveis de forma pública. Deste modo, não houve a necessidade de avaliação ou aprovação de algum comitê de ética para que os dados pudessem ser utilizados.

6.6 Procedimentos metodológicos

O estudo comparativo foi realizado a partir da modelagem da série temporal, utilizando os modelos ARIMA e GARMA, de acordo com os procedimentos apresentados a seguir:

- análise gráfica da série original e do correlograma da série, a fim de observar possíveis presenças de tendência ou sazonalidade;
- realização dos testes de raiz unitária ADF e KPSS a fim de verificar se a série original é ou não estacionária;
- se a série não fosse estacionária, foram realizadas d diferenças até que se obtivesse a ausência de raiz unitária, ou em outras palavras, a estacionariedade ou estabilidade da série;
- após atingida a estacionariedade da série, foi analisado, novamente, o correlograma, tendo como finalidade auxiliar na detecção e obtenção de possíveis modelos candidatos, baseando-se no número de defasagens fora dos limites de confiança observado na FAC e FACP;
- a partir da identificação de modelos ajustados à série, utilizou-se o AIC, AICc e BIC para definir aquele com melhor ajuste;
- o passo seguinte consistiu na análise de diagnóstico, com o intuito de avaliar os resíduos do modelo. Foi realizado o teste Q' de Ljung-Box a fim de verificar se os resíduos são *iid*. Também foi realizado o teste Jarque-Bera para verificar a normalidade dos resíduos, assim como o gráfico Q-Q Normal com envelopes de confiança simulados;
- caso os pressupostos de normalidade e ruído branco não tivessem sido atendidos, foi considerado o modelo seguinte que apresentasse o menor AIC AICc e BIC. Realizou-se novamente a análise de diagnóstico até que os pressupostos tivessem sido atingidos;
- a partir disso, foram realizadas previsões para o modelo ARIMA (p,d,q) identificado, assim como a avaliação da qualidade das previsões através do MAPE, MPE, REQm, e U de Theil;
- a validação do modelo foi realizada comparando o número de óbitos observados, para os quatro trimestres de 2015 e para os 6 meses desse mesmo ano, com os valores previstos pelos modelos. Esses foram considerados válidos quando os valores observados estavam dentro dos intervalos de confiança de previsão;
- a modelagem da série utilizando os Modelos GARMA (p,q) , Poisson e Binomial Negativa, foi análoga à modelagem dos modelos ARIMA, conforme descrito anteriormente.

Posteriormente, foi realizada a comparação dos resultados obtidos entre os modelos ARIMA e GARMA a fim de identificar a classe que apresentou os melhores ajustes e melhor qualidade de previsões para a série analisada.

Todas as análises foram realizadas em linguagem de programação no software R core Team (2017), livre e gratuito, utilizando os pacotes: stats, graphics, lattice, astsa, forecast, tseries, urca, car, nortest, gamlss.util e VGAM, entre outros.

7 RESULTADOS

Este capítulo apresenta uma análise descritiva das séries com periodicidade trimestral e mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014, o ajuste dos modelos ARIMA e GARMA, assim como a comparação entre essas duas classes de modelos.

7.1 Apresentação e análise descritiva das séries temporais

As séries temporais analisadas estão apresentadas na Fig. 7.1 e na Fig. 7.2. Pode-se observar em ambas as figuras uma tendência de crescimento na ocorrência de óbitos por neoplasias malignas de pele na região Sul ao longo do período apresentado.

O menor número de óbitos trimestrais ocorreu no 4º trimestre de 1997, com 87 óbitos registrados, e atingiu o maior número no 1º trimestre de 2014, com 235 óbitos. Ao longo dos 19 anos analisados a média do número de óbitos trimestrais foi de 160,1, o desvio padrão foi de 38,4 óbitos e o coeficiente de variação foi de 23,7%. O menor número de óbitos mensais ocorreu em dezembro de 1997, com 22 óbitos, e atingiu o maior número em julho de 2011, com 91 óbitos. Ao longo dos 19 anos analisados a média do número de óbitos mensais foi de 54,0, o desvio padrão foi de 14,3 óbitos e o coeficiente de variação foi de 26,4%.




Figura 7.1: Série temporal trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.




Figura 7.2: Série temporal mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

7.2 Análise da estacionariedade das séries temporais

Realizou-se, inicialmente, uma análise gráfica para avaliar a estacionariedade das séries de óbitos por neoplasias malignas de pele ocorridos na região Sul do Brasil entre 1996 e 2014. De acordo com a Fig. 7.1 e a Fig. 7.2, tanto a série trimestral, quanto a série mensal não aparentam ser estacionárias, pois apresentaram característica de crescimento no número de óbitos, ou seja, com aparente presença de uma tendência crescente (ou positiva). Gráficamente não foram observadas em nenhuma das séries algum tipo de variação regular entre períodos de mesmo comprimento, característica que vai ao encontro de uma possível ausência de componente sazonal na evolução das observações.

A estacionariedade também pode ser avaliada pela função de autocorrelação (FAC) das séries trimestral e mensal, respectivamente, apresentadas na Fig. 7.3 e a Fig. 7.4, com um número de defasagens equivalente a $1/4$ das observações totais. Conforme verificado graficamente, é possível observar um decaimento lento no valor das autocorrelações após o aumento do número de defasagens de ambas as séries em nível. As autocorrelações das séries trimestral e mensal, mesmo após as defasagens 19 e 57 ainda apresentam valores significativos ao nível de significância de 5%, ou seja, fora dos limites de confiança de 95%. Sendo assim, pode-se dizer que essa é uma evidente característica de uma série temporal não estacionária.




Figura 7.3: Função de autocorrelação (FAC) da série temporal trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.




Figura 7.4: Função de autocorrelação (FAC) da série temporal mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Após a análise da estacionariedade pelos gráficos das séries temporais trimestral e mensal em nível e pela FAC das respectivas séries, a estacionariedade também foi avaliada pelos testes de raiz unitária Dickey-Fuller aumentado (ADF) e pelo teste Kwiatkowski–Phillips–Schmidt–Shin (KPSS).

O teste ADF para a série trimestral em nível foi realizado considerando um modelo de regressão sem constante, um modelo com constante e um modelo com constante e tendência, com um número máximo de 11 defasagens. O número de ideal de defasagens para essas regressões foi obtido com 3 defasagens de acordo com o BIC.

O modelo sem constante apresentou p-valor= 0,9960, mostrando que não há evidências de estacionariedade da série trimestral em nível. O modelo com constante apresentou p-valor= 0,8912 demonstrando as mesmas conclusões quanto à estacionariedade do modelo sem constante e ainda não apresentou constante significativa (p-valor= 0,30627). E o modelo com constante e tendência apresentou resultado significativo tanto para a constante quanto para a tendência, p-valor< 0,0001, e o resultado do teste apresentou p-valor< 0,0001.

Portanto, esse modelo se caracteriza como estacionário em torno de uma tendência, e assim torna-se necessário extrair essa tendência para tornar o processo estacionário. Para retirar essa tendência da série trimestral foi realizada a primeira diferença dos dados, transformando a série integrada de ordem zero, $I(0)$, em integranda de ordem 1, $I(1)$, conforme a Fig. 7.5.




Figura 7.5: Série temporal trimestral em primeira diferença dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014

Os mesmos procedimentos realizados para a série em nível foram realizados para a série em primeira diferença, porém considerando 2 defasagens de acordo com o BIC. O modelo para a série trimestral em primeira diferença sem constante apresentou p-valor< 0,0001, o modelo com constante apresentou p-valor< 0,0001 e constante significativa (p= 0,0131), e o modelo com constante e tendência apresentou p-valor< 0,0001, dessa vez livre de tendência

(p-valor= 0,9288). Sendo assim, pode-se concluir que, ao nível de significância de 5%, há evidências de que a série trimestral, integrada de ordem 1, seja estacionária.

O teste KPSS da série trimestral em nível com 2 defasagens, considerando um modelo com tendência apresentou p-valor < 0,01, demonstrando que não há evidências de estacionariedade. Para a série trimestral $I(1)$, esse teste apresentou p-valor=0,1, mostrando que há evidências de que a série seja estacionária após a primeira diferença. Esse resultado corrobora com o que foi evidenciado pelo teste ADF.

O teste ADF para a série mensal em nível foi realizado considerando um modelo de regressão sem constante, um modelo com constante e um modelo com constante e tendência, com um número máximo de 15 defasagens. O número de ideal de defasagens para essas regressões foi obtido com 6 defasagens de acordo com o BIC.

O modelo sem constante apresentou p-valor= 0,9175, demonstrando que não há evidências de estacionariedade da série mensal em nível. O modelo com constante teve p-valor= 0,7547, demonstrando as mesmas conclusões em relação ao modelo sem constante, e ainda não apresentou constante significativa (p-valor= 0,2115). E o modelo com constante e tendência apresentou resultado significativo tanto para a constante quanto para a tendência (p-valor < 0,0001) e o resultado do teste apresentou p-valor < 0,0001.

Portanto, o modelo gerado pela série mensal também se caracteriza como estacionário em torno de uma tendência. Assim, também foi necessário extrair essa tendência para tornar o processo estacionário. Para retirar essa tendência da série mensal foi realizada a primeira diferença dos dados, transformando a série integrada de ordem zero, $I(0)$, em integrada de ordem 1, $I(1)$, conforme a Fig. 7.6.




Figura 7.6: Série temporal mensal em primeira diferença dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Realizou-se os mesmos procedimentos da série em nível, porém com 5 defasagens sele-

cionadas pelo BIC. O modelo da série em primeira diferença sem constante apresentou p-valor $< 0,0001$; o modelo da série trimestral em primeira diferença com constante apresentou p-valor $< 0,0001$ e constante não significativa ($p = 0,2105$); e o modelo da série mensal, em primeira diferença, com constante e tendência apresentou p-valor $< 0,0001$, dessa vez livre de tendência ($p\text{-valor} = 0,8076$). Sendo assim, pode-se dizer que, ao nível de significância de 5%, há evidências de que a série mensal, integrada de ordem 1, seja estacionária.

O teste KPSS da série mensal em nível com 3 defasagens, considerando um modelo com tendência apresentou p-valor $< 0,01$, demonstrando que não há evidências de estacionariedade. Para a série mensal $I(1)$, esse teste apresentou p-valor $= 0,1$, demonstrando que há evidências de que a série seja estacionária após a primeira diferença. Esse resultado também corrobora com o que foi evidenciado pelo teste ADF.

7.3 Identificação e estimação de modelos ARIMA

Após a análise da estacionariedade das séries trimestral e mensal, na qual foi identificado que ambas séries temporais são Integradas de ordem 1, realizou-se o ajuste de modelos $ARIMA(p,1,q)$. Inicialmente, a escolha das possíveis ordens p e q do modelo ARIMA para essas séries foi baseada na análise da FAC e FACP.

A FAC e a FACP da série trimestral em primeira diferença (Fig. 7.7) possuem, respectivamente, 1 e 3 defasagens significativas ao nível de significância de 5%. Essa característica indica que o possível modelo de melhor ajuste para a série trimestral em primeira diferença é o $ARIMA(3,1,1)$. A FAC e a FACP da série mensal em primeira diferença (Fig. 7.8) possuem, respectivamente, 1 e 5 defasagens significativas ao nível de significância de 5%. Essa característica indica que o possível modelo de melhor ajuste para a série mensal em primeira diferença é o $ARIMA(0,1,1)$.




Figura 7.7: Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) da série trimestral em primeira diferença dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.




Figura 7.8: Função de autocorrelação (FAC) e Função de autocorrelação parcial (FACP) da Série temporal mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Foram estimados diversos modelos $ARIMA(p,1,q)$, baseando-se na função autoarima do R, para as séries trimestral e mensal, com diferentes ordens p e q , com e sem a presença de constante. Além de identificar os modelos que obtiveram bons ajustes, também foi avaliada a parcimônia pelos critérios de informação AIC, AICc e BIC.

Os modelos estimados para a série trimestral em primeira diferença e seus respectivos critérios de informação podem ser visualizados na Tab. 7.1.

Tabela 7.1: Critérios de informação dos modelos estimados para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Modelos Estimados	Significativo ($\alpha = 5\%$)	AIC	AICc	BIC
ARIMA(0,1,1)	Sim	620,1247	620,2914	624,7597
ARIMA(0,1,2)	Não	622,1007	622,4387	629,0532
ARIMA(0,1,3)	Não	619,7407	620,3121	629,0106
ARIMA(1,1,1)	Não	622,1113	622,4493	629,0638
ARIMA(1,1,3)	Não	619,6289	620,4985	631,2163
ARIMA(2,1,0) com constante	Não	618,5471	619,1185	627,8170
ARIMA(2,1,1)	Não	621,8461	622,4176	631,1161
ARIMA(2,1,2)	Sim	618,9927	619,8622	630,5801
ARIMA(2,1,3)	Não	620,9634	622,1987	634,8684
ARIMA(3,1,0)	Sim	621,1692	621,7407	630,4392
ARIMA(3,1,0) com constante	Sim	609,0771	609,9466	620,6645
ARIMA(3,1,1)	Não	621,5534	622,4230	633,1408
ARIMA(3,1,2)	Não	620,9507	622,1860	634,8556
ARIMA(4,1,0)	Não	621,1738	622,0433	632,7612
ARIMA(4,1,0) com constante	Sim	605,5597	606,7950	619,4647
ARIMA(5,1,0) com constante	Não	605,4387	607,1103	621,6611

Fonte: Elaborada pelo autor.

Dentre os 16 modelos descritos para a série trimestral, 11 não apresentaram todos os

parâmetros estimados significativos. Os demais modelos, os quais apresentaram todos os parâmetros estimados significativos, foram considerados candidatos a melhor ajuste, por isso estão descritos detalhadamente na Tab.7.2.

Tabela 7.2: Modelos estimados com bons ajustes para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

ARIMA(0,1,1)	Parâmetros Estimados	Erro Padrão	p-valor
$\hat{\theta}_1$	-0,6606	0,0692	<0,0001
ARIMA(2,1,2)	Parâmetros Estimados	Erro Padrão	p-valor
$\hat{\phi}_1$	0,7039	0,1997	0,0017
$\hat{\phi}_2$	-0,3034	0,1562	0,0451
$\hat{\theta}_1$	-1,4473	0,1734	<0,0001
$\hat{\theta}_2$	0,7106	0,1436	<0,0001
ARIMA(3,1,0)	Parâmetros Estimados	Erro Padrão	p-valor
$\hat{\phi}_1$	-0,6535	0,1093	<0,0001
$\hat{\phi}_2$	-0,5116	0,1183	<0,0001
$\hat{\phi}_3$	-0,3237	0,1089	0,0034
ARIMA(3,1,0) com constante	Parâmetros Estimados	Erro Padrão	p-valor
constante	1,5700	0,6091	0,0094
$\hat{\phi}_1$	-0,7092	0,1079	<0,0001
$\hat{\phi}_2$	-0,5785	0,1172	<0,0001
$\hat{\phi}_3$	-0,3816	0,1075	0,0004
ARIMA(4,1,0) com constante	Parâmetros Estimados	Erro Padrão	p-valor
constante	1,6014	0,4625	0,0005
$\hat{\phi}_1$	-0,8150	0,1127	<0,0001
$\hat{\phi}_2$	-0,7382	0,1312	<0,0001
$\hat{\phi}_3$	-0,5759	0,1308	<0,0001
$\hat{\phi}_4$	-0,2686	0,1117	0,0162

Fonte: Elaborada pelo autor.

Considerando todos os 16 modelos estimados para a série trimestral, constatou-se que o único modelo ARIMA(0,1,q) que apresentou todos os parâmetros significativos foi o ARIMA(0,1,1). Quanto aos modelos ARIMA com ordens p e q diferentes de zero, o único que apresentou todos os parâmetros significativos foi o ARIMA (2,1,2). E quanto aos modelos ARIMA(p,1,0), apenas os com ordem maiores ou iguais a três apresentaram todos os parâmetros significativos.

No geral, o modelo de menor AICc e BIC para a série trimestral foi o ARIMA(4,1,0) com constante. Pelo AIC, o resultado foi um pouco diferente, o modelo de menor AIC foi o ARIMA(5,1,0) com constante, seguido do ARIMA (4,1,0) com constante. Apesar disso, ambos os modelos apresentaram valores bastante próximos, respectivamente, 605,4387 e 605,5597. Ainda assim, o modelo ARIMA(5,1,0) com constante foi desconsiderado pois não apresentou todos os parâmetros estimados significativos, por isso o modelo ARIMA(4,1,0) com constante foi considerado o mais parcimonioso também pelo AIC, assim como já havia sido obtido pelo AICc e BIC.

Os modelos estimados para a série mensal em primeira diferença e seus respectivos critérios de informação podem ser visualizados na Tab. 7.3.

Tabela 7.3: Critérios de informação dos modelos estimados para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Modelos Estimados	Significativo ($\alpha = 5\%$)	AIC	AICc	BIC
ARIMA(0,1,1)	Sim	1595,9380	1595,9910	1602,7870
ARIMA(0,1,2)	Não	1597,7280	1597,8360	1608,0030
ARIMA(0,1,3)	Não	1599,3980	1599,5780	1613,0980
ARIMA(0,1,4)	Não	1601,3100	1601,5820	1618,4350
ARIMA(0,1,5)	Não	1600,4130	1600,7950	1620,9630
ARIMA(1,1,0)	Sim	1657,9260	1657,9790	1664,7760
ARIMA(1,1,0) com constante	Não	1652,4340	1652,5420	1662,7090
ARIMA(1,1,1)	Não	1597,7120	1597,8200	1607,9870
ARIMA(2,1,0)	Sim	1637,8910	1637,9980	1648,1650
ARIMA(2,1,0) com constante	Não	1632,6290	1632,8090	1646,0640
ARIMA(2,1,1)	Não	1599,4440	1599,6250	1613,1440
ARIMA(3,1,0)	Sim	1632,6290	1632,8090	1646,3290
ARIMA(3,1,0) com constante	Não	1627,0040	1627,2750	1644,1280
ARIMA(3,1,1)	Não	1601,3820	1601,6530	1618,5070
ARIMA(4,1,0)	Sim	1626,6910	1626,9620	1643,8160
ARIMA(4,1,0) com constante	Não	1620,9040	1621,2860	1641,4540
ARIMA(4,1,1)	Não	1601,4810	1601,8630	1622,0310
ARIMA(5,1,0)	Sim	1623,2650	1623,6470	1643,8150
ARIMA(5,1,0) com constante	Não	1617,2480	1617,7600	1641,2230

Fonte: Elaborada pelo autor.

Dentre os 19 modelos descritos para a série mensal, 13 não apresentaram todos os parâmetros estimados significativos. Os demais modelos apresentaram todos os parâmetros estimados significativos e foram considerados candidatos a melhor ajuste, por isso estão descritos detalhadamente na Tab. 7.4.

Considerando todos os 19 modelos estimados para a série mensal, constatou-se que o único modelo ARIMA(0,1, q) que apresentou todos os parâmetros significativos também foi o ARIMA(0,1,1). Não houveram modelos ARIMA com ordens p e q diferentes de zero que apresentaram todos os parâmetros significativos. Quanto aos modelos ARIMA(p ,1,0), apenas os com ordem maiores ou iguais a dois e sem constante apresentaram todos os parâmetros significativos.

Constatou-se pela análise dos critérios de informação dos modelos estimados para a série mensal, que o modelo de menor AIC, AICc e BIC foi o ARIMA(0,1,1). Não houve divergência no resultado obtido pelos critérios, por isso o modelo ARIMA(0,1,1) foi considerado o mais parcimonioso por todos os critérios.

Tabela 7.4: Modelos estimados com bons ajustes para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

ARIMA(0,1,1)	Parâmetros Estimados	Erro Padrão	P-Valor
$\hat{\theta}_1$	-0,8821	0,0250	<0,0001
ARIMA(1,1,0)	Parâmetros Estimados	Erro Padrão	P-Valor
$\hat{\phi}_1$	-0,5287	0,0567	<0,0001
ARIMA(2,1,0)	Parâmetros Estimados	Erro Padrão	P-Valor
$\hat{\phi}_1$	-0,6881	0,0634	<0,0001
$\hat{\phi}_2$	-0,3069	0,0637	<0,0001
ARIMA(3,1,0)	Parâmetros Estimados	Erro Padrão	P-Valor
$\hat{\phi}_1$	-0,7429	0,0656	<0,0001
$\hat{\phi}_2$	-0,4279	0,0769	<0,0001
$\hat{\phi}_3$	-0,1789	0,0658	<0,0001
ARIMA(4,1,0)	Parâmetros Estimados	Erro Padrão	P-Valor
$\hat{\phi}_1$	-0,7760	0,0655	<0,0001
$\hat{\phi}_2$	-0,5081	0,0807	<0,0001
$\hat{\phi}_3$	-0,3151	0,0804	<0,0001
$\hat{\phi}_4$	-0,1865	0,0656	0,0044
ARIMA(5,1,0)	Parâmetros Estimados	Erro Padrão	P-Valor
$\hat{\phi}_1$	-0,8046	0,0658	<0,0001
$\hat{\phi}_2$	-0,5564	0,0824	<0,0001
$\hat{\phi}_3$	-0,3940	0,0863	<0,0001
$\hat{\phi}_4$	-0,3044	0,0820	0,0002
$\hat{\phi}_5$	-0,1545	0,0659	0,0192

Fonte: Elaborada pelo autor.

7.4 Análise de diagnóstico dos resíduos dos modelos ARIMA

Realizou-se a análise de diagnóstico dos resíduos gerados a partir do modelo ARIMA(4,1,0) com constante para a série com periodicidade trimestral e do modelo ARIMA(0,1,1) para a série com periodicidade mensal.

Graficamente, os resíduos do modelo da série trimestral (Fig. 7.9) aparentam distribuir-se ao longo do tempo de forma aleatória e com variabilidade constante, assim como o comportamento dos resíduos do modelo da série mensal (Fig. 7.10). A FAC e a FACP dos resíduos do modelo da série trimestral (Fig. 7.11) evidenciam a ausência de autocorrelação ao longo do tempo, já que estes se encontram dentro dos intervalos de confiança. Contudo, esta ausência de autocorrelação não fica evidente na FAC e na FACP dos resíduos do modelo da série mensal (Fig. 7.12).

Para se ter uma avaliação mais clara se os resíduos dos modelos ajustados são *i.i.d.*, utilizou-se o teste Q' de Ljung-Box. O resultado obtido a partir deste teste apresentou, respectivamente, p-valor igual a 0,7613 e 0,1017, indicando que, ao nível de significância de 5%, não há evidências para rejeitar a hipótese de que os resíduos gerados por ambos os modelos ajustados se comportam de forma *i.i.d.* E, como os resíduos desses modelos são *i.i.d.*, pode-se então dizer que a

autocorrelação não está presente nas variações que os modelos estimados não foram capazes de explicar, sendo assim, estes modelos apresentam bons ajustes.

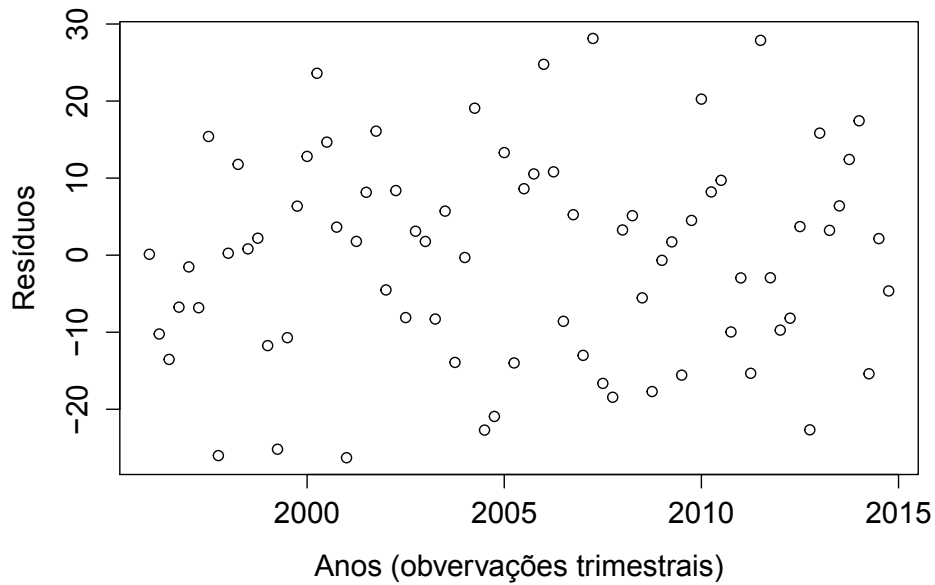


Figura 7.9: Resíduos do modelo ARIMA(4,1,0) com constante da Série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

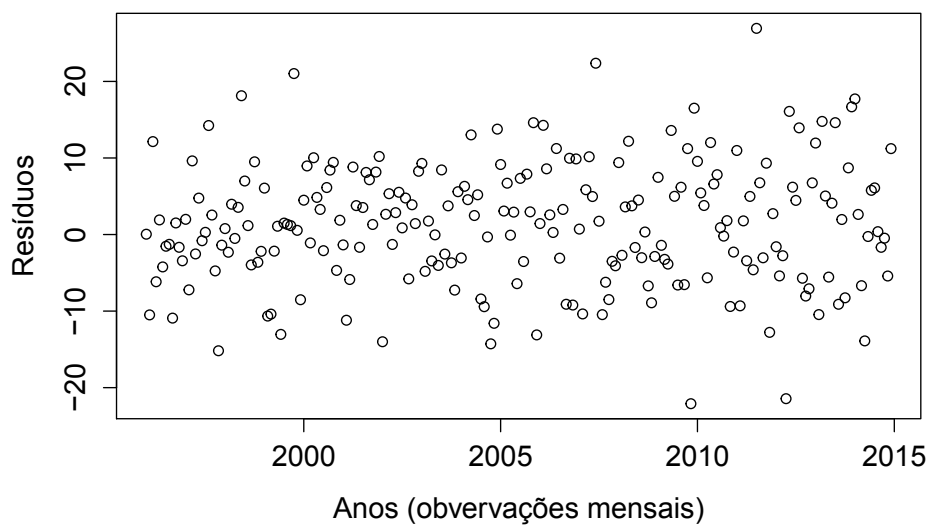


Figura 7.10: Resíduos do modelo ARIMA(0,1,1) da Série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.




Figura 7.11: Função de autocorrelação(FAC) e função de autocorrelação parcial(FACP) dos resíduos do modelo ARIMA(4,1,0) com constante da Série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.




Figura 7.12: Função de autocorrelação(FAC) e função de autocorrelação parcial(FACP) resíduos do modelo ARIMA(0,1,1) da Série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Quanto ao pressuposto de normalidade, os resíduos dos modelos estimados para as séries trimestral e mensal apresentaram, respectivamente, p-valor igual a 0,5617 e 0,7705, pelo teste de Bera-Jarque. Logo, não foram encontradas evidências para rejeitar a hipótese de que os resíduos

desses modelos sejam normalmente distribuídos, ao nível de significância de 5%. Esse resultado também pode ser visualizado pelo gráfico dos Quantis teóricos *versus* Quantis observados (Q-Q) com envelopes de confiança simulados, conforme as Figs. 7.13 e 7.14, as quais apresentam os resíduos dentro dos envelopes de confiança, bem como distribuídos em torno da linha vermelha, caracterizada pelo que seria considerado um bom ajuste a distribuição normal.




Figura 7.13: Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo ARIMA(4,1,0) com constante da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.




Figura 7.14: Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo ARIMA(0,1,1) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Como todos os pressupostos da análise de diagnóstico dos resíduos foram atendidos, conclui-se que tanto o modelo estimado para a série trimestral, quanto o modelo estimado para a série mensal possuem boa adequação para as séries analisadas.

7.5 Qualidade dos ajustes e das previsões obtidas pelos modelos ARIMA

A última etapa da metodologia de Box-Jenkins consiste em obter previsões acerca dos modelos ARIMA estimados e avaliar a qualidade dos ajustes e das previsões a partir de medidas de precisão ou acurácia.

Na Figura 7.15 estão apresentados graficamente o ajuste do modelo estimado e os valores reais da série trimestral de óbitos por neoplasias malignas de pele ocorridos na região Sul, entre 1996 e 2014. Nessa figura é possível observar que o modelo ARIMA(4,1,0) com constante, mesmo tendo sido aquele que apresentou melhores estimativas, ainda assim não foi capaz de captar as variações ocorridas em trimestres com maiores oscilações.




Figura 7.15: Gráfico do ajuste do modelo ARIMA(4,1,0) com constante e dos valores reais da série trimestral e óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.

A análise da precisão do modelo ajustado para a série trimestral apresentou um MAPE igual a 7,13%, RMSE igual a 13,15 e MPE igual a $-1,02\%$. De modo geral, mesmo que a análise gráfica tenha demonstrado que o modelo ajustado não captou as grandes oscilações da série, o modelo apresentou um MAPE relativamente baixo, assim como um RMSE abaixo de 15 óbitos.

Já o MPE, por ter apresentado resultado negativo, indicou que o modelo ARIMA(4,1,0) com constante resultou em uma superestimação média, mesmo que essa não tenha sido alta.

Na Figura 7.16 estão apresentados graficamente o ajuste do modelo estimado e os valores reais da série mensal de óbitos por neoplasias malignas de pele ocorridos na região Sul, entre 1996 e 2014. É possível observar que o modelo ARIMA(0,1,1), mesmo tendo sido aquele que apresentou melhores estimativas, ainda assim não foi capaz de captar as variações ocorridas nos meses com maiores oscilações. Quando comparado ao modelo da série de óbitos em periodicidades trimestrais, percebe-se que esse, visualmente, capta ainda menos a variabilidade ocorrida nos dados.

Quanto a análise da precisão, o modelo ajustado para a série mensal apresentou um MAPE igual a 12,33%, RMSE igual a 8,02 e MPE igual a 0,1978%. De modo geral, a análise gráfica desse modelo já havia demonstrado um ajuste inferior ao da série trimestral, essa observação ficou ainda mais evidente ao verificar o MAPE, o qual em valor absoluto foi 5,2% superior ao MAPE do ajuste da série trimestral. O RMSE também apresentou um valor relativamente alto, visto que a série mensal particiona os dados em um número de observações três vezes maior que a trimestral. Já o MPE, ao contrário do modelo ajustado para a série trimestral, apresentou resultado positivo indicando uma leve subestimação média.

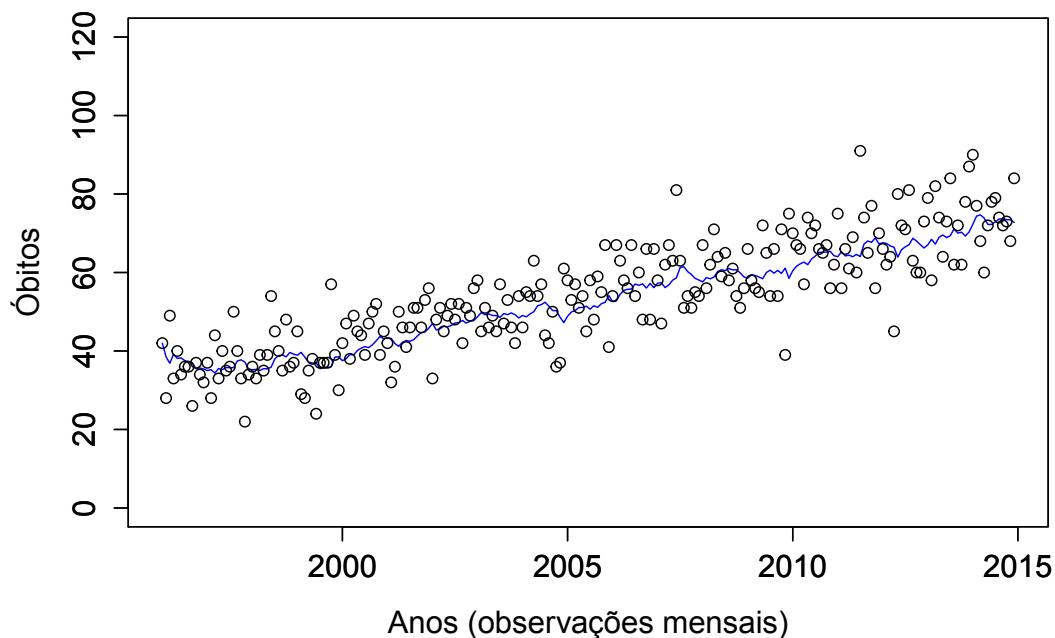


Figura 7.16: Gráfico do ajuste do modelo ARIMA(0,1,1) e dos valores reais da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.

Na Tabela 7.5 é possível observar as previsões obtidas a partir do modelo ARIMA(4,1,0) com constante e os respectivos intervalos de confiança dessas previsões. Também é possível

observar os valores reais para os quatro trimestres de 2015 afim de compará-los com os valores previstos e avaliar a qualidade dessas previsões.

Conforme o que é mostrado na Tab. 7.5, é possível observar que os óbitos ocorridos nos trimestres de 2015 se encontram próximos aos valores previstos e os intervalos de confiança dessas previsões contém as verdadeiras quantidades de óbitos por neoplasias malignas de pele ocorridas na Região Sul. Assim, é possível dizer que o modelo ARIMA(4,1,0) com constante foi validado e pode ser utilizado na obtenção de previsões para outros períodos futuros.

No que se refere a qualidade ou precisão das previsões obtidas para os quatro trimestres de 2015, observou-se um MAPE igual a 4,94%, RMSE igual a 15,33, MPE igual a 10,30% e U de Theil igual a 0,77. Diante disso, diz-se o resultado dessas medidas demonstram a boa qualidade das previsões obtidas pelo modelo ARIMA (4,1,0) com constante.

Tabela 7.5: Previsões para os trimestres de 2015 obtidas a partir do modelo ARIMA(4,1,0) com contante estimado para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Períodos	Óbitos reais	Óbitos previstos	Intervalos de confiança 95%
1º trimestre	213	231,6174	[204,7569; 258,4779]
2º trimestre	229	229,7422	[202,4261; 257,0582]
3º trimestre	252	227,7973	[200,3187; 255,2758]
4º trimestre	235	232,3967	[204,4132; 260,3801]

Fonte: Elaborada pelo autor

De acordo com a Tab. 7.6, é possível observar que os óbitos ocorridos nos meses de janeiro, março, abril, maio e junho de 2015 se encontram próximos aos valores previstos, assim como os intervalos de confiança das previsões para esses períodos contém as verdadeiras quantidades de óbitos por neoplasias malignas de pele ocorridas na Região Sul. Vale salientar que a previsão para o mês de fevereiro ficou muito acima do valor real, o resíduo para esse período gerou um erro percentual de 48,20% e, conseqüentemente, como é possível observar, o intervalo de confiança dessa previsão não conteve o verdadeiro valor observado. Diante disso, como o número de óbitos ocorridos em fevereiro de 2015 ficou muito abaixo em comparação com os demais meses, é possível que esse período se trate de um possível *outlier*, ou seja, um valor atípico.

Tabela 7.6: Previsões para os seis meses de 2015 obtidas a partir do modelo ARIMA(0,1,1) estimado para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Períodos	Óbitos reais	Óbitos previstos	Intervalos de confiança 95%
1º mês	75	74,10126	[58,31171; 89,89082]
2º mês	50	74,10126	[58,20241; 90,00012]
3º mês	67	74,10126	[58,09385; 90,10868]
4º mês	66	74,10126	[57,98603; 90,21650]
5º mês	66	74,10126	[57,87892; 90,32361]
6º mês	64	74,10126	[57,77252; 90,43001]

Fonte: Elaborada pelo autor

Quanto a qualidade ou precisão das previsões obtidas para os seis meses de 2015, observou-se um MAPE igual a 16,72%, RMSE igual a 12,01, MPE igual a -16,32% e U de Theil igual a 0,69. Ainda que o contexto dessas medidas para as seis previsões não tenham apresentado bons resultados, se desconsiderado o mês de fevereiro os valores do MAPE, RMSE e MPE seriam reduzidos, respectivamente, para 10,43%, 7,54 e -9,95%. Ainda assim, mesmo que o modelo ARIMA(0,1,1) tenha sido o que apresentou melhor ajuste para a série mensal, comparado à trimestral esse apresentou uma redução na qualidade das previsões.

Em um contexto geral, o modelo ARIMA se mostrou mais adequado para estimar e prever a série de óbitos por neoplasias malignas de pele ocorridos na Região Sul agregada em periodicidades trimestrais comparado à mensais. As melhores estimativas foram obtidas pelo modelo agregado em períodos trimestrais, pois as agregações dos meses em trimestres proporcionou uma redução na variabilidade da série.

7.6 Identificação e estimação de modelos GARMA

Após a realização de todas as análises relacionadas aos modelos ARIMA, foram identificados e estimados os modelos GARMA com distribuição condicional Poisson e BN para as séries trimestral e mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul entre 1996 e 2014.

Estimou-se diversos modelos GARMA-Poisson e GARMA-BN com diferentes ordens p e q para a série trimestral. Desses, os que apresentaram bons ajustes estão descritos, respectivamente, na Tab. 7.7 e na Tab. 7.8.

Tabela 7.7: Modelo GARMA-Poisson estimado com bom ajuste para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014

GARMA-Poisson (1,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	5,24592	0,07787	<0,0001
$\hat{\phi}_1$	0,88344	0,03874	<0,0001
GARMA-Poisson (2,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	5,11398	0,4636	<0,0001
$\hat{\phi}_1$	0,56491	0,08378	<0,0001
$\hat{\phi}_2$	0,35719	0,08413	<0,0001

Fonte: Elaborada pelo autor.

Entre os modelos GARMA com distribuição condicional Poisson com bons ajustes para a série trimestral, o GARMA-Poisson (1,0) apresentou AIC igual a 643,273, AICc igual a 643,606 e BIC igual a 650,346, e o GARMA-Poisson (2,0) apresentou AIC igual a 632,309, AICc igual a 632,640 e BIC igual a 641,283. Diante disso, o GARMA-Poisson (2,0) foi escolhido como o mais parcimonioso para a série trimestral, pois apresentou os menores valores dos critérios de informação.

Tabela 7.8: Modelos GARMA-Binomial Negativa (BN) estimados com bons ajustes para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

GARMA-BN(1,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	5,187829	0,1240	<0,0001
$\hat{\phi}_1$	0,890684	0,0250	<0,0001
GARMA-BN(2,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	5,292245	0,1977	<0,0001
$\hat{\phi}_1$	0,57228019	0,1050	<0,0001
$\hat{\phi}_2$	0,34924785	0,1052	<0,0001

Fonte: Elaborada pelo autor.

Entre os modelos com distribuição condicional BN com bons ajustes para a série trimestral, o GARMA-BN (1,0) apresentou AIC igual a 645,193, AICc igual a 645,476 e BIC igual a 652,186, e o GARMA-BN (2,0) apresentou AIC igual a 634,109, AICc igual a 634,672 e BIC igual a 643,432. Diante disso, o GARMA-BN (2,0) foi escolhido como o modelo mais parcimonioso para a série trimestral pois apresentou os menores valores dos critérios de informação.

Estimou-se também diversos modelos GARMA-Poisson e GARMA-BN com diferentes ordens p e q para a série mensal. Desses, os que apresentaram bons ajustes estão descritos, respectivamente, na Tab. 7.9 e na Tab. 7.10.

Tabela 7.9: Modelos GARMA-Poisson estimados com bons ajustes para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014

GARMA-Poisson (1,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	6,20971	0,03013	<0,0001
$\hat{\phi}_1$	0,70033	0,03378	<0,0001
GARMA-Poisson (2,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	6,29503	0,04327	<0,0001
$\hat{\phi}_1$	0,39020	0,04781	<0,0001
$\hat{\phi}_2$	0,43134	0,04777	<0,0001
GARMA-Poisson (3,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	4,10572	0,09064	<0,0001
$\hat{\phi}_1$	0,27684	0,05382	<0,0001
$\hat{\phi}_2$	0,31385	0,05242	<0,0001
$\hat{\phi}_3$	0,28493	0,05302	<0,0001
GARMA-Poisson (4,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	4,24143	0,06127	<0,0001
$\hat{\phi}_1$	0,23539	0,05586	<0,0001
$\hat{\phi}_2$	0,26149	0,05555	<0,0001
$\hat{\phi}_3$	0,24036	0,05463	<0,0001
$\hat{\phi}_4$	0,15197	0,05474	0,0055

Fonte: Elaborada pelo autor.

Tabela 7.10: Modelos GARMA-Binomial Negativa (BN) estimados com bons ajustes para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

GARMA-BN (1,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	4,0229	0,04187	<0,0001
$\hat{\phi}_1$	0,69686	0,04656	<0,0001
GARMA-BN (2,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	4,06817	0,06612	<0,0001
$\hat{\phi}_1$	0,38659	0,05791	<0,0001
$\hat{\phi}_2$	0,43616	0,05793	<0,0001
GARMA-BN (3,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	4,10997	0,09768	<0,0001
$\hat{\phi}_1$	0,27391	0,06252	<0,0001
$\hat{\phi}_2$	0,32019	0,06067	<0,0001
$\hat{\phi}_3$	0,28344	0,06192	<0,0001
GARMA-BN (4,0)	Parâmetros Estimados	Erro Padrão	p-valor
constante	4,14360235	0,11697	<0,0001
$\hat{\phi}_1$	0,23524	0,06466	<0,0001
$\hat{\phi}_2$	0,25886	0,06234	<0,0001
$\hat{\phi}_3$	0,24431	0,06333	<0,0001
$\hat{\phi}_4$	0,15351	0,06340	0,0055

Fonte: Elaborada pelo autor.

Entre os modelos GARMA com distribuição condicional Poisson com bons ajustes para a série mensal, o GARMA-Poisson (1,0) apresentou AIC igual a 1700,530, AICc igual a 1700,640 e BIC igual a 1712,233, o GARMA-Poisson (2,0) apresentou AIC igual a 1640,120, AICc igual a 1639,364 e BIC igual a 1654,100, o GARMA-Poisson (3,0) apresentou AIC igual a 1613,543, AICc igual a 1613,878 e BIC igual a 1627,095, e o GARMA-Poisson (4,0) apresentou AIC igual a 1602,913, AICc igual a 1603,431 e BIC igual a 1623,130. Diante disso, o GARMA-Poisson (4,0) foi escolhido como o melhor modelo para a série mensal pois apresentou os menores valores dos critérios de informação.

Entre os modelos GARMA com distribuição condicional BN com bons ajustes para a série mensal, o GARMA-BN (1,0) apresentou AIC igual a 1698,740, AICc igual a 1698,850 e BIC igual a 1709,030, o GARMA-BN (2,0) apresentou AIC igual a 1639,180, AICc igual a 1639,404 e BIC igual a 1652,900, o GARMA-BN (3,0) apresentou AIC igual a 1612,640, AICc igual a 1612,320 e BIC igual a 1625,750, e o GARMA-BN (4,0) apresentou AIC igual a 1602,130, AICc igual a 1602,634 e BIC igual a 1622,710. Diante disso, o GARMA-BN (4,0) foi escolhido como o melhor modelo para a série mensal pois apresentou os menores valores dos critérios de informação.

7.7 Análise de diagnóstico dos resíduos dos modelos GARMA

Realizou-se a análise de diagnóstico dos resíduos gerados a partir dos modelos GARMA-Poisson(2,0) e GARMA-BN(2,0) para a série com periodicidade trimestral e dos modelos GARMA-Poisson(4,0) e GARMA-BN(4,0) para a série com periodicidade mensal.

Observou-se que a FAC dos resíduos do modelo GARMA-Poisson (2,0) da série trimestral (Fig. 7.17) apresentou a primeira defasagem fora dos limites de confiança. De todo modo, essa defasagem não apresentou autocorrelação muito alta. Ainda assim, não fica evidente se há ou não ausência de autocorrelação nos resíduos ao longo do tempo.




Figura 7.17: Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Poisson (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Para melhores conclusões quanto a ausência de autocorrelação, realizou-se o teste Q' de Ljung-Box, o qual apresentou $p\text{-valor}=0,5395$, indicando que, ao nível de significância de 5%, não há evidências para rejeitar a hipótese que os resíduos sejam *iid*. Logo, não há autocorrelação nos resíduos dos modelo GARMA-Poisson (2,0).

Quanto à normalidade dos resíduos do modelo GARMA-Poisson (2,0) da série trimestral, foi obtido um $p\text{-valor}=0,8295$, pelo teste Jarque-Bera, demonstrando que não há evidências para rejeitar a hipótese de normalidade. Visualmente, o ajuste a uma distribuição Normal, com envelopes de confiança de 95%, pode ser observado na Fig. 7.18.




Figura 7.18: Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Poisson (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Observou-se também que a FAC dos resíduos do modelo GARMA-BN (2,0) da série trimestral (Fig. 7.19) apresentou a primeira defasagens fora dos limites de confiança, de todo modo, essa defasagem não apresentou autocorrelação muito alta, e comparado ao GARMA-Poisson (2,0) foi um pouco menor. Nesse caso, também não fica evidente se há ou não ausência de autocorrelação nos resíduos ao longo do tempo. Por isso realizou-se o teste Q' de Ljung-Box, o qual apresentou p-valor=0,4836, indicando que, ao nível de significância de 5%, não há evidências para rejeitar a hipótese que os resíduos sejam *iid*. Logo, também não há autocorrelação nos resíduos dos modelo GARMA-BN (2,0).




Figura 7.19: Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Binomial Negativa (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Quanto à normalidade dos resíduos do modelo GARMA-BN (2,0) da série trimestral, foi obtido um p-valor=0,7993, pelo teste Jarque-Bera, demonstrando que não há evidências para rejeitar a hipótese de normalidade. Visualmente, o ajuste a uma distribuição Normal, com envelopes de confiança de 95%, pode ser observado na Fig. 7.20.

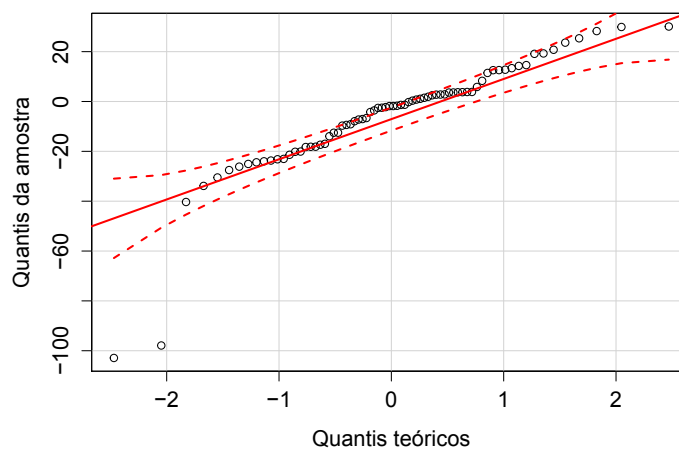


Figura 7.20: Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Binomial Negativa (2,0) da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Na Fig. 7.21 pode-se observar que a FAC dos resíduos do modelo GARMA-Poisson (4,0) da série mensal apresentou baixas autocorrelações e, de modo geral, essas se encontram dentro dos limites de confiança. O teste Q' de Ljung-Box apresentou p-valor=0,1022, indicando que, não há evidências para rejeitar a hipótese que os resíduos sejam *iid*. Logo, não há autocorrelação nos resíduos dos modelo GARMA-Poisson (4,0).




Figura 7.21: Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Poisson(4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Quanto à normalidade dos resíduos do modelo GARMA-Poisson (4,0) para a série mensal, foi obtido um p-valor=0,8292, pelo teste Jarque-Bera, demonstrando que não há evidências para rejeitar a hipótese de normalidade. Visualmente, o ajuste a uma distribuição Normal, com envelopes de confiança de 95%, pode ser observado na Fig. 7.22.




Figura 7.22: Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Poisson (4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Na Fig. 7.23 pode-se observar que a FAC dos resíduos do modelo GARMA-BN (4,0) da série mensal apresentou baixas autocorrelações e, de modo geral, essas se encontram dentro dos limites de confiança. O teste Q' de Ljung-Box apresentou p-valor=0,2673, indicando que, não há evidências para rejeitar a hipótese que os resíduos sejam *iid*. Logo, também não há autocorrelação nos resíduos dos modelo GARMA-Poisson (4,0).




Figura 7.23: Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) dos resíduos do modelo GARMA Binomial Negativa(4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Quanto à normalidade dos resíduos do modelo GARMA-BN (4,0) para a série mensal, foi obtido um p-valor=0,8305, pelo teste Jarque-Bera, demonstrando também que não há evidências para rejeitar a hipótese de normalidade. Visualmente, o ajuste a uma distribuição Normal, com envelopes de confiança de 95%, pode ser observado na Fig. 7.24.




Figura 7.24: Q-Q Normal com envelopes de confiança simulados para os resíduos do modelo GARMA Binomial Negativa (4,0) da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil entre 1996 e 2014.

Como todos os pressupostos da análise de diagnóstico dos resíduos foram atendidos, conclui-se que tanto o modelos GARMA estimados para a série trimestral, quanto o modelo GARMA estimados para a série mensal possuem boa adequação para as séries analisadas.

7.8 Qualidade dos ajustes e previsões obtidas pelos modelos GARMA

A última etapa consiste em obter previsões acerca dos modelos GARMA estimados e avaliar a qualidade dos ajustes e das previsões a partir de medidas de precisão ou acurácia.

Nas Figuras 7.25 e 7.26 estão apresentados, respectivamente, os gráficos dos ajustes dos modelos estimados GARMA-Poisson (2,0) e GARMA-BN (2,0), assim como os valores reais da série trimestral de óbitos por neoplasias malignas de pele ocorridos na Região Sul, entre 1996 e 2014. Quanto à comparação desses modelos para a série com periodicidades trimestrais, é possível observar que o GARMA-Poisson (2,0) aparentemente encontra-se melhor ajustado que o GARMA-BN (2,0).




Figura 7.25: Gráfico do ajuste do modelo GARMA-Poisson (2,0) e dos valores reais da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.

Quanto à qualidade da precisão, os modelos GARMA-Poisson (2,0) e GARMA-BN (2,0) ajustados para a série trimestral, apresentaram respectivamente, um MAPE igual a 3,53% e 3,78%, RMSE igual a 11,23 e 11,35 e MPE igual a -0,09% e -0,12%. Ambos os modelos apresentaram MAPE's relativamente baixos, assim como os RMSE's, e subestimação praticamente nula. O GARMA-Poisson (2,0) apresentou levemente melhores resultados, apesar disso foram bastante próximos.

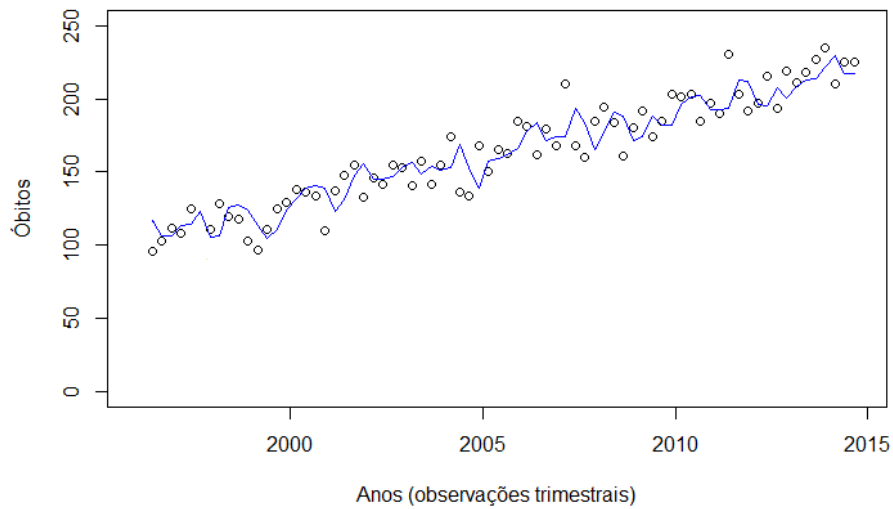


Figura 7.26: Gráfico do ajuste do modelo GARMA-BN (2,0) e dos valores reais da série trimestral dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.

Nas Figuras 7.27 e 7.28 estão apresentados, respectivamente, os gráficos dos ajustes dos modelos estimados GARMA-Poisson (4,0) e GARMA-BN (4,0), assim como os valores reais da série mensal de óbitos por neoplasias malignas de pele ocorridos na Região Sul, entre 1996 e 2014.




Figura 7.27: Gráfico do ajuste do modelo GARMA-Poisson (4,0) e dos valores reais da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.




Figura 7.28: Gráfico do ajuste do modelo GARMA-BN (4,0) e dos valores reais da série mensal dos óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014.

Quando à comparação desses modelos para a série com periodicidades mensais, é possível observar que o GARMA-BN (4,0) aparentemente encontra-se melhor ajustado que o GARMA-Poisson (4,0). Esse resultado vai de encontro ao que havia sido observado para a série com periodicidades trimestrais. Contudo, esse resultado se justifica pelo fato da série mensal apresentar maiores oscilações, assim o modelo com distribuição condicional BN consegue captar melhor essas variações devido as suas características.

Quanto à qualidade da precisão, os modelos GARMA-Poisson (4,0) e GARMA-BN (4,0) ajustados para a série mensal, apresentaram respectivamente, um MAPE igual a 6,23% e 5,78%, RMSE igual a 7,32 e 7,16 e MPE igual a 0,16% e 0,14%. Ambos os modelos também apresentaram MAPE's relativamente baixos, assim como os RMSE's, e superestimação praticamente nula. O GARMA-BN (4,0) apresentou levemente melhores resultados, apesar disso também foram bastante próximos.

Quanto à qualidade das previsões para os trimestres de 2015 utilizando o modelo GARMA-Poisson (2,0), apresentados na Tab. 7.11, observou-se que os óbitos ocorridos nos trimestres de 2015 se encontram próximos aos valores previstos, assim como os intervalos de confiança dessas previsões contém as verdadeiras quantidades de óbitos por neoplasias malignas de pele ocorridas na região Sul. O MAPE das previsões desse modelo foi de 4,41%, o RMSE foi de 13,22 e o MPE foi de 2,17%.

Quanto à qualidade das previsões para os trimestres de 2015 utilizando o modelo GARMA-BN (2,0), apresentados na Tab. 7.12, observou-se que os óbitos ocorridos nos trimestres de 2015 também se encontram próximos aos valores previstos, assim como os intervalos de confiança dessas previsões também contém as verdadeiras quantidades de óbitos por neoplasias malignas de pele ocorridas na Região Sul. O MAPE das previsões desse modelo foi de 3,73%, o RMSE foi de 13,33 e o MPE foi de 2,08%.

Tabela 7.11: Previsões para os trimestres de 2015 obtidas a partir do modelo GARMA-Poisson (2,0) estimado para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Períodos	Óbitos reais	Óbitos previstos	Intervalos de confiança 95%
1º trimestre	213	216,3721	[199,9389; 236,5624]
2º trimestre	229	226,9674	[208,3321; 247,0232]
3º trimestre	252	225,9387	[201,3870; 254,1182]
4º trimestre	235	237,2621	[207,4005; 257,1817]

Fonte: Elaborada pelo autor

Comparando as medidas de precisão dos modelos GARMA-Poisson (2,0) e GARMA-BN (2,0), foi observado que o GARMA-Poisson (2,0) apresentou um MAPE levemente menor, enquanto o RMSE e o MPE foram levemente maiores. Pode-se constatar que o modelo GARMA-Poisson (2,0) apresentou melhores resultados comparado ao modelo GARMA-BN (2,0). Ainda assim, os resultados da qualidade das previsões foram bastante próximos.

Tabela 7.12: Previsões para os trimestres de 2015 obtidas a partir do modelo GARMA-BN (2,0) estimado para a série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Períodos	Óbitos reais	Óbitos previstos	Intervalos de confiança 95%
1º trimestre	213	216,8302	[204,1563; 258,5379]
2º trimestre	229	227,3022	[202,4261; 253,0182]
3º trimestre	252	226,0003	[200,2115; 255,2588]
4º trimestre	235	238,4967	[208,0167; 261,4916]

Fonte: Elaborada pelo autor

Quanto à qualidade das previsões para os seis meses de 2015 utilizando o modelo GARMA-Poisson (4,0), apresentados na Tab. 7.13, com exceção das previsões para mês de fevereiro, observou-se que as previsões para os demais meses também se encontram próximos aos valores reais, e os intervalos de confiança dessas previsões também contém as verdadeiras quantidades de óbitos por neoplasias malignas de pele ocorridas na Região Sul. O MAPE das previsões desse modelo foi de 10,10%, o RMSE foi de 10,21 e o MPE foi de -6,73%. Vale ressaltar que o MAPE se reduziria para 2,48% e o RMSE para 2,98.

Quanto à qualidade das previsões para os seis meses de 2015 (Tab. 7.14) utilizando o modelo GARMA-BN (4,0), com exceção das previsões para mês de fevereiro, observou-se também que as previsões para os demais meses também se encontram próximos aos valores reais, e os intervalos de confiança dessas previsões também contém as verdadeiras quantidades de óbitos por neoplasias malignas de pele ocorridas na Região Sul. O MAPE das previsões desse modelo foi de 11,37%, o RMSE foi de 10,18 e o MPE foi de 6,73%. Vale ressaltar que o MAPE se reduziria para 3,88% e o RMSE para 3,00.

Comparando as medidas de precisão dos modelos GARMA-Poisson (2,0) e GARMA-BN

Tabela 7.13: Previsões para os seis meses de 2015 obtidas a partir do modelo GARMA-Poisson (4,0) estimado para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Períodos	Óbitos reais	Óbitos previstos	Intervalos de confiança 95%
1º mês	75	72,82227	[60,30008; 84,02446]
2º mês	50	74,01996	[58,23471; 90,02002]
3º mês	67	67,55277	[56,60109; 86,73145]
4º mês	66	62,45418	[52,80330; 72,11666]
5º mês	66	61,11107	[50,38790; 73,45181]
6º mês	64	65,88036	[52,00125; 79,75947]

Fonte: Elaborada pelo autor

Tabela 7.14: Previsões para os seis meses de 2015 obtidas a partir do modelo GARMA-BN (4,0) estimado para a série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil entre 1996 e 2014.

Períodos	Óbitos reais	Óbitos previstos	Intervalos de confiança 95%
1º mês	75	72,66273	[60,11472; 84,08226]
2º mês	50	74,10777	[58,32241; 90,04108]
3º mês	67	67,35239	[56,34510; 86,81368]
4º mês	66	62,25185	[52,98033; 72,27600]
5º mês	66	61,21402	[50,78090; 73,21261]
6º mês	64	65,96362	[52,31400; 79,47597]

Fonte: Elaborada pelo autor

(2,0), foi observado que o GARMA-Poisson (2,0) apresentou um MAPE levemente menor, enquanto o RMSE e o MPE foram levemente maiores. Pode-se constatar que o modelo GARMA-Poisson (2,0) apresentou melhores resultados comparado ao modelo GARMA-BN (2,0). Ainda assim, os resultados da qualidade das previsões foram bastante próximos.

Comparando as medidas de precisão dos modelos GARMA-Poisson (4,0) e GARMA-BN (4,0), foi observado que o GARMA-Poisson (4,0) apresentou um MAPE e um MPE levemente menor, enquanto o RMSE foi levemente maior. Pode-se constatar que o modelo GARMA-BN (4,0) apresentou melhores resultados para a série mensal, comparado ao modelo GARMA-Poisson (4,0). De todo modo, assim como na série com periodicidade trimestral, pode-se dizer que os resultados obtidos por ambos os modelos foram bastante próximos. também foram superiores ao modelo ARIMA(0,1,1) para a série mensal.

7.9 Comparação dos resultados obtidos pelos modelos ARIMA e GARMA

Analisando os gráficos das figuras 7.25 e 7.26 foi possível constatar que os modelos GARMA-Poisson (2,0) e GARMA-BN (2,0) ajustaram-se as variações ocorridas na série trimestral de óbitos por neoplasias malignas de pele na Região Sul do Brasil, entre 1996 e 2014, quando comparado ao ajuste do modelo ARIMA(4,1,0) com constante.

Pelos gráficos das figuras 7.25 e 7.26, também foi possível constatar que os modelos GARMA-BN (4,0) e GARMA-BN (4,0) ajustaram-se melhor as variações ocorridas na série mensal de óbitos por neoplasias malignas de pele na Região Sul do Brasil, entre 1996 e 2014, quando comparado ao ajuste do modelo ARIMA(0,1,1).

Em geral, avaliando as medidas de acurácia ou qualidade dos ajustes dos modelos ARIMA e GARMA, foi constatado que, tanto o GARMA-Poisson (2,0), quanto o GARMA-BN (2,0) para série com periodicidade trimestral, apresentaram melhores resultados que o modelo ARIMA (4,1,0) com constante. Essa mesma constatação foi obtida para os ajustes da série com periodicidade mensal, na qual os ajustes dos modelos GARMA-BN (4,0) e GARMA-Poisson (4,0) mostraram-se superiores ao modelo ARIMA (0,1,1).

Quanto à qualidade das previsões, os modelos GARMA-Poisson (2,0) e GARMA-BN(2,0) também demonstraram superioridade comparados ao ARIMA (4,1,0) com constante, para a série trimestral de óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014, assim como os modelos GARMA-BN (4,0) e GARMA-Poisson (4,0), para a série com periodicidade mensal.

8 CONSIDERAÇÕES FINAIS

Este estudo possibilitou evidenciar algumas características como presença de tendência crescente, ausência de sazonalidade e comportamento não estacionário das séries trimestral e mensal dos óbitos por neoplasias malignas de pele ocorridos Região Sul do Brasil, entre 1996 e 2014.

O modelo ARIMA com melhor ajuste, previsões e mais parcimonioso para a série com periodicidade trimestral foi o ARIMA (4,1,0) com constante e para a série mensal foi o modelo ARIMA (0,1,1). A classe de modelos ARIMA se mostrou mais adequada para estimação e previsão para a série de óbitos por neoplasias malignas de pele ocorridos na Região Sul do Brasil, entre 1996 e 2014, agregada em períodos trimestrais, quando comparada a série em períodos mensais.

Os modelos ARIMA se mostraram mais adequados para estimar e prever a série de óbitos por neoplasias malignas de pele ocorridos na Região Sul agregada em observações trimestrais, como parado as mensais. Considerando essa classe de modelos, as melhores estimativas foram obtidas pelo modelo ARIMA agregado dessa forma pois as agregações dos meses em trimestres proporcionaram uma redução na variabilidade, se comparada a série agregada em períodos mensais.

Os modelos GARMA-Poisson e GARMA-BN com melhor ajuste, previsões e mais parcimoniosos para a série com periodicidade trimestral foram, respectivamente, os modelos GARMA-Poisson (2,0) e GARMA-BN (2,0). Quanto a essa classe de modelos para a série agregada em períodos trimestrais, foi constatado que o modelo GARMA-Poisson (2,0) apresentou melhores resultados quando comparado ao GARMA-BN (2,0). Ainda assim, ficou evidente que os resultados obtidos por esses modelos com distribuições condicionais Poisson e BN foram bastante próximos.

Já para a série agregada em períodos mensais, os modelos GARMA-Poisson e GARMA-BN com melhor ajuste, previsões e mais parcimoniosos foram, respectivamente, os modelos GARMA-Poisson (4,0) e GARMA-BN (4,0). Considerando essa classe de modelos, foi constatado que o modelo GARMA-BN (4,0) apresentou melhores resultados quando comparado ao GARMA-Poisson (4,0). Nesse caso, o melhor resultado do modelo GARMA-BN, em relação ao GARMA-Poisson, se justifica pela maior variabilidade existente na série em períodos mensais, quando comparada a série em períodos trimestrais. De todo modo, os resultados obtidos por essas duas distribuições também foram bastante próximos, assim como observado para a série em períodos trimestrais.

De modo geral, tanto a classe de modelos ARIMA quanto a classe de modelos GARMA se mostraram adequadas para estimação e previsão para a série de óbitos por neoplasias malignas de pele ocorridos na Região Sul, entre 1996 e 2014. No que se refere a comparação entre essas classes, os modelos ajustados e as previsões obtidas pelos modelos GARMA-Poisson e GARMA-BN, tanto para a série agregada em períodos trimestrais quanto para a série agregada em períodos mensais, apresentaram resultados bastante superiores em relação aos modelos

ARIMA.

A classe de modelos GARMA mostrou-se mais adequada pois captou melhor a variabilidade presente na evolução das observações. Ainda assim, pode-se dizer que ambas podem ser utilizadas no auxílio e formulação de novas políticas públicas proporcionando controlar, prevenir e/ou estabilizar a mortalidade por neoplasias malignas de pele, não somente nas regiões Sul, mas também para às demais regiões brasileiras.

No que diz respeito a facilidade de programação dos modelos ARIMA e GARMA no software R, foi possível constatar que os modelos ARIMA possuem uma maior quantidade de bibliotecas e, conseqüentemente, apresentam maiores possibilidades e formas de análise. Ainda assim, a superioridade apresentada pelas estimações e pelas previsões obtidas a partir dos modelos GARMA com distribuição condicional Poisson e BN evidenciaram a necessidade do desenvolvimento de novas bibliotecas de uso mais simples e intuitivo para análise desses modelos.

A continuidade de estudos relacionados às neoplasias malignas de pele se justifica por apresentarem impacto bastante relevante na área da saúde. Os modelos de séries temporais ARIMA e GARMA com distribuições condicionais Poisson e BN se mostraram bastante adequados e podem auxiliar no processo de melhorias e também direcionar à tomada de decisões em termos de saúde pública.

Por isso, para estudos futuros pretende-se modelar a série analisada utilizando os modelos GARMA com outras distribuições condicionais de probabilidade. Outra possibilidade de estudos futuros se refere ao desenvolvimento de bibliotecas com maiores opções de análise e maior facilidade de utilização para os usuários do software R, livre e de uso gratuito em pesquisas.

9 REFERÊNCIAS

- AKAIKE, H. Maximum likelihood identification of Gaussian autoregressive moving average models. **Biometrika**, v.60, n.2, p.255–265, 1973.
- AKHTAR, S.; ROZI, S. An autoregressive integrated moving average model for shortterm prediction of hepatitis C virus seropositivity among male volunteer blood donors in Karachi, Pakistan. **World Journal of Gastroenterology**, v. 15, n. 13, p. 1607, 2009.
- BENJAMIN, M. A.; RIGBY, R. A.; STASINOPOULOS, D. M. Generalized autoregressive moving average models. **Journal of the American Statistical association**, v.98, n.461, p.214–223, Mar. 2003.
- BOX, G. E. P *et al.* **Time series analysis: forecasting and control**. John Wiley & Sons, 709 p., 2015.
- BOX, G. E.; JENKINS, G. M. **Time Series Analysis Forecasting and Control**. San Francisco: Holden-Day, Inc, 1970.
- BOX, G. E.; PIERCE, D. A. Distribution of residual autocorrelations in autoregressive integrated moving average time series models. **Journal of the American statistical Association**, [S.l.], v.65, n.332, p.1509–1526, 1970.
- BROCKWELL, P. J.; DAVIS, R. A. **Time series: data analysis and theory**. Springer Science Business Media: New York, 589 p., 1991.
- BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 299 p., 2008.
- BURNHAM, K. P.; ANDERSON, D. R. Multimodel inference: understanding AIC and BIC in model selection. **Sociological methods & research**, v. 33, n. 2, p. 261-304, 2004.
- CARRADORI, R. G.; RAMOS, P. de S.. Avaliação de testes de normalidade implementados no programa R por simulação Monte Carlo. **Revista da Estatística da Universidade Federal de Ouro Preto**, v. 3, n. 2, p. 33-41, 2014.
- CUTHBERTSON, K.; HALL, S. G.; TAYLOR, M. P. **Applied econometric techniques**. Ann Arbor: University of Michigan Press, 1992.
- DICKEY, D. A.; FULLER, W. A. Distribuition of the estimators for autoregressive time series with a unit Root. **Journal of the American Statistical Association**, v.74, n. 366, p. 427-31, 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.

- EARNEST, A *et al.* Using autoregressive integrated moving average (ARIMA) models to predict and monitor the number of beds occupied during a SARS outbreak in a tertiary hospital in Singapore. **BMC Health Services Research**, v.5, n.1, p.36, 2005.
- GUJARATI, D. M; PORTER, D. C. **Econometria básica**. 5. Ed. São Paulo: Makron books, 924 p., 2011.
- HAMILTON, J. D. **Time series analysis**. Princeton: Princeton university press, 1994.
- HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International journal of forecasting**, v. 22, n. 4, p. 679-688, 2006.
- HURVICH, C. M. TSAI, C. L. Regression and time series model selection in small samples. **Biometrika**, v.76, 297-307, 1989.
- INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA (INCA). **Estimativas 2014: Incidência de câncer no Brasil**. Rio de Janeiro, 124 p., 2014.
- INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA (INCA). **Estimativas 2016: Incidência de câncer no Brasil**. Rio de Janeiro, 124 p., 2015.
- KWIATKOWSKI, D. *et al.* Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?. **Journal of econometrics**,[S.l.],v.54,n.1-3,p.159–178, 1992.
- LI, W. K. Time series models based on generalized linear models: some further results. **Biometrics**, p.506–511, 1994.
- LIMA-COSTA, M. F. F.; BARRETO, S. M. Tipos de estudos epidemiológicos: conceitos básicos e aplicações na área do envelhecimento. **Epidemiologia e serviços de saúde**, v. 12, n. 4, p. 189-201, 2003.
- LIU, Q. *et al.* Forecasting incidence of hemorrhagic fever with renal syndrome in China using ARIMA model. **BMC infectious diseases**, v. 11, n. 1, p. 218, 2011.
- LJUNG, G. M.; BOX, G. E. On a measure of lack of t in time series models. **Biometrika**, p.297–303, 1978.
- MCCULLAGH, P.; NELDER, J. A. **Generalized Linear Models**. 5 ed. Chapman and Hall, 1989.
- MADDALA, G. S. **Introduction to Econometrics**. 3. ed. New York: John Wiley Sons, 664 p., 2001.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: Methods and Applications**. 3. ed. Ed. Wiley Sons, 642 p., 1998.

- MATOS, O. C. **Econometria Básica: teoria e aplicações**. 3. ed. São Paulo: Atlas, 300 p., 2000.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Blücher, 535 p., 2006.
- NELDER, J. A.; WEDDERBURN, R. W. M. Generalized Linear Models. **Journal of the Royal Statistical Society**, v.135, p.370-384, 1972.
- ORGANIZAÇÃO MUNDIAL DA SAÚDE. **CID-10: Classificação Estatística Internacional de Doenças**. Vol. 1. Edusp, 1994.
- PHILLIPS, P. C.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, [S.l.], p.335–346, 1988.
- R, C. D. A language and environment for statistical computing. **R foudation for Statistical computing**, Vienna, Austria. 2017.
- RAZALI, N. M.; WAH, Y. B. Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. **Journal of statistical modeling and analytics**, v. 2, n. 1, p. 21-33, 2011.
- SCHWARZ, G. Estimating the dimension of a model. **The annals of statistics**. Hayward, v.6, n.2, p.461–464, Abr. 1978.
- SOUZA, R. C.; CAMARGO, M. E. **Análise e previsão de séries temporais: os modelos ARIMA**. Ijuí: Sedigraf, 1996.
- THEIL, H. **Applied economic forecasting**. Amsterdam: North-Holland, 1966.
- TUKEY, J. W. Discussion, emphasizing the connection between analysis of variance and spectrum analysis. **Technometrics**, v. 3, n. 2, p. 191-219, 1961.
- VASCONCELLOS, M. A. S.; ALVES, D. **Manual de Econometria**. 1 ed. São Paulo: Atlas, 2000.
- WALKER, G. "On Periodicity in Series of Related Terms". **Proceedings of the Royal Society of London**, Ser. A, Vol. 131, 518–532, 1931.
- WHITTLE, P. **Hypotesis testing in the time series analysis**. Thesis, Uppsala University, Almqvist and Wiksell, Uppsala, 1951.
- YULE, G. On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers. **Philosophical Transactions of the Royal Society of London Series A**, v. 226, p. 267-298, 1927.

ZEGER, S. L.; QAQISH, B. Markov regression models for time series: aquasi-likelihood approach. **Biometrics**, p.1019–1031, 1988.

ZHANG, X. *et al.* Tendência prediva das caries da primeira infância na China continental: uma abordagem combinada de modelagem meta-analítica e matemática baseada em pesquisas epidemiológicas. **Scientific Reports** , v. 7, n. 1, p. 6507, 2017.