



Universidade Federal de Uberlândia
Instituto de Matemática e Estatística

Bacharelado em Estatística

**PREVISÃO DA SINISTRALIDADE NO
RAMO COMPREENSIVO RESIDENCIAL
POR MEIO DE MODELOS DE SÉRIES
TEMPORAIS: UMA APLICAÇÃO ÀS
SEGURADORAS BRADESCO E PORTO
SEGURO**

Guilherme Ferreira Oliveira

Uberlândia-MG

2025

Guilherme Ferreira Oliveira

**PREVISÃO DA SINISTRALIDADE NO
RAMO COMPREENSIVO RESIDENCIAL
POR MEIO DE MODELOS DE SÉRIES
TEMPORAIS: UMA APLICAÇÃO ÀS
SEGURADORAS BRADESCO E PORTO
SEGURO**

Trabalho de conclusão de curso apresentado à Co-
ordenação do Curso de Bacharelado em Estatística
como requisito parcial para obtenção do grau de
Bacharel em Estatística.

Orientador: Prof^ª Dra. Nádia Giaretta Biase

**Uberlândia-MG
2025**



**Universidade Federal de Uberlândia
Instituto de Matemática e Estatística**

Coordenação do Curso de Bacharelado em Estatística

A banca examinadora, conforme abaixo assinado, certifica a adequação deste trabalho de conclusão de curso para obtenção do grau de Bacharel em Estatística.

Uberlândia, 12 de Maio de 2025

BANCA EXAMINADORA

Prof^a Dra. Nádia Giaretta Biase

Prof^a Dra. Mirian Fernandes Carvalho Araújo

Prof^a Dra. Patrícia Ferreira Paranaíba

**Uberlândia-MG
2025**

AGRADECIMENTOS

Primeiramente, agradeço a Deus pela saúde, força e sabedoria, que me acompanharam durante toda essa jornada.

Agradeço à minha família pelo apoio incondicional, amor e compreensão ao longo de todo o processo. À minha namorada, pelo carinho, paciência e por me motivar a seguir em frente nos momentos mais desafiadores.

Aos meus amigos, sou grato pelos momentos de descontração, pelas risadas e pelas festas que me proporcionaram o alívio necessário para enfrentar os desafios dessa fase.

Agradeço à minha orientadora, Prof^a Dra.Nádia Giaretta Biase, pela valiosa orientação, dedicação e pelo constante apoio em todas as etapas deste trabalho.

Aos membros da banca, Prof^a Dra.Mirian Fernandes Carvalho Araújo e Prof^a Dra.Patrícia Ferreira Paranaíba, agradeço imensamente por aceitarem o convite e por disponibilizarem seu tempo para contribuir com a avaliação deste trabalho.

RESUMO

A sinistralidade no seguro compreensivo residencial é um indicador fundamental para o equilíbrio técnico das seguradoras, exigindo abordagens estatísticas consistentes para sua análise e previsão. Este estudo propõe a aplicação de modelos univariados de séries temporais do tipo SARIMA para estimar a sinistralidade mensal das seguradoras Bradesco Auto/RE e Porto Seguro, utilizando dados do período de janeiro de 2012 a dezembro de 2024. Embora o Itaú tenha sido incluído na etapa exploratória inicial, sua exclusão na fase de previsão foi motivada pela queda acentuada na participação da seguradora nos anos mais recentes, o que comprometeria a consistência estatística da modelagem. As análises foram realizadas no software R, com base em ferramentas gráficas e testes estatísticos. Foram aplicados o teste de Cox-Stuart para tendência, o teste de Fisher (G) para sazonalidade, e as funções de autocorrelação e autocorrelação parcial para identificação da estrutura temporal das séries. A escolha dos modelos foi guiada pelos critérios de informação AIC e BIC, enquanto a acurácia preditiva foi avaliada por meio do Erro Percentual Absoluto Médio (MAPE) e da Raiz do Erro Quadrático Médio (RMSE). O modelo SARIMA(0,1,1)(1,0,0)₁₂ foi ajustado para a Bradesco, com desempenho satisfatório. Já para a Porto Seguro, o modelo SARIMA(1,0,0)(1,0,2)₁₂ obteve melhor resultado, com menor erro e maior aderência à série observada. Os resultados confirmam a aplicabilidade da modelagem de séries temporais como ferramenta estatística de apoio à gestão atuarial, contribuindo para o controle de sinistralidade, a precificação e a definição de provisões no setor segurador.

Palavras-chave: Seguro Residencial, Tendência, Sazonalidade, SARIMA, Testes estatísticos, AIC, BIC, MAPE, RMSE.

ABSTRACT

Loss ratio in comprehensive residential insurance is a key indicator for the technical balance of insurance companies, requiring consistent statistical approaches for its analysis and forecasting. This study applies univariate time series models of the SARIMA class to estimate the monthly loss ratio of Bradesco Auto/RE and Porto Seguro, using data from January 2012 to December 2024. Although Itaú Seguros de Auto e Residência S.A. was initially considered due to its relevance in the sector, it was excluded from the forecasting stage as a result of a sharp decline in recent years, which compromised the consistency of its time series. Analyses were conducted in R software, employing graphical tools and statistical tests. The Cox-Stuart test was applied to detect trend, Fisher's G test for seasonality, and the autocorrelation function and partial autocorrelation function to identify temporal structure. Model selection was based on the Akaike Information Criterion (AIC) and Bayesian Information Criterion (BIC), while predictive accuracy was evaluated using the Mean Absolute Percentage Error (MAPE) and Root Mean Square Error (RMSE). The SARIMA(0,1,1)(1,0,0)₁₂ model was fitted to Bradesco with satisfactory performance. For Porto Seguro, the SARIMA(1,0,0)(1,0,2)₁₂ model showed better results, with lower prediction errors and higher adherence to the observed series. The results confirm the applicability of time series modeling as a statistical tool to support actuarial management, contributing to loss ratio control, pricing, and the definition of technical provisions in the insurance sector.

Keywords: Home Insurance, Trend, Seasonality, SARIMA, Statistical Tests, AIC, BIC, MAPE, RMSE.

SUMÁRIO

Lista de Figuras	I
Lista de Tabelas	II
1 Introdução	1
2 Fundamentação Teórica	3
2.1 Seguros	3
2.2 Fundamentos de Séries Temporais	3
2.3 Modelagem Estatística	5
2.4 Previsão e Avaliação de Modelos	9
3 Metodologia	11
4 Resultados	14
4.1 Prêmio Ganho das Seguradoras	14
4.2 Sinistralidade das Seguradoras	15
4.3 Ajuste e Previsão da Série de Sinistralidade – Bradesco	16
4.4 Ajuste e Previsão da Série de Sinistralidade – Porto Seguro	25
5 Conclusões	32
Referências Bibliográficas	33

LISTA DE FIGURAS

4.1	Prêmio ganho (R\$) das seguradoras Bradesco, Itaú e Porto Seguro no ramo compreensivo residencial de janeiro/2012 a dezembro/2024.	14
4.2	Sinistralidade das seguradoras Bradesco, Itaú e Porto Seguro no ramo compreensivo residencial de janeiro/2012 a dezembro/2024.	15
4.3	Série temporal da sinistralidade da seguradora Bradesco original e ajustada no período de janeiro/2012 a dezembro/2024.	17
4.4	Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal original.	18
4.5	Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal ajustada.	18
4.6	Cruzamento da média em relação ao desvio padrão da série original e da série ajustada da sinistralidade de Bradesco Seguradora.	19
4.7	Séries original e ajustada após a primeira diferenciação.	20
4.8	Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal original diferenciada.	21
4.9	Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal ajustada diferenciada.	21
4.10	Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACp) dos resíduos do modelo selecionado para a seguradora Bradesco.	23
4.11	Gráfico quantil-quantil dos resíduos do modelo selecionado para a seguradora Bradesco.	24
4.12	Comparação entre Valores Reais e Previstos da Sinistralidade da Seguradora Bradesco.	25
4.13	Série Temporal Ajustada da Sinistralidade da Porto Seguro.	26
4.14	Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACp) da Série Ajustada da Porto Seguro.	26
4.15	Gráfico de Dispersão da Média pelo Desvio Padrão da Série Ajustada da Porto Seguro.	27
4.16	Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACp) dos resíduos do modelo selecionado para a seguradora Porto Seguro.	29
4.17	Gráfico quantil-quantil dos resíduos do modelo selecionado para a seguradora Porto Seguro.	30
4.18	Comparação entre Valores Reais e Previstos da Sinistralidade da Seguradora Porto Seguro.	31

LISTA DE TABELAS

4.1	Estatísticas descritivas da sinistralidade das seguradoras Bradesco, Itaú e Porto Seguro no ramo compreensivo residencial de janeiro/2012 a dezembro/2024. . . .	16
4.2	Estimativas dos parâmetros dos modelos escolhidos da seguradora Bradesco para a série original e ajustada.	22
4.3	Critérios de avaliação dos modelos ajustados para a série de sinistralidade da seguradora Bradesco.	22
4.4	Valores Reais, Previstos e Erro Absoluto da Sinistralidade.	24
4.5	Estimativas dos parâmetros dos modelos SARIMA testados.	28
4.6	Critérios de avaliação dos modelos SARIMA testados.	28
4.7	Valores Reais, Previstos e Erro Absoluto da Sinistralidade da seguradora Porto Seguro.	30

1. INTRODUÇÃO

O mercado de seguros desempenha papel fundamental na preservação da estabilidade financeira de indivíduos, empresas e instituições. Ele oferece proteção contra eventos imprevisíveis que possam comprometer o patrimônio, a renda ou até mesmo a vida das pessoas.

No Brasil, a história do setor segurador entrelaça-se intimamente com o desenvolvimento do país desde o século XIX, marcando os primórdios da proteção patrimonial e delineando o panorama do setor financeiro do país. Assim, com o desenvolvimento do setor em âmbito nacional tornou-se necessário regulamentar essa atividade, o que culminou na instituição da Superintendência Geral de Seguros em 1901 e a promulgação do Código Civil Brasileiro em 1916. Na década de 1930, marcos como o Instituto de Resseguros do Brasil (IRB) em 1939 e a Superintendência de Seguros Privados (SUSEP) em 1966 consolidaram o Sistema Nacional de Seguros Privados, acompanhado por medidas como o Princípio de Nacionalização do Seguro e a regulamentação das operações de seguros e resseguros [3, 16].

Com o avanço da regulamentação e da sofisticação dos produtos ofertados no setor segurador brasileiro, consolidou-se o grupo dos seguros compreensivos patrimoniais, caracterizado pela integração de múltiplas coberturas em uma única apólice. Antes da consolidação dessa modalidade, a proteção patrimonial exigia que o segurado contratasse apólices separadas para cada tipo de risco, como incêndio, roubo, alagamento ou desmoronamento. Esse processo, além de burocrático, resultava em custos mais elevados e em maior dificuldade de gerenciamento das coberturas contratadas [24, 25]. Os seguros compreensivos surgiram, nesse contexto, como uma alternativa prática e eficiente, oferecendo proteção ampla e personalizável, com melhor custo-benefício e maior comodidade para o consumidor.

No âmbito dos seguros patrimoniais, o seguro compreensivo residencial destina-se à proteção de imóveis habitacionais, sejam de uso permanente ou sazonal. A cobertura básica contempla danos provocados por incêndio, queda de raio e explosão. Além disso, o produto pode incluir garantias adicionais, conforme as condições específicas de cada seguradora, como proteção contra roubo e furto qualificado, danos elétricos, vendaval, impacto de veículos, desmoronamento, alagamento, quebra de vidros, queda de aeronaves, responsabilidade civil familiar e serviços de assistência 24 horas. Essa estrutura de cobertura torna o seguro compreensivo residencial mais abrangente em relação ao seguro de incêndio tradicional, cuja proteção se limita aos prejuízos causados por incêndio, raio e explosão, sem previsão de coberturas complementares ou assistências [24]. Em um cenário de crescente complexidade urbana e multiplicidade de riscos, a abrangência do seguro compreensivo residencial apresenta-se como uma solução mais robusta e

coerente com as demandas atuais de proteção patrimonial.

Destarte, este estudo concentra-se na previsão da sinistralidade no ramo compreensivo residencial, com base em dados mensais provenientes de seguradoras representativas do setor. No decorrer da análise, três variáveis são consideradas: o Prêmio Ganho, explorado por meio de análise descritiva; o Sinistro Ocorrido, empregado no cálculo da sinistralidade; e a própria Sinistralidade, que constitui a variável central da modelagem estatística. A seleção dessas variáveis reflete sua importância na avaliação do desempenho técnico das seguradoras.

Em um mercado caracterizado por alta competitividade e sensível a variações econômicas e climáticas, como o brasileiro, a capacidade de estimar antecipadamente o comportamento da sinistralidade representa um diferencial estratégico. Isso permite maior precisão na definição dos prêmios, no dimensionamento das provisões técnicas e no controle de riscos, elementos fundamentais para a sustentabilidade das carteiras seguradas no longo prazo [20].

Nesse contexto, os modelos de séries temporais consolidam-se como ferramentas estatísticas robustas para a análise e a previsão da sinistralidade no setor de seguros. Ao examinar o comportamento histórico das séries, esses modelos permitem identificar padrões estruturais, como tendências e sazonalidades, além de capturar relações de dependência temporal entre as observações. Essa capacidade analítica oferece uma base sólida para projeções confiáveis, contribuindo diretamente para a antecipação de cenários e o aprimoramento das práticas de gestão atuarial.

Este trabalho tem como objetivo principal aplicar modelos univariados de séries temporais para prever a sinistralidade no ramo compreensivo residencial, com foco em duas das seguradoras mais representativas do mercado: Bradesco Auto/RE e Porto Seguro Companhia de Seguros Gerais. A análise será baseada em dados mensais do período de janeiro de 2012 a dezembro de 2024, reservando-se os seis últimos meses para a validação preditiva dos modelos ajustados. Busca-se, com isso, oferecer subsídios quantitativos que contribuam para o monitoramento e gestão do risco técnico no setor, além de fortalecer a aplicação da estatística como instrumento de suporte à tomada de decisão no campo securitário.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 SEGUROS

O contrato de seguro é um instrumento técnico de transferência e dispersão de riscos. Por meio dele, o segurado transfere à seguradora a responsabilidade financeira por eventuais prejuízos decorrentes de acontecimentos futuros e incertos, mediante o pagamento de um valor denominado prêmio. Essa lógica, alicerçada no princípio da mutualidade, sustenta a operação do mercado segurador, no qual diversos contribuintes formam uma base financeira coletiva destinada a cobrir as perdas daqueles que efetivamente sofrem sinistros [11].

No campo contábil e atuarial, o prêmio ganho representa a fração da receita originalmente contratada que já foi apropriada pela seguradora ao longo da vigência da apólice. Trata-se do montante correspondente ao risco efetivamente assumido até determinado momento, distinguindo-se do prêmio emitido, que considera a totalidade contratada, independentemente do tempo de cobertura já decorrida [22]. Já o sinistro ocorrido refere-se à materialização de um evento coberto, seja ele já indenizado, provisionado ou ainda em processo de regulação, sendo reconhecido como um passivo técnico que reflete a obrigação contratual da seguradora [6].

A partir da relação entre o prêmio ganho e o sinistro ocorrido, define-se a sinistralidade, um dos principais indicadores utilizados para avaliar o desempenho técnico de uma carteira de seguros. Calculada como a razão entre os sinistros ocorridos e os prêmios apropriados em um determinado período, e expressa em termos percentuais, a sinistralidade mensura o impacto das obrigações indenizatórias sobre a receita da seguradora. Por sua relevância, é amplamente utilizada no monitoramento do equilíbrio atuarial e na gestão do risco técnico [22].

2.2 FUNDAMENTOS DE SÉRIES TEMPORAIS

Séries temporais são conjuntos de observações quantitativas registrados ao longo do tempo, com registros realizados em instantes sucessivos e com intervalos regulares, como minutos, dias, meses ou anos. O aspecto distintivo dessas séries está no fato de que a ordem cronológica das observações não é arbitrária, mas fundamental para sua interpretação e modelagem. Além disso, é comum que cada dado registrado em um determinado instante está potencialmente influenciado por valores anteriores, configurando uma estrutura de dependência temporal. Essa estrutura temporal rompe com a suposição de independência entre observações frequentemente assumida em métodos estatísticos tradicionais, exigindo um tratamento específico que considere

a conexão entre os dados ao longo do tempo [14].

Do ponto de vista matemático, uma série temporal pode ser compreendida como a realização de um processo estocástico, definido como um conjunto de variáveis aleatórias $\{X_t\}_{t \in \mathbb{Z}}$, cada uma associada a um instante de tempo específico. Um processo estocástico é, portanto, uma coleção de variáveis aleatórias definidas sobre um mesmo espaço amostral, em que cada variável representa o valor de um fenômeno em um instante específico. A indexação temporal dessas variáveis permite capturar não apenas a incerteza associada a cada observação individual, mas também as possíveis dependências e padrões que surgem ao longo da evolução do tempo [7]. Em aplicações práticas, a série temporal observada $\{X_t\}$ corresponde a uma trajetória específica gerada por esse processo subjacente, isto é, uma realização única entre todas as possíveis evoluções que o processo pode assumir.

Para extrair informações relevantes de uma série temporal, é importante compreender certas propriedades estatísticas, como média, variância e autocovariância, que descrevem o comportamento do processo ao longo do tempo. A média $\mu_t = \mathbb{E}[X_t]$ indica o valor esperado do processo no instante t , a variância $\sigma_t^2 = \text{Var}(X_t)$, por sua vez, indica o grau de variabilidade dos valores em torno da média. Também se considera a autocovariância $\gamma_{t,s} = \text{Cov}(X_t, X_s)$, que quantifica a dependência linear entre observações realizadas em dois momentos distintos t e s . A interpretação conjunta dessas medidas pode fornecer subsídios relevantes para a identificação de estruturas dinâmicas presentes na série, apoiando a formulação de modelos estatísticos adequados.

Com base nessas propriedades, fundamenta-se a identificação dos principais componentes que descrevem a estrutura evolutiva da série temporal. Os quatro elementos tradicionalmente considerados nesse processo de decomposição são: tendência, sazonalidade, ciclos e componente aleatório. A tendência refere-se a uma mudança persistente no nível médio da série ao longo do tempo, podendo indicar padrões de crescimento, declínio ou estabilidade. Exemplos típicos incluem o aumento contínuo do consumo de energia elétrica em áreas urbanas, o crescimento progressivo no volume de tráfego em plataformas digitais ou a redução gradual da taxa de mortalidade em determinadas populações. A correta identificação da tendência desempenha papel fundamental na modelagem de séries temporais, uma vez que sua presença não tratada pode gerar distorções nas estimativas, comprometer a validade das inferências e prejudicar a capacidade preditiva dos modelos ajustados [14].

As séries temporais também podem apresentar comportamentos que se repetem em intervalos fixos de tempo, fenômeno conhecido como sazonalidade. Essas variações sistemáticas são provocadas por fatores previsíveis, como padrões climáticos, eventos do calendário civil, ciclos agrícolas ou dinâmicas sazonais de consumo associadas a hábitos culturais [4]. Diferenças sazonais de demanda em setores econômicos, como o aumento nas vendas do comércio varejista durante o fim de ano, a elevação da venda de chocolates no período da Páscoa ou a redução da ocupação hoteleira em meses de baixa temporada, ilustram esse tipo de comportamento. A componente sazonal, diferentemente da tendência, caracteriza-se por oscilações regulares que se repetem em períodos definidos, como ciclos mensais ou anuais, mantendo padrão de

periodicidade previsível.

Os ciclos correspondem a oscilações de subida e queda que ocorrem ao longo da componente de tendência da série temporal, de forma suave e prolongada. Esses movimentos não apresentam uma periodicidade fixa e estão frequentemente associados a fenômenos econômicos, sociais ou ambientais, como fases de expansão e recessão de uma economia ou padrões climáticos de longo prazo.

Por fim, o componente aleatório reúne as variações não explicadas pelos padrões estruturais anteriores. São flutuações imprevisíveis, de curta duração e sem estrutura recorrente aparente, que resultam de fatores não sistemáticos que afetam a série temporal. Em geral, essas variações são tratadas como ruído branco $\{\varepsilon_t\}$ caracterizado por:

$$\mathbb{E}[\varepsilon_t] = 0, \quad \text{Var}(\varepsilon_t) = \sigma^2, \quad \text{Cov}(\varepsilon_t, \varepsilon_{t+k}) = 0, \quad \text{para } k \neq 0, \quad (2.1)$$

A verificação de que os resíduos do modelo ajustado se comportam como ruído branco é fundamental para a avaliação da adequação da modelagem. Caso contrário, padrões residuais não capturados indicam deficiências na estrutura proposta, podendo comprometer a validade das inferências e a capacidade preditiva dos modelos [8].

Identificar a existência de padrões estruturais em séries temporais pode ser conduzido com o apoio de testes estatísticos específicos. No contexto da análise de tendência, o teste de Cox-Stuart compara pares simétricos de observações ao longo do tempo, buscando identificar alterações sistemáticas. A hipótese nula (H_0) nesse teste pressupõe a inexistência de tendência significativa, ou seja, que a série seja simétrica em relação ao tempo [9]. Na avaliação da sazonalidade, o teste de Fisher's G é empregado para investigar a presença de padrões periódicos relevantes na série. A hipótese nula (H_0) considera que não existe sazonalidade significativa no comportamento dos dados [10].

2.3 MODELAGEM ESTATÍSTICA

Modelar estatisticamente séries temporais exige que suas propriedades fundamentais permaneçam constantes ao longo do tempo. Essa característica, denominada estacionariedade, implica que o comportamento estatístico da série não se altere em função do momento da observação. Em termos práticos, uma série temporal é considerada estacionária quando apresenta média constante, variância constante e uma estrutura de dependência que se baseia exclusivamente na distância entre os instantes de tempo, independentemente do momento específico em que as observações são realizadas [4, 5].

Considerando uma série temporal $\{X_t\}$, a estacionariedade é caracterizada pelas seguintes propriedades:

$$\mathbb{E}[X_t] = \mu, \quad \text{Var}(X_t) = \sigma^2, \quad \text{Cov}(X_t, X_{t+h}) = \gamma(h), \quad (2.2)$$

para todo $t \in \mathbb{Z}$ e para qualquer defasagem h , onde $\gamma(h)$ representa a função de autocovariância

dependente apenas da distância h .

A verificação da estacionariedade é essencial antes da aplicação de métodos de modelagem e previsão, uma vez que séries que apresentam tendências sistemáticas, variações sazonais ou mudanças de variabilidade ao longo do tempo podem comprometer a validade das inferências estatísticas. Nessas situações, procedimentos de transformação, como a diferenciação ou o ajuste de componentes estruturais, tornam-se necessários para estabilizar as propriedades da série e possibilitar a construção de modelos adequados [4].

O estudo da estrutura de dependência entre observações de uma série temporal é fundamental para a construção de modelos adequados. A função de autocorrelação (FAC) constitui a principal ferramenta nesse diagnóstico preliminar, mensurando o grau de associação linear entre observações separadas por diferentes defasagens. Para uma defasagem h , a função de autocorrelação é definida como:

$$\rho(h) = \frac{\text{Cov}(X_t, X_{t+h})}{\text{Var}(X_t)}, \quad (2.3)$$

sendo $\rho(h)$ o coeficiente de autocorrelação correspondente à distância h entre as observações [14].

A análise FAC permite inferir padrões de dependência temporal: autocorrelações elevadas para defasagens pequenas podem indicar a presença de tendência, enquanto oscilações periódicas na FAC sugerem a existência de comportamento sazonal. Por outro lado, a ausência de autocorrelações significativas é característica de processos puramente aleatórios, compatíveis com ruído branco.

Embora a FAC forneça informações importantes para detectar padrões estruturais iniciais, ela não distingue correlações diretas de correlações indiretas, pois a autocorrelação observada em uma defasagem pode ser influenciada por relações intermediárias. Para contornar essa limitação, utiliza-se a função de autocorrelação parcial (FACp), que mede a associação direta entre duas observações separadas por uma defasagem h , eliminando os efeitos das variáveis situadas entre elas [4].

A interpretação conjunta dos gráficos da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACp) fornece subsídios importantes para a especificação preliminar da estrutura dos modelos de séries temporais. Esses diagnósticos permitem identificar padrões de dependência relevantes, orientando a seleção dos componentes autorregressivos e de médias móveis. A análise estrutural obtida a partir dessas funções fundamenta a escolha de estratégias de modelagem adequadas, conduzindo naturalmente à formulação dos modelos autorregressivos integrados de médias móveis (ARIMA) e suas extensões sazonais (SARIMA), introduzidos sistematicamente por Box e Jenkins [4].

Consolidando-se como uma das metodologias mais amplamente utilizadas na análise de séries temporais, os modelos ARIMA e SARIMA, combinam três componentes fundamentais: um termo autorregressivo (AR), um componente integrado (I), que trata características de não estacionariedade, e um termo de médias móveis (MA).

O componente autorregressivo de ordem p (AR(p)) descreve o valor atual da série como uma

combinação linear de seus próprios valores defasados, acrescido de um termo de erro aleatório. Esse comportamento é representado pela seguinte equação:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \cdots + \phi_p X_{t-p} + \varepsilon_t, \quad (2.4)$$

em que X_t é o valor observado no tempo t , $\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes autorregressivos que quantificam a influência dos valores passados, e ε_t corresponde a um termo de ruído branco [14].

Dentro da estrutura dos modelos ARIMA, o termo de médias móveis (MA) descreve a contribuição dos erros passados para a formação do valor atual da série temporal. Essa componente é representada pela equação:

$$X_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q}, \quad (2.5)$$

onde ε_t é o erro aleatório no instante t , $\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes de médias móveis, e ε_{t-i} correspondem aos erros defasados [14]. Esse componente captura os efeitos residuais de variações aleatórias passadas, desempenhando papel fundamental na representação de oscilações de curto prazo no comportamento da série.

O componente integrado (I) tem como função transformar séries temporais não estacionárias em séries aproximadamente estacionárias por meio da operação de diferenciação. Essa transformação é aplicada para remover tendências determinísticas e estabilizar a média da série ao longo do tempo [4]. A diferenciação simples é definida como:

$$\nabla X_t = X_t - X_{t-1}, \quad (2.6)$$

sendo ∇X_t a primeira diferença entre observações consecutivas. De maneira mais geral, a diferenciação de ordem d é expressa por:

$$\nabla^d X_t, \quad (2.7)$$

em que d indica o número de vezes que a diferenciação é aplicada.

A formulação geral de um modelo ARIMA(p, d, q) é expressa pela equação:

$$\Phi(B)(1 - B)^d X_t = \Theta(B)\varepsilon_t, \quad (2.8)$$

onde:

- B é o operador de defasagem, definido como $BX_t = X_{t-1}$;
- $\Phi(B)$ representa o polinômio autorregressivo de ordem p ;
- $\Theta(B)$ representa o polinômio de médias móveis de ordem q ;
- $(1 - B)^d$ indica a aplicação da diferenciação de ordem d para estabilizar a série em torno de uma média constante.

Embora os modelos ARIMA sejam amplamente eficazes para a modelagem de séries temporais que apresentam tendências ou oscilações irregulares, sua estrutura padrão não é suficiente quando a série manifesta padrões sazonais bem definidos. Nessas situações, em que as flutuações seguem periodicidades regulares, como variações mensais ou trimestrais, torna-se necessário incorporar uma dinâmica adicional ao modelo. A extensão SARIMA (modelo autorregressivo integrado de médias móveis sazonais) foi desenvolvida para atender a essa necessidade, acrescentando termos sazonais de autorregressão, diferenciação e médias móveis à estrutura tradicional. Essa formulação permite capturar adequadamente as dependências entre observações separadas por múltiplos da periodicidade sazonal s [14].

O modelo SARIMA(p, d, q)(P, D, Q) é representado pela seguinte equação:

$$\Phi(B^s)\phi(B)(1-B)^d(1-B^s)^D X_t = \Theta(B^s)\theta(B)\varepsilon_t, \quad (2.9)$$

em que:

- s representa a periodicidade sazonal (por exemplo, $s = 12$ para dados mensais);
- (P, D, Q) correspondem às ordens dos componentes sazonais: autorregressivo sazonal, diferenciação sazonal e média móvel sazonal, respectivamente;
- $\Phi(B^s)$ e $\Theta(B^s)$ são os polinômios sazonais de autorregressão e de médias móveis.

Definir adequadamente as ordens p, d, q, P, D e Q nos modelos ARIMA e SARIMA é fundamental para garantir parcimônia e maximizar a capacidade preditiva dos ajustes realizados. Embora as funções de autocorrelação (FAC) e autocorrelação parcial (FACp) forneçam diretrizes iniciais para a configuração dos modelos, a seleção definitiva entre alternativas viáveis exige a utilização de métricas formais que considerem tanto o grau de ajuste quanto a complexidade estrutural. Nesse contexto, destacam-se o Critério de Informação de Akaike (AIC) e o Critério de Informação Bayesiano (BIC), amplamente consolidados na literatura como ferramentas de apoio à escolha de modelos em séries temporais [5].

O AIC, proposto por Akaike (1974), fundamenta-se na minimização da perda de informação associada à escolha do modelo, incorporando uma penalização proporcional ao número de parâmetros estimados. Sua expressão é dada por:

$$\text{AIC} = -2\log(\hat{L}) + 2k, \quad (2.10)$$

onde \hat{L} representa a máxima verossimilhança do modelo ajustado e k o número de parâmetros livres [2].

O BIC, formulado por Schwarz (1978), adota uma abordagem bayesiana e penaliza mais severamente a complexidade conforme o tamanho da amostra n , sendo expresso por:

$$\text{BIC} = -2\log(\hat{L}) + k\log(n). \quad (2.11)$$

Modelos de séries temporais são comparados com base nos valores dos critérios AIC e BIC, que procuram equilibrar a qualidade do ajuste com a simplicidade estrutural. Dentro desse

processo de seleção, preferem-se as especificações que apresentem os menores valores desses critérios, sinalizando maior capacidade de descrever a dinâmica dos dados sem complexidade excessiva [2, 17]. Uma vez escolhido o modelo, a análise dos resíduos torna-se fundamental para avaliar a adequação do ajuste realizado.

Em séries temporais, os resíduos correspondem às diferenças entre os valores observados e aqueles previstos pelo modelo. A análise dessas diferenças permite verificar se os pressupostos básicos da modelagem são atendidos, em especial a ausência de autocorrelação serial. Idealmente, espera-se que os resíduos apresentem comportamento compatível com um processo de ruído branco, conforme caracterizado na equação (2.1), refletindo estabilidade da média, constância da variância e ausência de dependência linear entre períodos distintos.

Para formalizar a verificação dessa ausência de autocorrelação, emprega-se o teste de Box-Pierce, que avalia conjuntamente se as autocorrelações dos resíduos, em diversas defasagens, são estatisticamente distintas de zero. A hipótese nula (H_0) assume que não existe autocorrelação residual significativa. Assim, a não rejeição de H_0 indica que o modelo ajustado captura adequadamente a estrutura de dependência temporal dos dados [14].

2.4 PREVISÃO E AVALIAÇÃO DE MODELOS

Prever valores futuros a partir de informações históricas é um dos propósitos centrais da modelagem de séries temporais. Essa tarefa apoia-se na suposição de que as relações identificadas no comportamento passado da série mantêm-se válidas para períodos subsequentes, desde que a estrutura do modelo tenha sido adequadamente especificada e permaneça estável. A qualidade das previsões obtidas, portanto, reflete tanto o ajuste do modelo quanto a sua capacidade de representar a dinâmica essencial dos dados [8].

A avaliação da qualidade das previsões geradas é realizada com base em métricas específicas de desempenho. Entre as mais utilizadas destacam-se o Erro Percentual Absoluto Médio (MAPE) e a Raiz do Erro Quadrático Médio (RMSE). O MAPE é definido como:

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right|, \quad (2.12)$$

onde X_t e \hat{X}_t representam, respectivamente, os valores observados e previstos no instante t , e n é o número total de observações. Essa métrica expressa a média dos erros percentuais absolutos, sendo especialmente útil para comparar modelos em séries de diferentes magnitudes, pois normaliza o erro em relação ao valor real.

Outra medida relevante é o RMSE, definido como:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (X_t - \hat{X}_t)^2}, \quad (2.13)$$

o qual calcula a raiz quadrada da média dos erros quadráticos. Essa métrica é particularmente sensível a grandes desvios, atribuindo penalizações mais severas a previsões com erros expres-

sivos. A escolha entre MAPE e RMSE depende do objetivo da análise e das características da série estudada, sendo comum a utilização simultânea de ambas as métricas para uma avaliação mais abrangente da capacidade preditiva do modelo [14].

3. METODOLOGIA

Os dados utilizados neste estudo foram obtidos a partir do site oficial da Superintendência de Seguros Privados (SUSEP), órgão regulador do setor segurador no Brasil, o que garante a confiabilidade e a atualidade das informações analisadas [23]. Foram consideradas as séries temporais mensais do período de janeiro de 2012 a dezembro de 2024, referentes às seguradoras Bradesco Auto/RE, Itaú Seguros de Auto e Residência S.A. e Porto Seguro Companhia de Seguros Gerais. Essas três instituições, em conjunto, responderam por 42,36% do total de prêmio ganho no ramo compreensivo residencial durante o período analisado, sendo, portanto, as selecionadas para compor a base empírica deste estudo. Foram analisadas as variáveis prêmio ganho, sinistro ocorrido e sinistralidade, esta última definida como o quociente entre o sinistro ocorrido e o prêmio ganho, representando a razão entre os valores pagos em indenizações e os valores arrecadados pelas seguradoras.

O processo metodológico foi estruturado em cinco etapas principais: (i) leitura e preparação dos dados; (ii) análise gráfica e estatística descritiva; (iii) avaliação da estacionariedade; (iv) modelagem e diagnóstico dos modelos ajustados; e (v) previsão e avaliação da acurácia preditiva. Todo o procedimento foi conduzido no ambiente RStudio, utilizando bibliotecas especializadas para cada uma das etapas analíticas.

A análise gráfica das séries foi conduzida com a biblioteca ggplot2 [26], por meio da geração de gráficos de linha, com o objetivo de explorar visualmente o comportamento das variáveis ao longo do tempo. Esta etapa permitirá observar padrões como tendência, sazonalidade, rupturas estruturais e instabilidades locais, sendo fundamental para a escolha das técnicas de modelagem apropriadas. A visualização também auxiliará na identificação de possíveis irregularidades nos dados, como valores extremos ou variações abruptas, sem, contudo, antecipar inferências sobre as características estatísticas das séries.

Além da visualização gráfica, foi elaborada uma tabela contendo medidas estatísticas descritivas das séries de sinistralidade das três seguradoras, incluindo média, desvio padrão e coeficiente de variação. Esta etapa permitirá uma análise comparativa preliminar do comportamento das seguradoras ao longo do período. Complementarmente, foi realizada a análise das funções de autocorrelação (FAC) e autocorrelação parcial (FACp) das séries originais de sinistralidade, antes de qualquer transformação ou ajuste. A leitura conjunta dessas funções será essencial para a identificação inicial de possíveis padrões de dependência temporal e para o direcionamento das próximas etapas de modelagem.

Posteriormente, foi realizada a avaliação da estacionariedade das séries temporais, etapa

essencial para garantir a adequação dos modelos ARIMA, cuja formulação pressupõe séries com propriedades estatísticas constantes ao longo do tempo [14]. Inicialmente, foi aplicado o teste de Cox-Stuart, um procedimento não paramétrico utilizado para identificar a presença de tendência. A hipótese nula (H_0) desse teste assumirá que a série é simétrica ao redor do tempo (ausência de tendência), enquanto a hipótese alternativa (H_1) indicará a existência de tendência significativa. A rejeição de H_0 , ao nível de significância de 5%, implicará na necessidade de aplicar uma ou mais diferenciações à série.

Adicionalmente, foi empregado o teste de Fisher's G, disponível na biblioteca GeneCycle [1], para a verificação da existência de sazonalidade determinística. A hipótese nula (H_0) assumirá a inexistência de padrão sazonal, enquanto a hipótese alternativa (H_1) indicará a presença de sazonalidade periódica. Um p-valor inferior a 5% levará à rejeição da hipótese nula, sugerindo a necessidade de incluir componentes sazonais na modelagem. A avaliação do comportamento aditivo ou multiplicativo da série será complementada com o gráfico de dispersão entre a média e o desvio padrão de pares consecutivos, conforme proposto por Morettin e Toloi [14].

Após as transformações necessárias e a verificação da estacionariedade, foi realizada a modelagem das séries com base na metodologia de Box-Jenkins [4], por meio da classe de modelos ARIMA (AutoRegressive Integrated Moving Average). Caso os testes indiquem a presença de sazonalidade significativa, poderão ser considerados modelos do tipo SARIMA (Seasonal ARIMA), que estendem a estrutura tradicional para incluir componentes sazonais. A notação geral adotada será $ARIMA(p,d,q)$ ou $SARIMA(p,d,q)(P,D,Q)_s$, conforme aplicável, onde os parâmetros representam, respectivamente, os termos autoregressivo, de diferenciação e de médias móveis, nas partes não sazonais e sazonais, e s indica a periodicidade ($s = 12$ para séries mensais).

A identificação e estimação dos modelos foram realizadas utilizando a função `auto.arima()` da biblioteca `forecast` [13], que sugere modelos baseando-se nos critérios de informação de Akaike (AIC) e Bayesiano (BIC), os quais penalizam modelos excessivamente complexos. Também foram considerados modelos ajustados manualmente, com base na leitura dos gráficos de autocorrelação e autocorrelação parcial, por meio da função `arima()`. A significância estatística dos coeficientes foi verificada com a função `coeftest()` da biblioteca `lmtest` [12], que aplica o teste de Wald.

O diagnóstico dos modelos ajustados incluiu a análise dos resíduos para verificar se os pressupostos foram atendidos. Foram analisadas as funções de autocorrelação (FAC) e autocorrelação parcial (FACp) dos resíduos, buscando identificar a ausência de estrutura temporal remanescente. Adicionalmente, foi aplicado o teste de Box-Pierce, cuja hipótese nula (H_0) postula que os resíduos seguem um processo de ruído branco. A não rejeição de (H_0) indicará que o modelo é adequado. A verificação da normalidade dos resíduos foi realizada por meio da inspeção visual do gráfico quantil-quantil (QQ-plot).

Com os modelos validados, foi realizada a etapa final de previsão. Foram geradas previsões para os meses de julho a dezembro de 2024, intervalo previamente reservado para validação. As previsões obtidas foram comparadas aos valores efetivamente observados, utilizando métricas

como o Erro Percentual Absoluto Médio (MAPE) e a Raiz do Erro Quadrático Médio (RMSE), calculadas com o apoio da função `accuracy()` da biblioteca `forecast` [13]. Os resultados foram apresentados por meio de gráficos e tabelas para facilitar a análise da acurácia dos modelos preditivos.

4. RESULTADOS

Inicialmente, foi realizada uma estatística descritiva das variáveis prêmio ganho e sinistralidade no ramo compreensivo residencial, considerando as três seguradoras selecionadas no estudo: Bradesco Auto/RE, Itaú Seguros de Auto e Residência S.A. e Porto Seguro Companhia de Seguros Gerais, o que permitiu uma visão preliminar do comportamento das variáveis ao longo do período de janeiro de 2012 a dezembro de 2024, servindo como base para as etapas subsequentes de modelagem.

4.1 PRÊMIO GANHO DAS SEGURADORAS




Figura 4.1: Prêmio ganho (R\$) das seguradoras Bradesco, Itaú e Porto Seguro no ramo compreensivo residencial de janeiro/2012 a dezembro/2024.

A Figura 4.1 apresenta o comportamento do prêmio ganho das três seguradoras ao longo do período analisado. Até o final de 2022, as seguradoras Bradesco e Itaú mantiveram valores relativamente próximos, com um crescimento gradual e estável. Por sua vez, a seguradora Porto Seguro apresentou um crescimento constante, mas ainda registrava um volume inferior

em relação às demais. Contudo conforme indicado na figura em tese, no início de 2023, houve mudanças substanciais no mercado apresentado. O Itaú experimentou uma queda expressiva no prêmio ganho, enquanto a Porto Seguro passou por um crescimento acelerado, consolidando-se, em 2024, como a seguradora com o maior volume de prêmio ganho no ramo compreensivo residencial.

Tal alteração no segmento pode estar associado a fatores estratégicos e de mercado. Desde 2009, Itaú Unibanco e Porto Seguro estabeleceram uma relação de parceria para a oferta e distribuição de seguros residenciais e de automóveis nos canais de venda do banco. Sendo assim, no contexto dessa relação, a Porto Seguro é responsável pela operação e gestão desses produtos, embora o Itaú ainda comercialize seguros sob sua marca [18, 19]. Esse modelo de negócios pode ter influenciado a redistribuição da carteira de seguros entre as duas seguradoras, refletindo diretamente no comportamento observado a partir de 2023.

4.2 SINISTRALIDADE DAS SEGURADORAS




Figura 4.2: Sinistralidade das seguradoras Bradesco, Itaú e Porto Seguro no ramo compreensivo residencial de janeiro/2012 a dezembro/2024.

Partindo para análise da sinistralidade, a Figura 4.2 ilustra a sua variação ao longo do período analisado, destacando diferenças significativas entre as seguradoras. Disso, o estudo indica que a Porto Seguro manteve os índices mais elevados durante praticamente todo o período, por outro lado, a Bradesco apresenta os menores valores, embora com oscilações consideráveis. O Itaú, em contrapartida, mantém-se em um nível intermediário, com menor volatilidade até 2023, quando sua sinistralidade sofre uma forte variação em resposta à queda no prêmio ganho.

De forma complementar, os dados da Tabela 4.1, que contempla as métricas de Média, Desvio Padrão e Coeficiente de Variação (CV), reforçam esse padrão. Nesse ínterim, Porto Seguro apresenta a maior média de sinistralidade (36,83%) e a menor variabilidade (23,01%), o

que indica uma carteira de seguros mais estável e consolidada. Por sua vez, a Bradesco registra a menor sinistralidade média (18,45%), mas com o maior coeficiente de variação (51,53%), indicando maior flutuação ao longo do tempo. Essa disparidade reflete a complexidade de suas abordagens e a heterogeneidade de suas dinâmicas operacionais.

Observa-se que a Bradesco tende a adotar uma política de subscrição mais conservadora, restringindo a aceitação de riscos de forma a manter maior controle sobre a sinistralidade e garantir a sustentabilidade técnica de sua carteira. Essa postura está alinhada às diretrizes estabelecidas pelo Conselho Nacional de Seguros Privados (CNSP), em especial a Resolução nº 416/2021, a qual determina a necessidade de uma estrutura sólida de gerenciamento de riscos, incluindo a gestão do risco de subscrição [21]. Por outro lado, a Porto Seguro parece adotar uma estratégia mais agressiva de captação de clientes, possivelmente aceitando um espectro mais amplo de riscos e compensando tal exposição com ajustes nos prêmios cobrados. Essa abordagem pode refletir uma maior tolerância ao risco, desde que respaldada por mecanismos de precificação adequados e provisões técnicas compatíveis.

Tabela 4.1: Estatísticas descritivas da sinistralidade das seguradoras Bradesco, Itaú e Porto Seguro no ramo compreensivo residencial de janeiro/2012 a dezembro/2024.

Seguradora	Média	Desvio Padrão	CV
Bradesco	0,1845	0,0951	51,5290
Itaú	0,2929	0,0834	28,4572
Porto Seguro	0,3683	0,0847	23,0087

Por conseguinte, a análise da variação do prêmio ganho reforça a necessidade de aprofundamento na sinistralidade das seguradoras. Como o foco deste estudo é a previsão da sinistralidade, a escolha por modelar apenas as seguradoras Bradesco e Porto Seguro se justifica pelo comportamento observado, visto que o Itaú apresentou uma redução significativa na sua participação a partir de 2023, podendo comprometer a confiabilidade de uma modelagem preditiva baseada em sua série histórica.

4.3 AJUSTE E PREVISÃO DA SÉRIE DE SINISTRALIDADE — BRADESCO

Nesse sentido, o comportamento da sinistralidade da seguradora Bradesco ao longo do tempo é apresentado na Figura 4.3, em que a série original exibe oscilações significativas, incluindo períodos com valores negativos, possivelmente decorrentes de ajustes contábeis ou recuperação de valores. Destarte, os dados foram previamente ajustados com o objetivo de aprimorar a modelagem. Valores negativos foram substituídos pela média dos 20 menores valores positivos, enquanto os outliers superiores foram suavizados com base na média dos 20 maiores valores positivos, respeitando o limite superior esperado da série temporal. Essa abordagem de ajuste de outliers foi inspirada em uma metodologia similar aplicada por Pandolfi e Gonçalves (2024),

que também utilizaram a substituição de outliers para melhorar a modelagem e a previsão da sinistralidade em seguros de vida [15].



Figura 4.3: Série temporal da sinistralidade da seguradora Bradesco original e ajustada no período de janeiro/2012 a dezembro/2024.

Visualmente, a série ajustada mantém o comportamento da original, mas com uma distribuição mais uniforme ao longo do tempo, atenuando as variações extremas que poderiam dificultar a modelagem. Apesar de haver indícios de uma leve tendência de crescimento na série original, tal tendência não se mostra indispensável para o desenvolvimento do estudo, que pode ser conduzido sem a confirmação desse fenômeno. Já a sazonalidade não se mostra evidente à primeira vista, podendo estar encoberta por oscilações irregulares ao longo do período analisado.

Nesse contexto, é fundamental a aplicação de métodos que auxiliem na identificação de padrões nas séries observadas. Assim, tem-se que a função de autocorrelação (FAC) e autocorrelação parcial (FACp) são análises que podem ser úteis na identificação de séries temporais não estacionárias. Quando a FAC apresenta um decaimento lento ao longo das defasagens, pode haver a presença de tendência, indicando não estacionariedade. A FACp, por sua vez, ajuda a determinar a ordem do modelo autoregressivo ao indicar até que ponto as observações passadas influenciam a série.

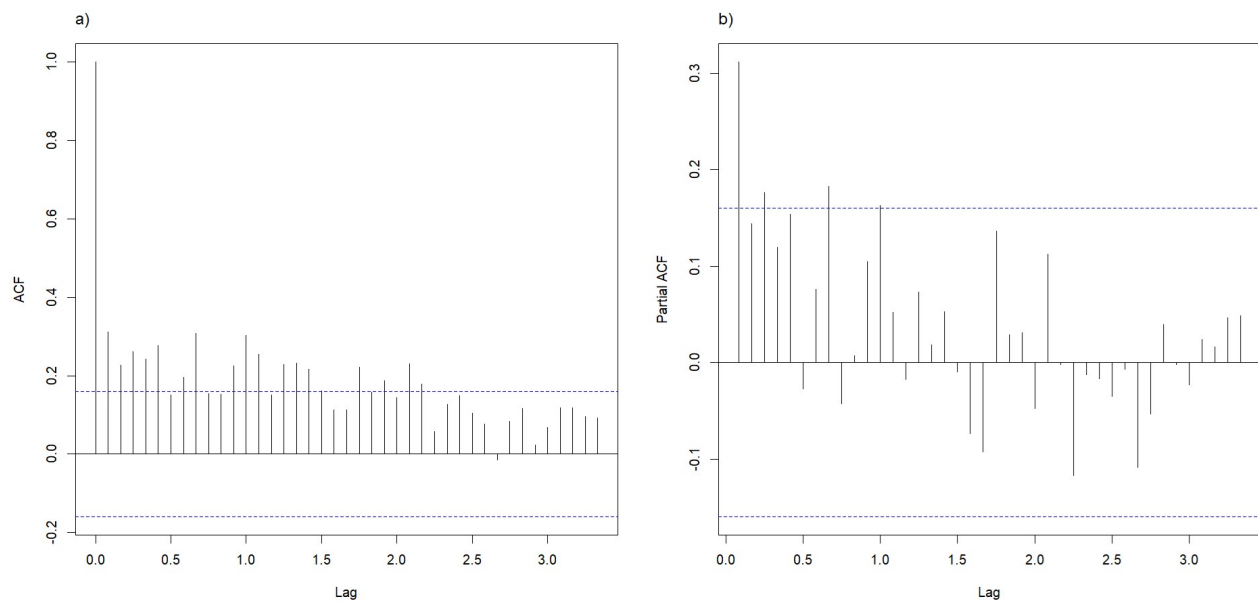


Figura 4.4: Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal original.

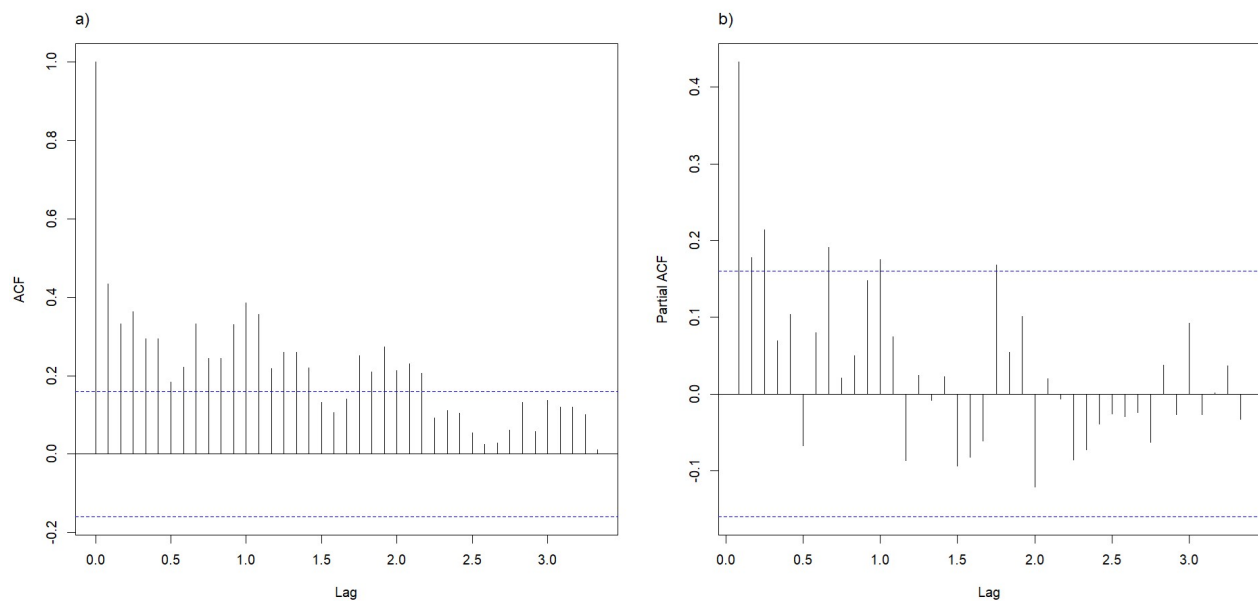


Figura 4.5: Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal ajustada.

As Figuras 4.4.a e 4.4.b apresentam, respectivamente, a função de autocorrelação (FAC) e a função de autocorrelação parcial (FACp) da série original da sinistralidade da seguradora Bradesco. Já as Figuras 4.5.a e 4.5.b correspondem aos mesmos gráficos aplicados à série ajustada. Em ambas as versões da série, a FAC apresenta um decaimento lento ao longo das

defasagens, enquanto a FACp exibe diversos lags significativos. Esse comportamento sugere a presença de dependência temporal de ordem mais alta, indicando que a série pode não ser estacionária. Diante disso, torna-se necessário aplicar testes estatísticos para avaliar a presença de tendência e sazonalidade, permitindo definir a estrutura mais adequada para a modelagem.

Com o objetivo de avaliar a necessidade de transformação da série, foi construído o gráfico de dispersão entre a média e o desvio padrão para as duas versões da série temporal da sinistralidade da seguradora Bradesco. A Figura 4.6.a exibe os resultados da série original, enquanto a Figura 4.6.b corresponde à série ajustada. Em ambas as representações, os pontos se distribuem de forma aleatória, sem indicar um padrão sistemático entre a média e o desvio padrão. Esse comportamento sugere que a variabilidade da série é constante ao longo do tempo, caracterizando uma estrutura aditiva. Assim, conclui-se que não há necessidade de aplicar transformações adicionais antes da modelagem.




Figura 4.6: Cruzamento da média em relação ao desvio padrão da série original e da série ajustada da sinistralidade de Bradesco Seguradora.

Para complementar a avaliação da estacionariedade da série, foram aplicados os testes de Cox-Stuart e Fisher's G às séries original e ajustada.

O teste de Cox-Stuart foi utilizado para avaliar a presença de tendência na série. A hipótese nula (H_0) desse teste assume que a série é aleatória, sem tendência significativa. Para ambas as séries, o p-valor obtido foi menor que 0,0000, e inferior ao nível de significância de 5% ($\alpha = 0,050$), o que leva à rejeição de H_0 e indica a presença de tendência. No entanto, ao aplicar a primeira diferenciação, o p-valor aumentou para 0,5614 tanto para a série original quanto para a série ajustada. Como esse valor está acima do nível de significância de 5%, não há mais evidência estatística de tendência em ambas as séries, indicando que a diferenciação foi eficaz na remoção da tendência.

Já o teste de Fisher's G foi aplicado para verificar a existência de sazonalidade. A hipótese nula desse teste (H_0) assume que a série não possui sazonalidade significativa. Os p-valores obtidos foram 0,5009 para a série original e 0,4132 para a série ajustada, ambos superiores a 5%, não permitindo rejeitar H_0 . Dessa forma, não há indícios estatisticamente significativos de sazonalidade na série.

Com base nos resultados observados, consolida-se que a série não é estacionária, devido à presença de tendência, mas não apresenta comportamento sazonal significativo. Logo, para torná-la adequada para modelagem, será necessária pelo menos uma diferenciação, indicando que os modelos a serem ajustados devem seguir uma estrutura (p,1,q), onde d=1 representa a necessidade de diferenciação para remover a tendência e tornar a série estacionária.

Para observar os efeitos da diferenciação aplicada à série temporal da sinistralidade da seguradora Bradesco, foram gerados os gráficos das séries original e ajustada após a primeira diferenciação. A Figura 4.7.a apresenta a série original diferenciada, enquanto a Figura 4.7.b exibe a série ajustada após a mesma operação.




Figura 4.7: Séries original e ajustada após a primeira diferenciação.

Nesse quadro, as séries diferenciadas apresentam variações mais acentuadas ao longo do tempo e ausência de tendência aparente, o que reforça os resultados obtidos pelo teste de Cox-Stuart. Para verificar se a diferenciação foi eficaz na estabilização da média da série, foram analisadas as funções de autocorrelação (FAC) e autocorrelação parcial (FACp). As Figuras 4.8.a e 4.8.b exibem, respectivamente, a FAC e a FACp da série original após a aplicação da primeira diferença, enquanto as Figuras 4.9.a e 4.9.b apresentam os mesmos gráficos para a série ajustada. Observa-se que, em ambas as séries, a FAC demonstra um rápido decaimento e a FACp evidencia poucos lags significativos, sugerindo que a estrutura de dependência foi minimizada e que a série pode ser considerada estacionária após a diferenciação.

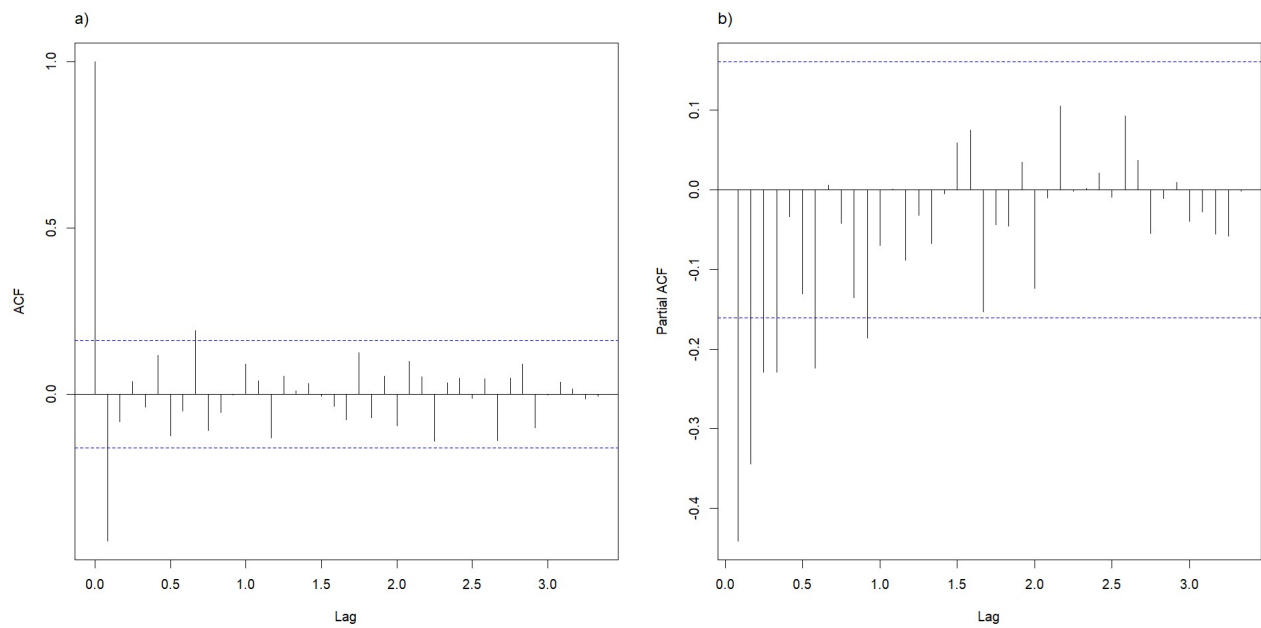


Figura 4.8: Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal original diferenciada.




Figura 4.9: Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACp) da série temporal ajustada diferenciada.

A FAC das séries diferenciadas, tanto para a série original quanto para a ajustada, apresenta um rápido decaimento ao longo das defasagens, confirmando a remoção da tendência após a diferenciação. Já a FACp exibe alguns lags significativos nas primeiras defasagens em ambas

as séries, sugerindo a presença de um componente autorregressivo. Após a verificação da estacionariedade das séries temporal original e ajustada da sinistralidade da seguradora Bradesco, foram estimados modelos SARIMA para ambas, com o objetivo de identificar as especificações que melhor descrevem a dinâmica da série, garantindo um ajuste adequado para a previsão.

A escolha dos modelos foi baseada nas análises realizadas anteriormente, incluindo a identificação da necessidade de diferenciação para garantir a estacionariedade da série e a avaliação da estrutura da autocorrelação. Além disso, a seleção final considerou a significância estatística dos coeficientes estimados, conforme apresentado na Tabela 4.2.

Tabela 4.2: Estimativas dos parâmetros dos modelos escolhidos da seguradora Bradesco para a série original e ajustada.

Série	Modelo	Parâmetro	Estimativa	Erro Padrão	p_valor
Original	SARIMA	θ_1	-0,9231	0,0278	0,0000
	(0,1,1)(0,0,1)₁₂	Θ_1	0,1662	0,0855	0,0519
	SARIMA	θ_1	-0,9242	0,0279	0,0000
	(0,1,1)(1,0,0)₁₂	Φ_1	0,1621	0,0862	0,0600
Ajustada	SARIMA	θ_1	-0,9110	0,0333	0,0000
	(0,1,1)(1,0,0)₁₂	Φ_1	0,2170	0,0830	0,0089
	SARIMA	θ_1	-0,9084	0,0333	0,0000
	(0,1,1)(0,0,1)₁₂	Θ_1	0,2081	0,0814	0,0106

Com o objetivo de avaliar e comparar o desempenho dos modelos ajustados, foram calculados os Critérios de Informação de Akaike (AIC) e Bayesiano (BIC), bem como métricas de erro preditivo, incluindo o Erro Percentual Absoluto Médio (MAPE) e o Erro Quadrático Médio (RMSE).

Em relação aos critérios sobreditos, AIC e BIC são utilizados para avaliar a qualidade dos modelos, penalizando a complexidade excessiva e auxiliando na escolha do modelo mais parcimonioso. Já as métricas MAPE e RMSE permitem verificar a precisão das previsões, sendo que valores menores indicam melhor desempenho preditivo. Visto isso, a Tabela 4.3 apresenta os valores dessas métricas para os modelos ajustados às séries original e ajustada.

Tabela 4.3: Critérios de avaliação dos modelos ajustados para a série de sinistralidade da seguradora Bradesco.

Série	Modelo	AIC	BIC	MAPE	RMSE
Original	SARIMA(0,1,1)(0,0,1) ₁₂	-311,9023	-302,8904	53,2159	0,0823
	SARIMA(0,1,1)(1,0,0) ₁₂	-311,7913	-302,7795	52,6868	0,0824
Ajustada	SARIMA(0,1,1)(1,0,0)₁₂	-402,5606	-393,5487	42,8157	0,0607
	SARIMA(0,1,1)(0,0,1) ₁₂	-402,1940	-393,1822	43,2369	0,0608

Com base nos resultados da Tabela 4.3, o modelo SARIMA(0,1,1)(1,0,0)₁₂ ajustado à série ajustada foi selecionado como o mais adequado para previsão da sinistralidade da seguradora Bradesco. Esse modelo apresentou os menores valores de MAPE e RMSE, indicando melhor desempenho preditivo.

Dessa forma, o ajuste prévio dos dados contribuiu para a melhoria da modelagem, permitindo que o modelo captasse melhor os padrões da série. Assim, o SARIMA(0,1,1)(1,0,0)₁₂ ajustado será utilizado para a previsão da sinistralidade.

Após a definição do modelo SARIMA(0,1,1)(1,0,0)₁₂, procedeu-se à validação por meio da análise dos resíduos, etapa fundamental para avaliar a adequação do ajuste. As Figuras 4.10.a e 4.10.b apresentam, respectivamente, os gráficos da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACp) dos resíduos do modelo. A ausência de picos significativos em ambas as funções sugere que não há estrutura de dependência temporal remanescente, indicando que o modelo foi eficaz em capturar a dinâmica da série. Esse resultado contribui para reforçar a robustez do modelo ajustado, validando sua utilização para fins preditivos.

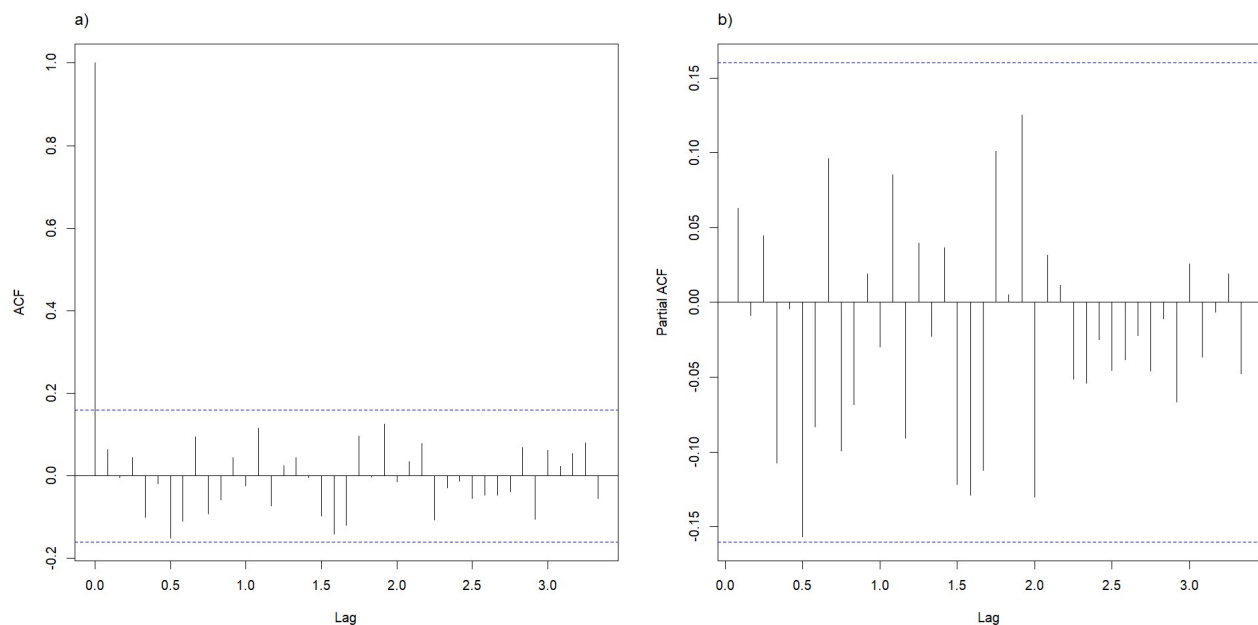


Figura 4.10: Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACp) dos resíduos do modelo selecionado para a seguradora Bradesco.

Além da análise gráfica, o teste de Box-Pierce foi aplicado para verificar a presença de autocorrelação nos resíduos. O p-valor obtido foi de 0,4416, superior ao nível de significância de 5%, indicando que não há evidências estatísticas de autocorrelação nos resíduos. O resultado analisado sugere que os resíduos do modelo podem ser caracterizados como ruído branco, ou seja, um processo aleatório sem padrões sistemáticos, o que confirma a adequação do modelo. Complementando essa avaliação, a Figura 4.11 apresenta o gráfico quantil-quantil dos resíduos, utilizado para analisar a normalidade da distribuição. A disposição dos pontos, próximos à reta de referência sugere que os resíduos seguem uma distribuição aproximadamente Normal,

um requisito importante para a validade das inferências do modelo. Diante dos dados obtidos, conclui-se que o modelo ajustado é adequado para a previsão da sinistralidade da seguradora Bradesco.




Figura 4.11: Gráfico quantil-quantil dos resíduos do modelo selecionado para a seguradora Bradesco.

A partir disso, com o modelo ajustado e validado, foram geradas previsões para a sinistralidade da seguradora Bradesco no período de julho/2024 a dezembro/2024. A Tabela 4.4 apresenta os valores reais, previstos e os erros absolutos para cada mês analisado.

Tabela 4.4: Valores Reais, Previstos e Erro Absoluto da Sinistralidade.

Mês/Ano	Valores Reais	Valores Previstos	Erro Absoluto
jul/24	0,1282	0,2476	0,1194
ago/24	0,0945	0,2527	0,1582
set/24	0,0317	0,2340	0,2023
out/24	0,2914	0,2692	0,0222
nov/24	0,1431	0,2692	0,1261
dez/24	0,1720	0,2539	0,0818

Para uma melhor visualização da aderência do modelo aos valores observados, a Figura 4.12 ilustra a comparação entre as séries real e prevista ao longo dos meses.




Figura 4.12: Comparação entre Valores Reais e Previstos da Sinistralidade da Seguradora Bradesco.

Em consonância com os resultados, o modelo conseguiu capturar a tendência geral da sinistralidade, embora tenha evidenciado discrepâncias em alguns meses. Nos primeiros três meses previstos (julho a setembro), houve uma superestimação da sinistralidade, com maior erro absoluto em setembro. Já nos meses seguintes, a previsão se aproximou mais dos valores reais, especialmente em outubro, onde o erro foi o menor do período analisado.

No geral, o modelo apresentou boa aderência à série, sendo mais preciso em períodos de menor variação. As discrepâncias podem ser atribuídas a oscilações atípicas da sinistralidade que não foram totalmente capturadas pelo modelo.

4.4 AJUSTE E PREVISÃO DA SÉRIE DE SINISTRALIDADE – PORTO SEGURO

Dando continuidade à análise da sinistralidade, procedeu-se à modelagem para a seguradora Porto Seguro, seguindo a mesma abordagem metodológica previamente aplicada à seguradora Bradesco. Foram realizadas análises exploratórias, avaliação da estacionariedade, aplicação de testes estatísticos e modelagem da série temporal. Os resultados indicaram que a série ajustada apresentou um desempenho superior em relação à original, permitindo um ajuste mais eficiente. Dessa forma, a apresentação dos resultados será direta, enfatizando as principais características da série ajustada e os modelos estimados, garantindo uma exposição objetiva e clara das análises conduzidas.

A avaliação da série temporal ajustada da sinistralidade da Porto Seguro, apresentada na

Figura 4.13, revela variações ao longo do tempo sem uma tendência bem definida. No entanto, observa-se a presença de oscilações cíclicas, sugerindo um possível comportamento sazonal.




Figura 4.13: Série Temporal Ajustada da Sinistralidade da Porto Seguro.

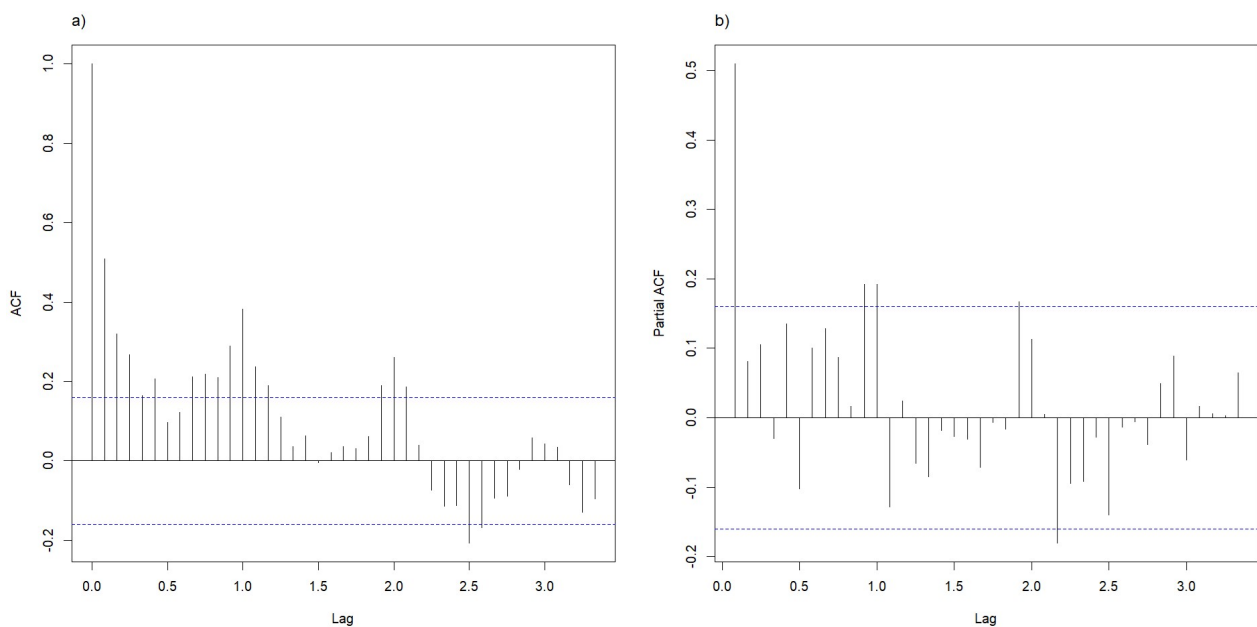


Figura 4.14: Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACp) da Série Ajustada da Porto Seguro.

Para compreender melhor a estrutura da dependência temporal, foram analisadas a função

de autocorrelação (FAC) e a função de autocorrelação parcial (FACp), cujos resultados estão na Figura 4.14, sendo a Figura 4.14.a referente à FAC e a Figura 4.14.b à FACp.

Destarte, para confirmar esse aspecto da série, foram aplicados os testes estatísticos de Cox-Stuart e Fisher's G. O teste de Cox-Stuart foi utilizado para avaliar a presença de tendência na série, e seu resultado apresentou um p-valor de 0,4887, acima do nível de significância de 5%, indicando que não há evidências estatísticas de uma tendência significativa. Já o teste de Fisher's G, que verifica a presença de sazonalidade, resultou em um p-valor inferior a 0,05, sugerindo que a série apresenta um comportamento sazonal que deve ser considerado na modelagem. Diante desses resultados, conclui-se que não há necessidade de diferenciação ($d = 0$), mas que a modelagem deve incorporar componentes sazonais (P,D,Q), além de possíveis termos autorregressivos (p) e de médias móveis (q), resultando em uma estrutura do tipo SARIMA(p,0,q)(P,D,Q)₁₂.

O gráfico de dispersão da média em relação ao desvio padrão, representada na Figura 4.15, complementa os testes realizados. A disposição aleatória dos pontos sugere que a série ajustada segue um comportamento aditivo, sem indícios de que a variabilidade dependa da média. Dessa forma, não há necessidade de transformações adicionais antes da modelagem, permitindo a aplicação direta dos modelos para previsão da sinistralidade.




Figura 4.15: Gráfico de Dispersão da Média pelo Desvio Padrão da Série Ajustada da Porto Seguro.

Dando sequência à modelagem da série ajustada da sinistralidade da seguradora Porto Seguro, foram estimados diferentes modelos SARIMA, ajustando os componentes sazonais e não sazonais para identificar a especificação mais adequada. A seleção dos modelos foi baseada na análise da FAC e FACp, nos testes estatísticos aplicados anteriormente e na significância dos coeficientes estimados, cujos resultados são apresentados na Tabela 4.5.

makecell

Tabela 4.5: Estimativas dos parâmetros dos modelos SARIMA testados.

Modelo	Parâmetro	Estimativa	Erro Padrão	p_valor
SARIMA(1,0,0)(1,0,2) ₁₂	ϕ_1	0,4607	0,0734	0,0000
	Φ_1	-0,6705	0,2248	0,0028
	Θ_1	1,0055	0,2378	0,0000
	Θ_2	0,3996	0,0946	0,0000
SARIMA(1,0,0)(0,0,2) ₁₂	ϕ_1	0,0479	5,9068	0,0000
	Θ_1	0,0870	3,6682	0,0024
	Θ_2	0,0818	2,8037	0,0050
SARIMA(1,0,0)(2,0,1) ₁₂	ϕ_1	0,4436	0,0758	0,0000
	Φ_1	-0,4451	0,1982	0,0247
	Φ_2	0,3787	0,0879	0,0000
	Θ_1	0,7613	0,2134	0,0003
SARIMA(1,0,0)(1,0,0) ₁₂	ϕ_1	0,4557	0,0741	0,0000
	Φ_1	0,3172	0,0805	0,0000

Em sequência, com o objetivo de determinar o modelo mais adequado para a seguradora Porto Seguro, foram observados na Tabela 4.6 os critérios de informação AIC e BIC, em conjunto com as métricas de erro MAPE e RMSE, o que viabiliza uma comparação objetiva entre as diferentes especificações estimadas.

Tabela 4.6: Critérios de avaliação dos modelos SARIMA testados.

Modelo	AIC	BIC	MAPE	RMSE
SARIMA (1,0,0)(1,0,2)₁₂	-390,1870	-372,1232	14,3865	0,0625
SARIMA (1,0,0)(0,0,2) ₁₂	-389,9314	-374,8782	14,5709	0,0633
SARIMA (1,0,0)(2,0,1) ₁₂	-389,8971	-371,8333	14,3391	0,0626
SARIMA (1,0,0)(1,0,0) ₁₂	-388,2797	-376,2372	14,7992	0,0642

O modelo **SARIMA(1,0,0)(1,0,2)₁₂** foi selecionado para a previsão da sinistralidade da seguradora Porto Seguro por apresentar o menor AIC, indicando o melhor ajuste aos dados em comparação com os demais modelos testados. Além disso, obteve o menor RMSE, demonstrando menor erro médio nas previsões, e o segundo menor MAPE, o que reforça sua boa precisão preditiva. Diante desses resultados, esse modelo equilibra um ajuste eficiente e uma capacidade preditiva robusta, sendo a escolha mais adequada para a análise.

Em sequência, após a seleção do modelo, a próxima etapa consiste na verificação da adequação dos resíduos, a fim de assegurar que os pressupostos da modelagem foram atendidos. A Figura 4.16.a apresenta a função de autocorrelação (FAC) dos resíduos, enquanto a Figura 4.16.b exibe a função de autocorrelação parcial (FACp).

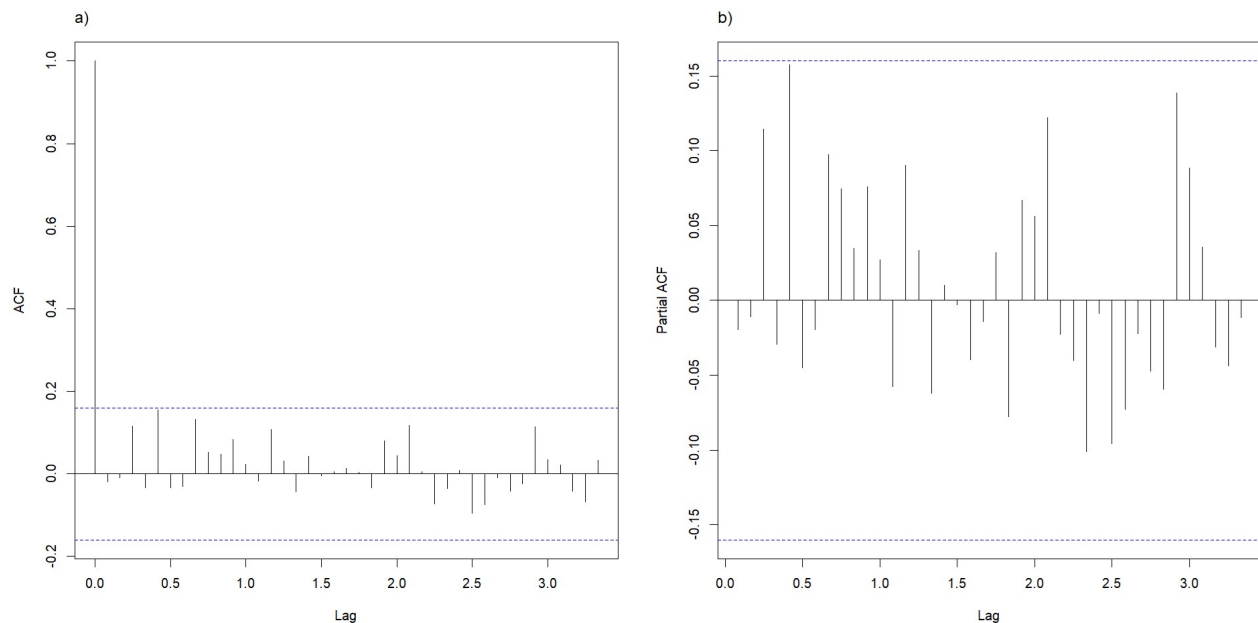


Figura 4.16: Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACp) dos resíduos do modelo selecionado para a seguradora Porto Seguro.

Os resultados da FAC mostram que os coeficientes não ultrapassam os limites de significância, indicando ausência de padrões estruturados e sugerindo que os resíduos não apresentam autocorrelação significativa. De maneira semelhante, a FACp não evidencia lags relevantes, reforçando a ideia de que o modelo capturou corretamente as relações temporais da série. Esses comportamentos sugerem que os resíduos seguem um padrão aleatório, caracterizando-se como ruído branco, o que valida a adequação do modelo para fins preditivos.

Para complementar essa análise, foi aplicado o teste de Box-Pierce aos resíduos, resultando em um p-valor de 0,8103. A hipótese nula (H_0) desse teste postula que os resíduos são independentes, ou seja, não apresentam autocorrelação significativa. Como o p-valor obtido é superior ao nível de significância de 5%, não há evidências estatísticas para rejeitar (H_0), indicando que os resíduos podem ser considerados como ruído branco.

Outra avaliação importante foi realizada por meio do gráfico quantil-quantil, ilustrado na Figura 4.17, que avalia se os resíduos apresentam comportamento condizente com um processo puramente aleatório. Como a maior parte dos pontos do gráfico permanece dentro da região de confiança, reforça-se a ausência de padrões estruturados nos resíduos, confirmando a adequação do modelo ajustado.




Figura 4.17: Gráfico quantil-quantil dos resíduos do modelo selecionado para a seguradora Porto Seguro.

Em virtude disso, os resultados obtidos evidenciam que o modelo é estatisticamente válido para previsão, dado que atende aos critérios fundamentais de modelagem de séries temporais. Com isso, foram geradas as previsões para a sinistralidade da seguradora Porto Seguro no período de julho a dezembro de 2024, permitindo avaliar sua capacidade de replicar a dinâmica observada na série. A Tabela 4.7 apresenta os valores reais e previstos para esse intervalo, bem como os erros absolutos de cada previsão, fornecendo uma medida da precisão do modelo.

Tabela 4.7: Valores Reais, Previstos e Erro Absoluto da Sinistralidade da seguradora Porto Seguro.

Mês/Ano	Valores Reais	Valores Previstos	Erro Absoluto
jul/24	0,3378	0,3460	0,0081
ago/24	0,3270	0,3742	0,0472
set/24	0,3515	0,3674	0,0158
out/24	0,4411	0,3730	0,0680
nov/24	0,3770	0,4262	0,0492
dez/24	0,3144	0,4291	0,1147

Com base nos dados expostos, a análise dos valores previstos em relação aos observados permite prever a capacidade do modelo em reproduzir a dinâmica da sinistralidade ao longo do período projetado. Assim, a Figura 4.18 ilustra essa comparação, evidenciando que o modelo

ajustado para a Porto Seguro conseguiu acompanhar com maior precisão as variações da série, especialmente nos meses iniciais da previsão.




Figura 4.18: Comparação entre Valores Reais e Previstos da Sinistralidade da Seguradora Porto Seguro.

Consequentemente, os resultados indicam que, de maneira geral, o modelo conseguiu representar bem a trajetória da sinistralidade ao longo do período analisado. A maioria das previsões apresentou erros absolutos relativamente baixos, sendo que apenas no mês de dezembro a discrepância ultrapassou 10%, refletindo uma maior dificuldade do modelo em capturar os padrões específicos desse período.

Ainda assim, a proximidade entre os valores reais e previstos sugere que a modelagem adotada é eficaz para antecipar variações na sinistralidade da seguradora Porto Seguro. Essa aderência reforça a confiabilidade do modelo para aplicações futuras, evidenciando que ajustes adequados podem contribuir para previsões mais consistentes e alinhadas à dinâmica da série histórica.

5. CONCLUSÕES

Este estudo avaliou a aplicação de modelos univariados de séries temporais na previsão da sinistralidade no ramo compreensivo residencial, utilizando dados mensais das seguradoras Bradesco Auto/RE e Porto Seguro. O uso de modelos SARIMA para séries temporais mostrou-se adequado para representar o comportamento histórico das séries e para construir previsões coerentes com as variações observadas ao longo do tempo.

Para a Bradesco, o modelo SARIMA(0,1,1)(1,0,0)₁₂ obteve resultados satisfatórios nas métricas de avaliação, com valores de MAPE e RMSE que demonstraram boa aderência ao comportamento histórico, apesar de maior variação nos primeiros meses do horizonte previsto. Já no caso da Porto Seguro, o modelo SARIMA(1,0,0)(1,0,2)₁₂ destacou-se por sua maior precisão estatística, com menor erro percentual médio absoluto e menor raiz do erro quadrático médio, refletindo uma modelagem mais aderente à dinâmica da série.

De modo geral, os resultados obtidos reforçam o papel dos modelos de séries temporais como instrumentos úteis para a análise e previsão de indicadores técnicos no setor segurador, contribuindo com subsídios quantitativos para a gestão atuarial e a definição de políticas de precificação e provisão.

Como continuidade para pesquisas futuras, recomenda-se a ampliação do escopo deste estudo, tanto em termos de seguradoras quanto de metodologia. A incorporação de modelos multivariados permitiria investigar a influência conjunta de variáveis operacionais e macroeconômicas sobre a sinistralidade, hipótese que pode trazer ganhos em capacidade explicativa e preditiva, a serem avaliados empiricamente [4]. Também se sugere a aplicação da abordagem proposta a outros ramos compreensivos, como o empresarial e o condominial, cujas estruturas de risco podem demandar estratégias específicas de modelagem e previsão.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Ahdesmäki, M., Fokianos, K. e Strimmer, K.: *GeneCycle: Identification of Periodically Expressed Genes – Reference Manual*, 2025. <https://cran.r-project.org/web/packages/GeneCycle/GeneCycle.pdf>, acessado em 12/03/2025.
- [2] Akaike, H.: *A new look at the statistical model identification*. IEEE Transactions on Automatic Control, 19(6):716–723, 1974.
- [3] Apólice, R.: *A história do seguro*, 2018. <https://revistaapolice.com.br/2018/10/a-historia-do-seguro/>, acessado em 11/01/2025.
- [4] Box, G. E. P., Jenkins, G. M., Reinsel, G. C. e Ljung, G. M.: *Time Series Analysis: Forecasting and Control*, vol. 1. Wiley, 5ª ed., 2015.
- [5] Brockwell, P. J. e Davis, R. A.: *Introduction to Time Series and Forecasting*. Springer, New York, 3ª ed., 2016.
- [6] Castiglione, L. R.: *Seguros: Conceitos e Critérios de Avaliação de Resultados*. Editora XYZ, São Paulo, 2015.
- [7] Chang, J.: *Análise de Variância em Séries Temporais*, 2013. <https://www.ime.usp.br/~chang/home/mae325/mae5871%20-%20Analise%20espectral%20de%20ST/aulas/aplicacao-ANOVA.pdf>, acessado em 2/01/2025.
- [8] Chatfield, C.: *The Analysis of Time Series: An Introduction*. CRC Press, Boca Raton, 6ª ed., 2003.
- [9] Cox, D. R. e Stuart, A.: *Some Quick Sign Tests for Trend in Location and Dispersion*. Biometrika, 42(1/2):80–95, 1955.
- [10] Fisher, R. A.: *Tests of Significance in Harmonic Analysis*. Proceedings of the Royal Society of London. Series A, 125(796), 1929.
- [11] Guedes-Vieira, M.: *Introdução aos Seguros*. Vida Económica, Lisboa, s.d., ISBN 978-972-788-XXXX.
- [12] Hothorn, T., Zeileis, A., Farebrother, R. W., Cummins, C., Millo, G. e Mitchell, D.: *lmtest: Testing Linear Regression Models*, 2025. <https://cran.r-project.org/package=lmtest>, acessado em 12/03/2025.

- [13] Hyndman, R. J., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., Koutsoyiannis, K., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E. e Yasmien, F.: *forecast: Forecasting Functions for Time Series and Linear Models*, 2025. <https://cran.r-project.org/package=forecast>, acessado em 12/03/2025.
- [14] Morettin, P. A. e Toloi, C. M. C.: *Análise de Séries Temporais: Modelos Lineares Univariados*, vol. 1. Editora Blucher, 3ª ed., 2018.
- [15] Pandolfi, A. S. e Gonçalves, J. N.: *Previsão da sinistralidade em seguros de vida utilizando modelos de séries temporais*. Revista ENIAC Pesquisa, 13(1), 2024. <https://doi.org/10.22567/rep.v13i1.961>, acessado em 11/01/2025.
- [16] RE, I. B.: *Sobre a Companhia*, 2025. <https://ri.irbre.com/a-companhia/sobre-a-companhia/>, acessado em 11/01/2025.
- [17] Schwarz, G. E.: *Estimating the dimension of a model*. The Annals of Statistics, 6(2):461–464, 1978.
- [18] Seguro, P.: *Empresas do Grupo Porto Seguro*, 2025. <https://www.portoseguro.com.br/institucional/sobre-a-porto-seguro/empresas-do-grupo>, acessado em 15/02/2025.
- [19] Seguros, I.: *Seguro Residencial Itaú com Porto Seguro*, 2025. <https://www.itaui.com.br/seguuros/residencial/porto-seguro>, acessado em 15/02/2025.
- [20] Seguros, Z.: *O que é subscrição? Entenda como funciona esse processo essencial para os seguros*, 2023. <https://www.zurich.com.br/blog/articles/2023/08/o-que-e-subscricao>, acessado em 21/01/2025.
- [21] Seguros Privados, C. N. de: *Resolução CNSP nº 416, de 20 de julho de 2021*, 2021. <https://www2.susep.gov.br/safe/scripts/bnweb/bnmapi.exe?router=upload/25061>, acessado em 09/03/2025.
- [22] Seguros Privados (SUSEP), S. de: *Guia de Orientação e Defesa do Segurado – 2ª Edição*, 2021. <https://www.gov.br/susep/pt-br/arquivos/arquivos-meu-futuro-seguro/acoes-educacionais/programa-educacao-em-seguuros/arquivos-pdf/guia-de-orientacao.pdf>, acessado em 11/01/2025.
- [23] Seguros Privados (SUSEP), S. de: *Estatísticas: Prêmios e Sinistros por Ramo*, 2025. <https://www2.susep.gov.br/menuestatistica/ses/premiosesinistros.aspx?id=54>, acessado em 11/01/2025.
- [24] Seguros Privados (SUSEP), S. de: *Seguro Compreensivo*, 2025. https://www.gov.br/susep/pt-br/copy_of_planos-e-produtos/seguuros/seguuro-compreensivo, acessado em 14/01/2025.

-
- [25] Seguros Privados (SUSEP), S. de: *Seguros Compreensivos*, 2025. https://www2.susep.gov.br/download/menuatendimento/Seguros_Compreensivos.pdf, acessado em 14/01/2025.
- [26] Wickham, H.: *ggplot2: Elegant Graphics for Data Analysis*, 2025. <https://ggplot2.tidyverse.org/>, acessado em 12/03/2025.