



FACULDADE DE CIÊNCIAS
Departamento de Matemática e Informática

Trabalho de Licenciatura em
Estatística

**Análise da Demanda ao Crédito Imobiliária com
Recurso aos Modelos de Box–Jenkins. Caso de estudo:
Moza Banco da Cidade de Maputo (2012 - 2020)**

Autor: Nelson Joaquim Gante

Maputo, Abril de 2024



FACULDADE DE CIÊNCIAS
Departamento de Matemática e Informática

Trabalho de Licenciatura em
Estatística

**Análise da Demanda ao Crédito Imobiliária com
Recurso aos Modelos de Box–Jenkins. Caso de estudo:
Moza Banco da Cidade de Maputo (2012 - 2020)**

Autor: Nelson Joaquim Gante

Supervisor: Zacarias Mutombene, MSc., UP

Maputo, Abril de 2024

Declaração de Honra

Declaro por minha honra, que o presente Trabalho de Licenciatura é resultado da minha investigação e que o processo foi concebido para ser submetido apenas para a obtenção do grau de Licenciado em Estatística, na faculdade de Ciências da Universidade Eduardo Mondlane.

Maputo, Abril de 2024

(Nelson Joaquim Gante)

Dedicatória

Dedico este trabalho aos meus pais, Joaquim Antônio Gante (em memória) e Felizarda Francisco Sendela Sengo Gante e ao meu tio Fernando Fanheiro que foi depois dos meus Pais o meu orientador nesta caminhada Estudantil e a minha maravilhosa família.

Agradecimentos

Agradecer ao nosso Deus por ter me guiado ate aqui dentro dos seus ensinamentos com saúde e sua proteção.

Agradecer ao meu Supervisor Doutor Zacarias Mutombene, pela disponibilidade, empenho e sua ricas orientações mesmo diante das suas enumeras funções, ocupações e actividades do dia dia, pois colaborou de forma incansável e incondicional para elaboração do presente trabalho.

Agradecer os meus pais mais uma vez Joaquim Antônio Gante (em memoria) e Felizarda Francisco Sendela Sengo Gante por terem sido sempre Pais presente na minha vida, por terem tido toda paciência, disciplina, dedicação e entrega para que pudessem ver me um dia formado na vida acadêmica.

Ao meu tio Fernando Fanheiro que me acompanhou nesta jornada com amor, dedicação atenção e orientação desde o inicio da minha vida estudantil.

As minhas tias Maria Francisco Sendela Sengo e Ana Francisco Sendela Sengo Abreu por sempre inculcaram na minha cabeça o valor de abraçar os estudos.

Agradecer ao corpo todo de Docentes do Departamento de Matemática e Informática (DMI), particularmente aos do curso de Licenciatura em Estatística pelo acompanhamento, atenção e ensinamentos prestados ao longo deste curso.

Agradecer a minha família em particular a minha esposa Ludimila Isabel Antônio Mafuiane Gante, aos meus filhos Djyunel Nelson Gante, Kyanga Ludimila Gante e Khael Nelson Gante por trazerem a minha vida a força de continuar a crescer em prol de uma vida sabia e orientada aos bons costumes.

Por fim a minha secretaria de casa Adelaide Fernando Matha que sempre esta do nosso a já mais de 10 anos com dedicação e empenho nas nossas vidas o que tranquilizou a minha mente para que pudesse ter suceso e foco para finalização deste trabalho acadêmico.

Muito obrigado...

Resumo

O presente trabalho de conclusão do Curso de licenciatura em Estatística, debruçou sobre o crédito ao consumo, concretamente o crédito imobiliário, onde foram descritos conceitos sobre o crédito e a respectiva finalidade. Todavia, usou-se uma das conceituadas técnicas da estatística, onde fez uma análise da tendência e previsão do crédito imobiliário na cidade de Maputo. A análise gráfica de previsão com flutuações (altas e baixas) mostram uma alta demanda para os meses de junho de ambos os anos (2012 e 2020) e baixas para os meses de agosto e outubro respectivamente, concluindo-se que as sazonalidades irão recair nestes períodos. Assim sendo, com base na análise gráfica da série, que foi confirmado pelo teste de raiz unitária, que constatou-se que a série em análise é não estacionária, por conseguinte, foi feita a transformação através das suas box-cox, que ajudou na remoção da variabilidade da série, o que fez com que esta se tornasse estacionária. Uma vez satisfeito esse pressuposto de estacionariedade e com auxílio da metodologia de Box–Jenkins, entre 22 modelos criados pela função `auto.arima()`, foi selecionado o modelo SARIMA(1,0,2)(0,0,1)[12], como o mais adequado para previsões, com o AIC = 173.312, e verificou-se ainda que, o MAPE do modelo foi de 21,32%. A previsão da demanda de crédito imobiliário dos clientes do Moza Banco da cidade de Maputo, para os próximos trinta e quatro meses. A relevância desta monografia deve-se ao facto de que irá auxiliar aos gestores bancários na elaboração de melhores estratégias para a gestão de crédito e minimizar os riscos de perdas de investimentos. Porém recomenda para uma actualização dos gestores bancários na matéria de uso de sistemas tecnológicos de gestão de crédito, bem como a redução das taxas do crédito que sufocam os jovens que pretendem adquirir um imóvel para começar o seu novo lar.

Palavras-chave: Crédito Imobiliário, Série temporal, Metodologias de Box – Jenkins, previsões.

Abstract

The present work to conclude the Degree Course in Statistics, focused on credit and consumption, specifically real estate credit, where we described concepts on credit and the respective purpose. However, we use one of the technical concepts of statistics, where we conduct an analysis of the trend and forecast of housing credit in the city of Maputo. The graphical analysis of forecast with fluctuations (highs and lows) shows a high demand for the months of June of both years (2012 and 2020) and lows for the months of August and October respectively, concluding that the seasonality does not recur in this period. Similarly, as based on the graphical analysis of the series, which was confirmed by the unit root test, it was found that the series in the analysis is not stationary, therefore, the transformation was performed through its box-cox, which helped the removal of this variation. stationary. Once this assumption of stationarity was satisfied and with the help of the Box–Jenkins methodology, among 22 models created by the `auto.arima()` function, the SARIMA(1,0,2)(0,0,1)[12] model was selected as the 7th most suitable. verified still that, the MAPE of the model was 21.32%. Forecasting the demand for real estate loans from Moza Bank customers in the city of Maputo, for the next thirty-four months. The relevance of this monograph is due to the fact that it will assist bank managers in developing better strategies for credit management and minimizing the risks of investment losses. We can recommend an update to two bank managers on the use of credit management technology systems, as well as reducing credit fees that suffocate young people who intend to acquire a mortgage to start their new Home.

Keywords: Real Estate Credit, Time series, Box – Jenkins methodologies, forecasts.

Abreviaturas

- ACF** - Função de autocorrelação
- ADF** - Augmented Dickey-Fuller test
- AIC** - Akaike Information Criterion
(Crítério de informação de Akaike)
- AIE** - Agência Internacional de Energia
- AR** - Auto-regressivos
- ARMA** - Auto-regressivos Médias Móveis
- ARIMA** - Auto-regressivos Integrado de Médias Móveis
- PACF** - Função de autocorrelação parcial
- PIB** - Produto Interno Bruto
- SARIMA** - Auto-regressivos Integrado de Médias Móveis com Sazonalidade
- MA** - Média Móvel
- MAPE** - Erro absoluto percentual médio
- PAE** - Programa de medidas de aceleração económica

Índice

1	Introdução	1
1.1	Contextualização	1
1.2	Definição do problema	2
1.3	Objectivos	2
1.3.1	Objectivo Geral	2
1.3.2	Objectivos Específicos	2
1.4	Justificação	3
1.5	Relevância	3
1.6	Estrutura do Trabalho	4
2	Revisão de literatura	5
2.1	Crédito imobiliário	5
2.1.1	Conceitos básicos sobre créditos	5
2.1.2	Etapas do Financiamento	7
2.1.3	A Importância do Financiamento da Habitação	7
2.2	Séries temporais	9
2.2.1	Análise no domínio do tempo	9
2.2.2	Análise no domínio de frequência	12
2.2.3	Componentes das Series Temporais	13
2.2.4	Estacionariedade	16
2.3	Modelos de séries temporais	18
2.3.1	Modelos Auto-regressivos (AR)	19
2.3.2	Modelos de médias móveis (MA)	19
2.3.3	Modelos autorregressivos de médias móveis (ARMA)	20
2.3.4	Modelo Autorregressivo integrado de médias móveis (ARIMA)	20
2.3.5	Extensão dos modelos ARIMA	21
2.4	Previsão	22
2.5	Adequação do modelo	23
2.5.1	Análise residual	23
2.5.2	Critérios para selecção do melhor modelo	24
2.5.3	Avaliação da precisão de previsão do modelo	25

2.6 Estudos relacionados	27
3 Material e Métodos	28
3.1 Material	28
3.2 Métodos	28
3.2.1 Transformação da série em estacionária	29
3.2.2 Teste de estacionariedade	29
3.2.3 Estágios de interação dos modelos Box & Jenkins	30
3.2.4 Diagnósticos do modelo estimado	31
4 Resultados e Discussão	33
4.1 Resultados	33
4.1.1 Descrição do crédito imobiliário do Moza banco	33
4.1.2 Identificação dos parâmetros do modelo adequado	35
4.1.3 Estimação e escolha do melhor modelo	36
4.1.4 Diagnóstico do modelo através dos resíduos	38
4.1.5 Análise da previsão do crédito imobiliário	40
4.2 Discussão	42
5 Conclusões e Recomendações	43
5.1 Conclusões	43
5.2 Recomendações	44
Anexos	48

Lista de Figuras

4.1	Evolução do crédito imobiliário na Cidade de Maputo	33
4.2	Representação da sazonalidade do crédito imobiliário	34
4.3	Representação do crédito imobiliário depois de transformada	35
4.4	Resíduos do modelo SARIMA estimado	38
4.5	Previsão do crédito imobiliário	40
5.1	Representação do crédito imobiliário sem transformação	48
5.2	Sazonalidade do crédito imobiliário sem transformação	48
5.3	Sazonalidade mensal das 1ª diferenças do Crédito	49

Lista de Tabelas

4.1	Teste de ADF do crédito imobiliário	34
4.2	Teste de ADF do Crédito imobiliário depois de Cox-Box	35
4.3	Modelos ARIMA estimados	36
4.4	Coefficientes estimados pelo modelo escolhido	37
4.5	Medidas dos erros estimados através dos coeficientes	37
4.6	Resultado do Teste de Jarque-Bera	38
4.7	Resultado do Teste de Box-Pierce dos resíduos	39
4.8	Resultado do Teste de Ljung-Box dos resíduos	39
4.9	Valores do Crédito previstos e observados	41
5.1	Crédito imobiliário	52

Capítulo 1

Introdução

1.1 Contextualização

O crédito ao consumo é uma actividade econômica de extrema importância na conjuntura social da humanidade porque alavanca a procura de bens de consumo e de serviços, de investimento, produção e emprego gerando mais receitas ao Estado por via do aumento das contribuições sociais e dos impostos indirectos resultantes do aumento do poder de compra. (Nunes, 2016). Por sua vez, o crédito imobiliário também é uma peça central no processo de desenvolvimento econômico, pois, financiar o cidadão a adquirir imóveis é apoiar a construção do patrimônio de uma nação. Entretanto, quando todas as atenções estão voltadas para a abertura de uma fase de crescimento sustentado, o estabelecimento de condições para a expansão de todas as formas de financiamento de longo prazo aparece como uma tarefa natural e premente.

O crescimento das cidades, nas primeiras décadas do século 20, ao mesmo tempo em que atendeu ao aumento da demanda por mão-de-obra, deu-se de maneira pouco organizada no que diz respeito à tarefa de alojar essa população e criar a infra-estrutura urbana necessária. A solução espontânea para esse rápido crescimento demográfico nas cidades foi a “habitação coletiva” – mais de uma família compartilhando o mesmo teto ou o mesmo terreno. Sendo que, para responder essa necessidade que a sociedade tem de obter residências próprias, o Moza banco que vem engajando se em resolver as preocupações relacionadas com a habitação, disponibiliza aos clientes o crédito imobiliária, que ajuda a resolver assuntos relacionados os de habitação.

Uma serie temporal é um conjunto de observações feitas sequencialmente ao longo do tempo. A característica mais importante deste tipo de dados e que as observações vizinhas têm dependência e estamos interessados em analisar e modelar esta dependência. Enquanto em modelos de regressão por exemplo a ordem das observações e irrelevante para a análise, em series temporais a ordem dos dados e crucial. Vale notar que o tempo pode ser substituído por outra variável como espaço, profundidade, etc. (Ehlers, 2005).

Assim sendo, surge uma crescente necessidade de obter mais informações econômico financeiras, com destaque a série da demanda do crédito imobiliário, por parte dos gestores bancários. Entretanto, no presente estudo, foi utilizada a metodologia de Box-Jenkins para analisar a série da demanda ao crédito imobiliário, onde vai se descrever o comportamento, estimar o modelo adequado e fazer a previsão da demanda do crédito imobiliário do Moza Banco no horizonte temporal compreendido entre janeiro de 2012 até dezembro de 2020, na cidade de Maputo.

1.2 Definição do problema

O recurso ao crédito é uma realidade irredundante numa sociedade de consumo, não obstante a consideração dos riscos de incumprimento inerentes ao consumidor. Os agentes bancários no dia pós dia das suas actividades tem se deparado com problemas de créditos mal parados gerando prejuízos avultados as respectivas instituições, deste modo, surge a necessidade por parte dos agentes aprimorar um método de previsão que seja consistente e fiável de modos a minimizar os riscos de perdas nos processos de concessão de crédito. A escolha do melhor método de previsão baseado no histórico dos dados seriais disponíveis nas instituições e o escopo desta proposta de trabalho de licenciatura.

Deste modo, com base no exposto acima, surge a seguinte pergunta de pesquisa: **Qual é o melhor modelo de previsão da serie de demanda de crédito imobiliário no Moza Banco da cidade de Maputo para o próximo período de 34 meses subsequentes?**

1.3 Objectivos

Para que o presente estudo pudesse ser realizado, foi necessário definir alguns objectivos com vista a delimitar a área por investigar, nesse contexto, neste estudo foram definidos os seguintes objectivos.

1.3.1 Objectivo Geral

Analisar a série temporal da demanda ao Crédito Imobiliária com Recurso aos Modelos de Box-Jenkins. Caso de estudo: Moza Banco da cidade de Maputo no período 2012 à 2020.

1.3.2 Objectivos Específicos

- Descrever o comportamento da série da demanda ao Crédito Imobiliária dos clientes do Moza Banco da cidade de Maputo no período 2012 - 2020;

- Aplicar o metodologia de Box – Jenkins para identificar um modelo que melhor se ajuste aos dados da série em análise;
- Prever a demanda de crédito imobiliário dos clientes do Moza banco na cidade de Maputo, para o período de janeiro de 2022 a Outubro de 2024.

1.4 Justificação

A vida dos moçambicanos tornou-se insustentável, pois, os seus salários ou a renda por si gerada graças ao esforço diário não satisfazem as actuais necessidades do cidadão moçambicano, visto que, os preços de quase todos os bens e serviços subiram, impossibilitando assim, o poder de compra e de aquisição de imoves de habitação e outros, é por isso que neste estudo, foram feitas análises da série temporal com objectivo de descrever a tendência do crédito imobiliário dos clientes do Moza banco da cidade de Maputo e investigar o mecanismo gerador dessa série com vista a fazer previsão do crédito imobiliário a ser disponibilizado no futuro, afinal só assim poderão ser desencadeadas estratégias ou políticas que possam ajudar na verificação do crédito imobiliário disponível para ajudar a mitigar o custo de vida dos moçambicanos.

Com base neste relatório, tanto o autor com os leitores, poderão ter mais conhecimento sobre o estado actual do crédito imobiliário na sociedade e também vão poder ter uma contribuição significativa em relação a aplicação dos modelos das séries temporais, podendo assim, este estudo contribuir para o desempenho académicos dos estudantes que tiverem acesso ao estudo.

1.5 Relevância

A relevância deste tema reside no facto de que proporciona a realização de previsões de valores futuros da série de crédito imobiliário, ou seja, prevê o que vai acontecer no futuro, e para o caso específico, trata de prever como vai ser a demanda de crédito imobiliário nos próximos 34 meses no banco Moza. Contudo, esta informação é importante para uma melhor preparação dos agentes bancários na sua tomada de decisão que conseqüentemente irá minimizar o riscos de perdas de valores financeiros.

1.6 Estrutura do Trabalho

O presente estudo é constituído por cinco capítulos, dos quais, foram descritos os conteúdos que serão abordados em cada capítulo que passam se a apresentar:

- **Capítulo I:** Composto pela Introdução, justificativa, delimitação e formulação da pergunta de partida; Objectivos da investigação; questões de investigação subjacentes aos objectivos; clarificação da pertinência teórica e prática da investigação;
- **Capítulo II:** em que apresenta-se a revisão da literatura, onde é feito o levantamento de conceitos gerais dos diversos autores com objectivo de sustentar mais ainda o tema em análise;
- **Capítulo III:** Com informações sobre o material e métodos que foram usados para o desenvolvimento da Investigação;
- **Capítulo IV:** Apresentação dos Resultados da Pesquisa, aqui a autor do trabalho fez uma apreciação detalhada da série temporal em análise, de modo a perceber o seu comportamento e produziu informações para sustentar os elementos que respondem os objectivos da pesquisa;
- **Capítulo V:** que compreende as conclusões e discussões, aqui foram arroladas as principais conclusões e confrontados resultados de outros estudos relacionados com esse, baseado no conjunto de resultados e suas interpretações e comparações;

O resto das secções que vem depois do Capítulo V, são considerados conteúdos pós-textuais e compreendem todas referências bibliográficas utilizadas para o desenvolvimento do estudo e os anexos de informações que não foram colocados no corpo do trabalho.

Capítulo 2

Revisão de literatura

Neste capítulo foram abordados aspectos relacionados com a temática abordada, desde o crédito imobiliário, a sua demanda e a técnica estatística usada para fazer a análise, este último compreende os modelos Box-Jenkins e os testes realizado para a sua execução.

2.1 Crédito imobiliário

O mercado imobiliário é visto como um investimento de baixo risco e alto retorno. No entanto, é uma categoria de mercado vulnerável, pois o financiamento é a principal fonte de endividamento dos investidores. Se comparado a outras categorias de mercados, o mercado imobiliário é um dos mais complexos porque possui características distintas quando comparadas aos demais bens de consumo.

2.1.1 Conceitos básicos sobre créditos

A palavra crédito tem suas origens no termo do latim *creditum* que significa ter acreditado ou acreditar (Thomas, 2009). Ao associar o termo do latim *creditum* ao significado financeiro de crédito, Thomas (2009) afirmou que, durante 4.000 anos as pessoas acreditaram umas nas outras, emprestando entre si dinheiro ou bens.

Segundo Nunes (2016), o **Crédito ao Consumo** é um tipo específico de crédito pessoal em que um instituição financeira especializada disponibiliza a um particular os montantes necessários para a aquisição de bens de consumo e de serviços pessoais. A finalidade do financiamento está ao critério de cada cliente, mas deve ser anunciado previamente ao banco. A título de exemplo, o crédito ao consumo pode ter as seguintes finalidades:

1. Compra de electrodomésticos e mobiliário;
2. Pagamento de despesas inesperadas e imprevisíveis;
3. Custear a formação académica ou profissional;
4. Pagamento de despesas de casamento;
5. Despesas de viagem, dentre outros.

O **crédito imobiliário** é a linha de Crédito do banco comercial para aquisição de imóveis residenciais, comerciais e lotes urbanos, ou término de construção de imóveis residenciais. Neste tipo de crédito podem ser feitas as seguintes operações:

- **Aquisição simples de imóvel novo ou usado:** Operação em que o Bradesco concede financiamento para complementar os recursos necessários para aquisição de imóvel residencial ou comercial;
- **Repasse Plano Empresário:** Nessa operação, concede-se financiamento aos clientes que desejam adquirir unidades de um empreendimento financiado pelo próprio Banco;
- **Término de Construção Isolada – Mutuário final Pessoa física:** Financiamento para término da construção de imóvel residencial, para clientes com escritura definitiva do terreno, livre de ônus e com, no mínimo, 30% dos serviços executados na obra, devendo o financiamento cobrir 100% do custo faltante;
- **Aquisição à vista com FGTS:** Operação em que o Bradesco faz a intermediação dos saques dos recursos do FGTS para a aquisição de imóvel residencial, observando as regras para utilização desses recursos;
- **Transferência de Dívida:** Operação em que o Bradesco concede financiamento da dívida de um contrato existente (refinancia), do actual devedor para um novo proponente. A transferência de dívida está condicionada à aprovação do crédito e taxa, da mesma forma que um novo financiamento;
- **Revenda de Imóveis do Banco Bradesco S.A.:** Operação em que o Bradesco concede financiamento para complementar os recursos necessários para aquisição de imóvel residencial ou comercial de sua propriedade, vendido por meio de leilão ou de forma directa;
- **Aquisição de Lote urbano (Terreno):** Operação em que o Bradesco concede financiamento para aquisição de Lote urbano, com infraestrutura completa, deve ser para fins residenciais, e o mesmo pode ser individual ou pertencer a loteamento devidamente regularizado.

Cédula de Crédito Imobiliário (CCI) é Disciplinada pela Lei 10.931/2004, a CCI nada mais é do que uma cédula que representa um crédito imobiliário. Por mais simples ela reza o artigo 18 da referida lei, que diz: **Art. 18.** É instituída a Cédula de Crédito Imobiliário - CCI para representar créditos imobiliários. Com efeito, a CCI é um documento representativo que transforma o crédito imobiliário de origem em um título circulável, contendo, em seu corpo, determinadas informações a respeito do instrumento que originou o crédito que se pretende representar. De salientar que, no CCI existem diversas informações que devem, obrigatoriamente, constar da cédula, como a qualificação do devedor e do credor, o valor do crédito, a data de vencimento, dentre outros.

2.1.2 Etapas do Financiamento

Geralmente para adquirir algum financiamento ou crédito é necessário que sejam acautelados algumas aspectos ou etapas que passa-se a apresentar:

1. Análise de Crédito

A primeira etapa do financiamento é a análise de crédito. Onde o cliente poderá ser submetido a uma simulação e enviada a proposta através do site da instituição ou estão um impresso dado pela agência;

2. Avaliação do Imóvel

Após aprovação do Crédito é necessário avaliar o imóvel objecto da garantia. Nesta etapa, você será contactado por um especialista em Crédito Imobiliário do Bradesco para apresentação e pre-start esclarecimentos sobre os documentos da 2^a etapa de contratação. Para agendamento da vistoria no imóvel, você receberá contato de uma empresa credenciada Bradesco, especializada em avaliação de imóveis;

3. Análise Jurídica

Você deverá fornecer os documentos relacionados a 2^a etapa, para análise jurídica e confecção do contrato. Após ter se feito a revisão dos documentos, passa-se a etapa seguinte que consiste na assinatura do contrato;

4. Assinatura Contrato

Nesta etapa, seu Gerente de Conta agendará uma data para assinatura do contrato de financiamento. Todos os participantes deverão estar presentes neste momento;

5. Registro do Contrato em Cartório

Você deverá levar as vias do contrato ao Cartório de Registro de Imóveis para registro. Deverá ser entregue ao seu Gerente de Conta uma via do contrato registrado e a matrícula original atualizada para que seja efetuado a liberação dos recursos ao vendedor.

2.1.3 A Importância do Financiamento da Habitação

As experiências de outros países têm indicado que a construção de habitação é um dos principais contributos para o crescimento económico (Green, 1997). Graças a este impacto, a promoção da habitação e a concessão de recursos financeiros têm um impacto directo na redução da pobreza e na criação de emprego pouco qualificado. O financiamento da habitação contribui para o crescimento económico nas quatro formas seguintes:

- Tornando o financiamento da habitação mais acessível a mais famílias de rendimento médio, as reformas podem mobilizar poupanças dormentes e gerar novas poupanças. Este efeito é particularmente importante para Moçambique, onde a taxa de poupança interna tende a ser baixa;
- As reformas no financiamento da habitação podem criar novo investimento e riqueza. Como o financiamento da habitação exige uma infra-estrutura administrativa e legal robusta para a gestão dos direitos de propriedade, pode ser uma ocasião excelente para se formalizarem os direitos de propriedade, básicos para a criação de riqueza. Ao receberem um título de propriedade legal, os proprietários podem acrescentar valor aos seus bens, dá-los como garantia e vendê-los por valores mais altos;
- Ao disponibilizar recursos, com base no mercado, às famílias de rendimento médio, o governo disporá de mais recursos para programas de habitação social para as populações urbanas mais pobres. Ao mesmo tempo, o desenvolvimento de financiamento da habitação comportável iria responder às necessidades da classe média crescente de Moçambique e alargar o acesso aos serviços bancários a uma percentagem da sociedade muito maior;
- Como o financiamento da habitação é uma actividade de longo prazo e, em princípio, de baixo risco, a sua evolução pode trazer estabilidade ao sistema bancário e ampliar o espectro de veículos de investimento existentes para o mercado de capital, aprofundando assim aquele mercado.

2.2 Séries temporais

Segundo Morettin e Tolo (2004), uma série temporal (ou série histórica/cronológica) constitui-se por um conjunto de observações registradas de forma ordenada em intervalos de instantes sucessivos. O objetivo primário da análise de séries temporais é estudar o comportamento passado das variáveis envolvidas, visando o entendimento do seu comportamento e, desta forma, possibilitando previsões sob o menor erro possível (Fonseca *et al.*, 1985).

Segundo Souza e Camargo (1996), estudar modelos de séries temporais significa buscar obter meios capazes de inferir ou generalizar as características do seu projecto gerador, bem como buscar modelos estocásticos que sejam capazes de descrever as situações particulares que ocorrem na realidade. Uma série temporal define-se como o conjunto de observações feitas em períodos sucessivos de tempo, durante um determinado intervalo e caracteriza-se sendo:

Série discreta: $Y_t, \quad t = \{1, 2, 3, \dots, n\}$

Série contínua: $Y_{(t)}, \quad t \in T \subseteq R$

Segundo Kirchner (2006), na análise de séries temporais, basicamente, existem dos enfoques básicos que o analista pode seguir: a análise no domínio do tempo e no domínio da frequência. Ambos têm como objectivo construir modelos para as séries com os propósitos determinados.

2.2.1 Análise no domínio do tempo

Nesta análise, considera-se a evolução temporal, ou seja, mede-se a magnitude do evento que ocorre em determinado tempo. Quando esta análise é baseada em um modelo paramétrico, utiliza as funções de autocorrelação e autocovariância (Souza e Camargo, 1996).

A função de autocovariância é a própria covariância entre o Y_t que é o valor variável no instante t e o Y_{t+k} , que é o seu valor separado por k intervalos de tempo, essa função pode ser definida pela seguinte forma:

$$\gamma_k = Cov[Y_t, Y_{t+k}] = E \{ [Y_t - \mu][Y_{t+k} - \mu] \} \quad (2.1)$$

Onde:

μ é a média do processo.

Segundo Kirchner (2006), a autocorrelação (ρ_k) é a autocovariância padronizada que serve para medir o comprimento e a memória de um processo, ou seja, a extensão para qual o valor tomado no tempo t , depende daquele tomado no tempo $t-k$. A autocorrelação de defasagem k é definida como:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{Cov[Y_t, Y_{t+k}]}{\sqrt{Var(Y_t)Var(Y_{t+k})}} \quad (2.2)$$

Usando a regra de Cramer para $k = \{1, 2, \dots, k\}$, tem-se:

$$\begin{aligned} \phi_{11} &= \rho_1; & \phi_{22} &= \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} \\ \phi_{33} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} \\ \phi_{kk} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}} \end{aligned} \quad (2.8)$$

A função de autocorrelação parcial amostral $\hat{\phi}_{kk}$ é obtida substituindo ρ_i por $\hat{\rho}_i$ em (2.8), ao invés de se calcular os determinantes para valores grandes de k , usa-se um método recursivo com $\hat{\phi}_{11} = \hat{\rho}_1$ para obter o valor de $\hat{\phi}_{kk}$, como ilustram as equações que se seguem:

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.9)$$

e também:

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, \quad j = \{1, 2, \dots, k\} \quad (2.10)$$

Para obter os valores de $\hat{\phi}_{kk}$ usando o método descrito acima, apenas sob a hipótese de um processo de ruído branco, onde a variância de $\hat{\phi}_{kk}$ pode ser aproximada por:

$$\text{Var}(\hat{\phi}_{kk}) \cong \frac{1}{n} \quad (2.11)$$

Deste modo, $\pm \frac{2}{\sqrt{n}}$ pode ser usado como limites críticos de ϕ_{kk} para o teste de hipótese de um processo de ruído branco.

2.2.2 Análise no domínio de frequência

Na análise do domínio da frequência, procura se identificar a periodicidade existente em uma série temporal. Esta forma de procedimento é empregada quando os componentes harmônicos da série têm um significado físico ou efeitos práticos do processo são analisados por suas componentes de frequência, logo, os mesmos são mais convenientes para sua representação.

Segundo Kirchner (2006), a função empregada neste caso é a densidade espectral, sendo que, a mesma visa estabelecer as propriedades de um processo estocástico em termos de frequência. logo, a verificação das periodicidades que por acaso existem em uma série temporal, podendo se realizar com o auxílio da análise espectral.

Para uma série $Y_t(t = 0, \pm 1, \pm 2, \dots)$ representado um processo estacionários com a função de autocovariância finita, e o seu espectro é definido por:

$$f(w) = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \rho_k e^{-jwk} \quad -\pi \leq w \leq \pi, \quad (2.12)$$

$$\rho_k = \sum_{k=-\infty}^{\infty} f(w) \cdot e^{-jwk} \quad k = 0, \pm 1, \pm 2, \dots \quad (2.13)$$

Onde:

- ρ_k - Autocorrelação na defasagem k;
- $f(w)$ - Densidade espectral;
- w - Frequências em radianos.

A função de densidade normalizada é a transformada de Fourier da função de autocorrelação. A variância de Y_t é uma medida da "Potência total do processo", e a função de densidade espectral representa a contribuição para a "Potência total" de todos os componentes de frequências presentes no processo.

Para Wanke e Julianelli (2006), uma serie temporal consiste em dados colectados, armazenados ou observados em sucessivos incrementos de tempo. Sendo que, os principais objectivos da análise de séries temporais são:

- Descrever o comportamento da série de dados por meio de cálculos estatísticos e da representação gráfica da série;
- Identificar o processo gerador da série;
- Estimar valores futuros da série temporal e;
- Monitorar os valores da série a fim de verificar alterações nas características da mesma.

Para uma boa análise, faz-se necessário o entendimento do comportamento de uma série temporal, motivo da importância da utilização de ferramentas gráficas, que facilitam o estabelecimento dos seus componentes (Shafer e Meredith, 1998).

2.2.3 Componentes das Series Temporais

As séries temporais podem apresentar algumas componentes que caracterizam seu comportamento. Segundo (Morettin e Tolo, 2004), pode-se entender a tendência (T) como o movimento persistente nos dados em uma dada direção e a sazonalidade (S) como o comportamento regular assumido pela série em algum sub-período. O erro aleatório (ϵ) leva em consideração movimentos esporádicos e irregulares presentes na série.

Segundo Wanke e Julianelli (2006) as técnicas de serie temporais são baseadas na identificação de padrões existentes nos dados históricos para posterior utilização no cálculo do valor previsto. Assim, todas essas técnicas consideram uma ou mais das cinco principais componentes de series temporais:

- **Nível (μ_t):** representa o comportamento das vendas caso não existisse nenhuma outra componente. Geralmente, o nível é simplesmente o ponto inicial de uma série de vendas;
- **Tendência (T_t):** componente que representa o crescimento ou declínio de uma serie no médio ou longo prazo;
- **Sazonalidade (S_t):** componente que representa um comportamento periódico de curto ou médio prazo;
- **Ciclo:** semelhante a sazonalidade mas reflete as flutuações ocorridas no longo prazo, sendo repetidas a cada três, quatro ou mais anos. Geralmente, esta componente é afectada pelas variações econômicas das nações;
- **Aleatoriedade (ϵ_t):** as demais variações, não explicadas pela tendência, ciclo e sazonalidade, são denominadas variações aleatórias. Estas são causadas principalmente por eventos particulares e não recorrentes. Um erro é dito ruído branco quando possui distribuição normal, a média de seus componentes é zero e a variância constante, a esses, são não-correlacionados indicando.

Sazonalidade

Em grande número de séries temporais, principalmente em Economia, é comum o aparecimento de algum comportamento cíclico de curto prazo (de até um ano), chamado de sazonalidade. Em vista disso, para um tratamento completo sobre séries de tempo, torna-se necessário caracterizar e eliminar essa função cíclica do tempo para se obter a condição de estacionariedade.

Sazonalidade significa uma tendência de repetição de um determinado comportamento da variável que ocorre com certa regularidade no tempo. Séries sazonais são, então, aquelas séries que apresentam variações similares de um espaço de tempo a outro, caracterizando-se por mostrarem alta correlação serial entre observações da variável distanciadas pelo período da sazonalidade, além, é claro, da correlação serial existente entre observações próximas.

Em modelos aditivos e multiplicativos, variações sazonais são representadas pelos índices sazonais ou fatores sazonais (um para cada período em que o ano é dividido). Os índices sazonais modificam a tendência ao serem somados (modelo aditivo) ou multiplicados (modelo multiplicativo) por esta. Em relação aos modelos, é importante destacar:

- **Modelo aditivo:**

Quando todos os índices são próximos ou exatamente iguais a zero, as componentes sazonais parecem não exercer grande efeito sobre a série; já quando os índices são substancialmente diferentes de zero, tanto positivos como negativos, o valor da tendência será modificado por eles, indicando influência das componentes sazonais na série.

Segundo Morettin e Toloi (1987), para ajustar uma série temporal para a componente sazonal é necessário estimar S_t e subtrair a série estimada do modelo Z_t .

$$Z_t = T_t + S_t + \varepsilon_t, \quad t = 1, 2, \dots, N \quad (2.14)$$

Assim sendo, o procedimento de ajuste sazonal consiste em:

- Obter estimativas \hat{S}_t do parâmetro S_t ;
- Calcular: $Z_t^{SA} = Z_t - \hat{S}_t$, em caso do modelo aditivo.

- **Modelo multiplicativo:**

Quando todos os índices sazonais são aproximadamente iguais a 1, as componentes sazonais parecem não exercer grande efeito sobre a série; quando os índices são substancialmente diferentes de 1, pelo menos 5% acima ou abaixo em alguns dos meses ou trimestres, o valor da tendência será modificado por eles, indicando que as componentes sazonais afetam a série. Desta forma, se o modelo ajustado for multiplicativo, como descrito em:

$$Z_t = T_t \times S_t \times \varepsilon_t, \quad t = 1, 2, \dots, N \quad (2.15)$$

A série sazonal ajustada será: $Z_t^{SA} = \frac{Z_t}{\hat{S}_t}$, ao se estimar em geral comete-se um erro de ajustamento sazonal, dado por:

$$\delta_t = S_t - \hat{S}_t \quad t = 1, 2, \dots, N \quad (2.16)$$

Segundo Morettin e Tolo (1987), as componentes são, em geral, bastantes relacionadas e a influencia da tendência sobre a componente sazonal pode ser muito forte, por duas razões:

- Métodos de estimação de S_t podem ser bastante afectados se não levar em conta a tendência;
- A especificação de S_t depende da especificação de T_t .

Por isso, não pode-se isolar uma das componentes sem tentar fazer o mesmo com a outra, e neste estudo vai se destacar a percepção da sazonalidade.

Tendência

A tendência descreve o comportamento da variável retratada na série temporal no longo prazo. Há três objetivos básicos na sua identificação: avaliar o seu comportamento para utilizá-lo em previsões, removê-la da série para facilitar a visualização das outras componentes, ou ainda identificar o nível da série (o valor ou faixa típica de valores que a variável pode assumir, se não for observado comportamento crescente ou decrescente no longo prazo). A obtenção da tendência pode ser feita de três formas: através de um modelo de regressão (como o modelo linear - reta), através de médias móveis, ou através de ajuste exponencial (que não deixa de ser uma média móvel).

O procedimento é semelhante ao usado na regressão linear simples, mas agora a variável independente é descrita pelo tempo. Para uma série registrada anualmente, por exemplo, de 2005 a 2014, para uma série registrada mensalmente, por exemplo, com 60 meses, a variável independente poderia assumir os valores de 1 a 60. As equações podem ser as mesmas usadas anteriormente (a estimativa do valor da série, Y , é denotada como \hat{Y}), e que também podem ter seus coeficientes obtidos por aplicativos computacionais:

- Linear (recta) - $T = \beta \times t + \alpha$;
- Polinômio de segundo grau - $T = c \times t^2 + \beta \times t + \alpha$;
- Logarítmica - $T = \beta \times \ln(t) + \alpha$;
- Potência - $T = \beta \times t^2$;
- Exponencial - $T = \beta \times e^{\alpha \times t}$

Onde:

T - é o valor da tendência;

t - é o valor do tempo;

no caso linear β é o coeficiente angular da recta (se positivo indica tendência crescente, se negativo a tendência é decrescente) e α é o coeficiente linear da recta.

As equações dos coeficientes estão expressas a seguir

$$\beta = \frac{n \times \sum_{i=1}^n (t_i \times Y_i) - \sum_{i=1}^n t_i \times \sum_{i=1}^n Y_i}{n \times \sum_{i=1}^n (t_i^2) - \left(\sum_{i=1}^n t_i \right)^2} \quad \alpha = \frac{\sum_{i=1}^n Y_i - \beta \sum_{i=1}^n t_i}{n}$$

Onde:

Y_i é um valor qualquer da variável registrada na série temporal, t_i é o período associado a Y_i , e n é o número de períodos da série. Para encontrar os coeficientes basta calcular os somatórios (tal como em análise de regressão linear simples).

2.2.4 Estacionariedade

Um dos conceitos mais importantes da econometria de séries temporais é o da estacionariedade. Para se trabalhar com séries temporais é importante que as variáveis sejam estacionárias ou passíveis de sua estacionariedade. Essa característica é fundamental para previsão do futuro com base na regressão de séries temporais, solidificando a premissa de que o futuro se comportará de acordo com o passado. Segundo Stock e Watson (2004) para uma série de dados ser estacionária suas variáveis não podem apresentar tendências e devem estar estáveis ao longo do tempo, só assim diz-se que essa série é estacionário.

Assim, como primeira tarefa a ser realizada no trabalho é a verificação quanto à estacionariedade das variáveis utilizadas, para isso será feita uma análise gráfica da série, e para uma análise mais formal será utilizado o teste da raiz unitária. O que ocorre, na prática, é que a maioria das séries econômicas apresentam algum tipo de não estacionariedade (ou podem ser estacionárias por períodos curtos ou longos), o que torna necessário uma mudança de nível e/ou inclinação. Como a maioria dos modelos consideram as séries como estacionárias, é necessário realizar sucessivas diferenças das séries originais (Tsay, 2001).

Testes de raiz unitária

De acordo com Enders (1995), a condição de estabilidade é um pressuposto necessário e fundamental para analisar as séries temporais. As propriedades usuais de mínimos quadrados vigoram apenas quando as séries analisadas são estacionárias. Portanto, é necessário investigar se o processo estocástico que gerou a série não varia ao longo do tempo.

1. Teste de Dickey-Fuller

Segundo Gujarat (2011), este teste pressupõe a manipulação do modelo auto regressivo de séries temporais descrita abaixo, sem o termo Z_{t-1} , em ambos os lados e obtém-se a seguinte equação:

$$Z_t = \delta * Z_{t-1} + u_t \quad (2.17)$$

Onde:

$\delta = (\rho - 1)$, na prática é estimado e testado o teste de hipótese H_0 em que $\delta = 0$. Se o $\delta = 0$, então $\rho = 1$, isto é, nestas condições diz-se que há presença de raiz unitária, o que significa que a série temporal em estudo é não estacionária.

2. Teste de Dickey-Fuller Aumentado

Este teste também é conhecido como teste ADF (Augmented Dickey – Fuller) que é a extensão do teste de Dickey - Fuller, esse teste foi proposto como, solução dos casos de haver necessidade de usar-se uma autorregressão de ordem superior ou suficientemente elevada, permitindo assim que, os resíduos das equações não apresentem sintomas de autocorrelação e baseia-se na seguinte regressão:

$$\Delta Z_t = \beta_1 + \beta_2 t + \delta Z_{t-1} + \sum_{i=1}^m \alpha_i \Delta Z_{t-1} + u_t \quad (2.18)$$

Onde:

β_1 - intercepto da série, também conhecido como *drit* da série;

β_2 - é o coeficiente de tendência;

δ - é o coeficiente de presença de raiz unitária;

m - número de defasagens tomada na série;

Desta feita, é feita uma regressão de ΔZ_t em $Z_{t-1}, \Delta Z_{t-1}, \dots, \Delta Z_{t+p-1}$ e de seguida calculada a estatística T , que será dada por:

$$T = \frac{\hat{\delta}}{se(\hat{\delta})} \quad (2.19)$$

Onde:

$\hat{\delta}$ - é o estimador do δ

$se(\hat{\delta})$ - Estimador do desvio padrão do erro de δ .

Os valores críticos da estatística T são calculados por Dickey e Fuller através de simulação Monte Carlo.

3. Teste Phillips-Perron

Este teste é conhecido na literatura pela sigla PP e é uma generalização do teste de Dickey-Fuller para os casos em que os erros $\{\varepsilon_t\}$, $t \in Z$ são correlacionados e, possivelmente, heterocedásticos, considerando portanto as mesmas hipóteses, baseando-se no estudo da regressão descrita na equação (2.17), que foi referido no teste de Dickey-Fuller Aumentado. Particularmente neste teste, a estatística Z é calculada por:

$$Z = n\hat{\delta}_n - \frac{n^2\hat{\sigma}^2}{2s_n^2} (\hat{\lambda}^2 - \hat{\gamma}_{0,n}) \quad (2.20)$$

Sendo que:

$$\hat{\lambda}^2 = \hat{\gamma}_{0,n} + 2 \sum_{j=1}^q \left(1 - \frac{j}{q+1}\right) \hat{\gamma}_{j,n} \quad (2.21)$$

$$\hat{\gamma}_{j,n} = \frac{1}{2} \sum_{i=1+j}^n \tau_i \tau_{i-j} \quad (2.22)$$

$$s_n^2 = \frac{1}{n-k} \sum_{i=1}^n \tau_i^2 \quad (2.23)$$

Onde:

τ_i representado o resíduo em Z_i utilizando estimadores de mínimos quadrados;

k – número de covariáveis na regressão;

q – número de defasagens utilizadas para calcular $\hat{\lambda}_n^2$.

De referir que Z é um ajuste da estatística de Dickley-Fuller e que se o processo for não correlacionado terá covariâncias nulas e portanto $\hat{\lambda}_n^2 = \hat{\gamma}_{0,n}$. Por outro lado se o processo não for heterocedástico ficará $se(\hat{\delta}) = \frac{1}{n}$ e Z será dada por:

$$Z = n\hat{\delta} = \frac{\hat{\delta}}{se(\hat{\delta})} \quad (2.24)$$

Assim sendo Z transforma-se na estatística de Dickley-Fuller e portanto, terá a mesma distribuição da estatística do teste ADF.

2.3 Modelos de séries temporais

De acordo com Santos (2003), os modelos estocásticos de séries temporais constituem o método mais sofisticado de extrapolação de uma série temporal. A ideia fundamental em que se baseia esta metodologia é de que a série a ser prevista é gerada por um processo estocástico cuja estrutura pode ser caracterizada e descrita.

Dentre os principais modelos estocásticos de séries temporais que se destacam na tarefa de realizar previsões estão os modelos da metodologia Box-Jenkins. esta metodologia se tornou bastante popular a partir de meados dos anos 70 em virtude de sua simplicidade e maior poder de previsão (em curto prazo) se comparados aos modelos econométricos, e neste estudo serão aplicados esses modelos.

O modelo ARIMA (autorregressivo integrado de média móvel) é uma combinação de diferentes modelos, sendo constituídos pelos modelos auto-regressivos (AR), modelos de média móvel (MA) e a diferenciação integrada (I). Desta forma, para mais bem compreender o modelo ARIMA é importante entender suas componentes, que são apresentadas nas próximas subsecções. Além disto, a processo para previsão por meio destes modelos é também um componente muito importante e desde já passa-se a apresentar a partes que compõem esse modelo.

2.3.1 Modelos Auto-regressivos (AR)

O modelo auto-regressivo é representado por $AR(p)$, e se parece com uma regressão linear onde as variáveis independentes são simplesmente os valores defasados no tempo da variável dependente. Nestes modelos, as observações correntes de uma série Y_t dependem apenas da função linear de seus valores passados e dos erros aleatórios. Matematicamente, tal modelo definido por $AR(p)$ tem a seguinte expressão geral:

$$AR(p) = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t, \quad (2.25)$$

Onde:

X_t é estacionário, $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ é um ruído branco;

Os coeficientes $\phi_1, \phi_2, \dots, \phi_p$ são constantes tais que $\phi_p \neq 0$.

Os modelos autorregressivos baseiam-se na ideia de que o valor atual da série X_t , pode ser explicado como uma função de p valores passados, $X_{t-1}, X_{t-2}, \dots, X_{t-p}$, onde p determina o número de etapas no passado necessárias para prever o valor actual.

2.3.2 Modelos de médias móveis (MA)

Como uma alternativa à representação autorregressiva na qual os X_t no lado esquerdo da equação são combinados linearmente, o modelo de médias móveis de ordem q , abreviado como $MA(q)$, assume o ruído branco ε_t do lado direito da equação definidora seja combinado linearmente para formar os dados observados.

O modelo de média móvel é representado por $AM(q)$, em que q denota o número de termos de médias móveis (Gujarati, 2006). Neste modelo, a previsão depende dos valores dos erros observados em cada período passado, sendo definido conforme a equação (2.26).

$$MA(q) = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}, \quad (2.26)$$

Onde:

$\varepsilon_t \sim N(0, \sigma_w^2)$ independentes; e

$\theta_1, \theta_2, \dots, \theta_q, \theta_q \neq 0$ são parâmetros.

2.3.3 Modelos autorregressivos de médias móveis (ARMA)

Segundo Matos (2000), a combinação dos modelos auto-regressivos (AR) e de médias móveis (MA) resulta no modelo denominado ARMA. Assim, tratando-se de uma série temporal X_t e considerando-se suas primeiras diferenças $X_t = X_t - X_{t-1}$, p defasagens para essa variável e q , para os erros aleatórios, tem-se o modelo $ARMA(p, q)$:

$$\begin{aligned} \text{ARMA}(p, q) = & \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + \varepsilon_t \\ & + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q} \end{aligned} \quad (2.27)$$

Onde:

$$\begin{aligned} & \phi_p \neq 0, \theta_q \neq 0; \text{ e} \\ & \sigma_\varepsilon^2 > 0. \end{aligned}$$

Os parâmetros p e q são chamados ordens autorregressivas e de médias móveis, respectivamente. Se X_t tiver uma média μ diferente de zero, definimos $\alpha = \mu(1 - \phi_1 - \cdots - \phi_p)$ e escrevemos o modelo como:

$$\text{ARMA}(p, q) = \alpha + \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + \varepsilon_t \quad (2.28)$$

Onde:

$$\begin{aligned} & + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q} \\ & \varepsilon_t \sim N(0, \sigma_\varepsilon^2) \text{ independentes.} \end{aligned}$$

Como observado anteriormente, quando $q = 0$, o modelo é chamado de modelo autorregressivo de ordem p ou $AR(p)$, e quando $p = 0$, o modelo é chamado de modelo de médias móveis de ordem q ou $MA(q)$.

2.3.4 Modelo Autorregressivo integrado de médias móveis (ARIMA)

Segundo Matos (2000), a maioria das séries temporais são não estacionárias. No entanto, rigorosamente falando, uma série temporal utilizada na estimação de um modelo univariado deve ser estacionária ou possa ser transformada para que os resultados obtidos não apresentem problemas de espuriedade, isto é, sem significado econômico.

Dessa forma, transformar uma série para estacionária através do cálculo de diferenças tomadas d vezes a partir de seus valores originais. Nesse caso, definimos aqui primeiras diferenças (d) como $X_t = X_t - X_{t-1}$. Assim sendo, quando se torna estacionária por diferenciação, diz-se que a série é integrada de ordem d , isto é $I(d)$. A definição do modelo $ARIMA(p, d, q)$ pode ser observada na equação (2.29)

$$\begin{aligned} \text{ARIMA}(p, d, q) = & \phi_0 + \phi_1 w_{t-1} + \phi_2 w_{t-2} + \cdots + \phi_p w_{t-p} + \varepsilon_t \\ & - \theta_1 \varepsilon_{t-1} - \cdots - \theta_q \varepsilon_{t-q} \end{aligned} \quad (2.29)$$

Tal que:

$$w_t = x_t - x_{t-d} \quad (2.30)$$

Onde:

w_t é o operador diferença;

X_t - corresponde à observação da série temporal no tempo t ,

d - representa o número de defasagens

ε_t - representa o erro de eventos aleatórios que não podem ser explicados pelo modelo no período t ;

ϕ_t - corresponde ao parâmetro do modelo AR de ordem p ; e

θ_q - corresponde ao parâmetro do modelo MA de ordem q .

2.3.5 Extensão dos modelos ARIMA

Segundo Freitas (2007), para as séries econômicas que não são necessariamente estacionário na variância e na covariância, mesmo depois da série ser transformada, mas é necessário que o seja na média. No caso de séries com uma longa dependência é indicado uso do modelo ARFIMA (ARIMA fracionário) e para séries que apresentam a componente sazonal os modelos SARIMA.

Modelo Sazonal ARIMA – SARIMA (p,d,q)x (P,D,Q)_s

Utiliza-se um modelo SARIMA dado por uma composição de uma parte não sazonal ARIMA(p,d,q) e outra parte sazonal ARIMA(P,D,Q), que pode ser aditiva ou multiplicativa. Muitas vezes, a dependência do passado tende a ocorrer mais fortemente em múltiplos de alguns lag s sazonais subjacentes. Por exemplo, a forte componente anual ocorrendo em lags que são múltiplos de $s = 12$, devido às fortes conexões de todas as atividades ao ano civil. Os dados obtidos trimestralmente exibirão o período anual repetitivo em $s = 4$ trimestres.

Assim sendo, a variabilidade natural de muitos processos físicos, biológicos e econômicos tende a combinar com as flutuações sazonais. O modelo multiplicativo sazonal autorregressivo integrado de médias móveis ou modelo SARIMA é denotado como $ARIMA(p, d, q) \times (P, D, Q)_s$ e é dado por:

$$\Phi_P(B^s)\phi(B)\nabla_s^D\nabla^dX_t = \delta + \Theta_Q(B^s)\theta(B)\varepsilon_t, \quad (2.31)$$

Onde:

ε_t é o processo habitual de ruído branco gaussiano e $s=12$;

$\phi(B)$ é o componente auto-regressivo de ordem p ;

$\theta(B)$ é o componente médias móveis de ordem q ;

$\Phi_P(B^s)$ é o componente sazonal auto-regressivo de ordem P

$\Theta_Q(B^s)$ é o componente sazonal médias móveis de ordem Q

$\nabla^d = (1 - B)^d$ é a diferença ordinária;

$\nabla_s^D = (1 - B^s)^D$ é a diferença sazonal.

2.4 Previsão

A análise de séries temporais, segundo Box e Jenkins (1994), tem como objetivo principal a realização de previsão. Essa metodologia permite que valores futuros de uma série sejam previstos tomando por base apenas seus valores presentes e passados. Isso é feito através da correlação temporal existente entre os valores existentes.

Na previsão, o objetivo é prever valores futuros de uma série temporal X_{n+m} , $m = 1, 2, \dots$ com base nos dados coletados até o presente, $X_{1:n} = \{X_1, X_2, \dots, X_n\}$. Levando em consideração que X_t é estacionário, resultante das transformações ou diferenciações, e os parâmetros do modelo são conhecidos. O preditor de erro quadrático médio mínimo de X_{n+m} é:

$$X_{n+m}^n = E(X_{n+m} | X_{1:n}) \quad (2.32)$$

porque a esperança condicional minimiza o erro quadrático médio.

$$E(X_{n+m} - g(X_{1:n}))^2, \quad (2.33)$$

Onde:

$g(\cdot)$ é uma função das observações $X_{1:n}$. Primeiro, vamos restringir a atenção aos preditores que sejam funções lineares dos dados, ou seja, preditores da forma

$$X_{n+m}^n = \alpha_0 + \sum_{k=1}^n \alpha_k X_k, \quad (2.34)$$

Onde:

$\alpha_0, \alpha_1, \dots, \alpha_n$ são números reais. Notamos que os α 's dependem de n e m , mas por enquanto abandonamos a dependência da notação.

Por exemplo, se $n = m = 1$, então X_2^1 é a previsão linear de um passo à frente de X_2 dado X_1 . Em termos da expressão acima, $X_2^1 = \alpha_0 + \alpha_1 X_1$. Mas se $n = 2$, X_3^2 é a previsão linear de um passo à frente de X_3 dado X_1 e X_2 , ou seja, $X_3^2 = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2$ e, em geral, os α 's em X_2^1 e X_3^2 são diferentes. Os preditores lineares que minimizam o erro quadrático médio são chamados de melhores preditores lineares (BLPs).

2.5 Adequação do modelo

Após identificar a ordem e estimar eficientemente os parâmetros de um modelo é necessário verificar sua adequação antes de utilizá-lo por exemplo para fazer previsões. Pode-se fazer testes de sobre ajustamento, que consistem em incluir parâmetros extras no modelo e verificar sua significância estatística.

2.5.1 Análise residual

Após um modelo ter sido ajustado a uma série temporal deve-se verificar se ele fornece uma descrição adequada dos dados. Assim como em outros modelos estatísticos a ideia é verificar o comportamento dos resíduos, que são dados por:

$$\text{resíduo} = \text{observação} - \text{valor ajustado} \quad (2.35)$$

Se o modelo tiver um “bom” ajuste espera-se que os resíduos se distribuam aleatoriamente em torno de zero com variância aproximadamente constante e sejam não correlacionados. Se a variância dos resíduos for crescente uma transformação logarítmica nos dados pode ser apropriada.

Teste sobre os resíduos

Ao invés de olhar para as autocorreções residuais individualmente pode-se testar se um grupo de autocorrelações é significativamente diferente de zero através das chamadas estatísticas Q.

➤ Teste de Box-Pierce

Para modelos ARMA Box e Jenkins (1970) sugeriram o uso do teste de Box-Pierce onde a estatística de teste é dada por:

$$Q_{bp} = n \sum_{k=1}^m \hat{\rho}_k^2 \quad (2.36)$$

Onde:

n = tamanho de amostra;

m = tamanho de defasagem;

k = número de parâmetros estimados.

Na prática o número m de autocorrelações amostrais é tipicamente escolhido entre 15 e 30. Se o modelo ajustado for apropriado então Q terá distribuição aproximadamente qui-quadrado com m-p-q graus de liberdade. Assim, valores grandes de Q_{bp} fornecem indicação contra a hipótese de que as autocorrelações são todas nulas, em favor da hipótese de que ao menos uma delas é diferente de zero.

➤ Teste de Ljung-Box

O teste de Box-Pierce não tem bom desempenho em amostras pequenas ou moderadas no sentido de que a distribuição se afasta da qui-quadrado. Vários testes alternativos foram sugeridos na literatura e o mais conhecido é o teste de Ljung-Box, aonde a estatística de teste é dada por:

$$Q_{lb} = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{n-k} \quad (2.37)$$

➤ Teste de Jarque-Bera

A normalidade dos resíduos é uma suposição essencial para que os resultados do ajuste do modelo de regressão linear sejam confiáveis, pois vários métodos de estimação e testes de hipóteses existentes foram formulados sob a suposição de que a amostra aleatória tenha sido extraída de uma população normal. A estatística de teste é dada por:

$$JB = n \left(\frac{\alpha_3^2}{6} + \frac{(\alpha_4 - 3)^2}{24} \right) \approx \chi_2^2 \quad (2.38)$$

Em que os valores \bar{y} representa a média amostral e $s^2, \alpha_3 e \alpha_4$ são a variância, assimetria e curtose respectivamente, e são obtidas através das seguintes formas.

$$\begin{aligned} \alpha_3 &= \frac{\sum_{i=1}^n (y_i - \bar{y})^3}{ns^3}; \\ \alpha_4 &= \frac{\sum_{i=1}^n (y_i - \bar{y})^4}{ns^4}; \\ S^2 &= \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} \end{aligned} \quad (2.39)$$

2.5.2 Critérios para selecção do melhor modelo

Segundo Gujarate e Porter (2011), existem vários critérios usados na selecção do melhor modelo, e os critérios mais usados são: critério de informação de Akaike (AIC = - 2(log likelihood - número de parâmetros no modelo)) e o critério de informação de Schwarz (CIS). Esses critérios tem como objectivo minimizar a soma dos quadrados dos resíduos (SQR) (ou aumentar o valor de R^2 , em caso de se usar esse valor como critério de selecção do modelo).

1. Critério de informação de Akaike (CIA)

A ideia de impor uma medida correctiva pelo acréscimo de regressores ao modelo foi levada adiante no critério CIA, definido como:

$$CIA = e^{2k/n} \frac{\sum \hat{u}_i^2}{n} = e^{2k/n} \frac{SQR}{n} \quad (2.40)$$

em que k é o número de regressores (incluindo o intercepto) e n é o número de observações. Por conveniência matemática, a equação (2.40) pode ser logaritimizada, pois, Alguns textos e programas definem CIA apenas em termos de sua transformação logarítmica, ao fazer essa transformação teria-se a equação (2.41)

$$\ln CIA = \left(\frac{2k}{n}\right) + \ln \frac{\sum \hat{u}_i^2}{n} = \left(\frac{2k}{n}\right) + \ln \frac{SQR}{n} \quad (2.41)$$

Onde: $\ln CIA$ = logaritmo natural de CIA e $2k/n$ D factor de correção.

2. Critério de informação de Schwarz (CIS)

Semelhante ao CIA, mas o CIS impõe medidas corretivas mais duras que o CIA, o critério CIS é definido como:

$$CIS = n^{k/n} \frac{\sum \hat{u}_i^2}{n} = n^{2k/n} \frac{SQR}{n} \quad (2.42)$$

ou na forma logarítmica:

$$\ln CIS = \left(\frac{k}{n}\right) \ln n + \ln \frac{\sum \hat{u}_i^2}{n} = \left(\frac{k}{n}\right) \ln n + \ln \frac{SQR}{n} \quad (2.43)$$

Segundo Agresti (2007), o melhor critério conhecido é o de informação de Akaike (AIC), pois, ele julga um modelo pela distância, onde os seus valores ajustados tendem a ser os verdadeiros valores esperados, e o modelo ideal é aquele que tende a ter seus valores ajustados mais próximos das verdadeiras probabilidades de resultado.

2.5.3 Avaliação da precisão de previsão do modelo

Dentre os tipos de erros mais utilizados para avaliar a precisão de um método quantitativo de previsão de vendas é possível listar: Média absoluta dos erros (Mean Absolute Deviation - MAD), Media percentual dos erros (Mean Percentual Error - MPE), Média percentual absoluta dos erros (Mean Absolute Percentual Error - MAPE) e Media dos quadrados dos erros (Mean Square Error - MSE).

Para avaliar a precisão das previsões, os intervalos de previsão são normalmente calculados junto com as previsões. Em geral, os intervalos de previsão com probabilidade de cobertura $1 - \alpha$, são da forma

$$X_{n+m}^n \pm c_{\alpha/2} \sqrt{P_{n+m}^n} \quad (2.44)$$

Onde:

$c_{\alpha/2}$ é escolhido para obter o grau de confiança desejado.

A média absoluta do erro (MAD) é escolhido para obter o grau de confiança desejado. Esta medida é calculada a partir da seguinte equação:

$$\text{MAD} = \frac{1}{n} \sum_{k=1}^n |\varepsilon_t| \quad (2.45)$$

Este cálculo é empregue para avaliar o nível de erro na mesma unidade que a série. Já o MPE é utilizado para avaliar se o método possui algum viés. Para previsões não enviesadas, espera-se um valor do MPE próximo de zero. Essa medida é obtida pela seguinte equação:

$$\text{MPE} = \frac{1}{n} \sum_{k=1}^n \frac{\varepsilon_t}{Z_t} \quad (2.46)$$

O desempenho preditivo dos modelos foi avaliado segundo o tamanho do erro de previsão, mensurado pela raiz quadrada da média dos quadrados do erro (**RMSE**), este índice é calculado com base nos desvios de \hat{y} (estimado) em relação a y (real). O índice da RMSE é dado pela equação (2.47):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2} \quad (2.47)$$

Uma outra medida de precisão da previsão, também usa-se o erro absoluto percentual médio (**MAPE**) descrita pela equação (2.48), esta é uma das medidas mais utilizadas em função da sua facilidade de interpretação e é expressa por porcentagem.

$$\text{MAPE} = \sum_{t=T+1}^{T+h} \left| \frac{\mu_t}{y_t} \right| / h \quad (2.48)$$

Os valores do erro percentual absoluto médio podem ser relacionados com a potencialidade das previsões: MAPE < 10% - previsão é potencialmente muito boa, MAPE < 20% - previsão é potencialmente boa, MAPE < 30% - previsão é potencialmente razoável e MAPE > 30% - previsão é potencialmente inexata.

Segundo Lopes (2002), a incerteza de previsão é medida através da variância do erro de previsão. Ora, pode mostrar-se que:

1. para processos ARMA (estacionários), a variância dos erros de previsão é limitada e tende para a variância não condicional do processo;
2. Pelo contrário, para os processos não estacionários a variância dos erros de previsão não é limitada e vai crescendo com o horizonte de previsão, geralmente a incerteza de previsão aumenta à medida que nos afastamos do presente. Isto é, muita atenção deve ser dada aos processos não estacionários.

Em termos práticos, é evidente que os parâmetros não são conhecidos e necessitam ser substituídos por estimativas nas expressões anteriores.

2.6 Estudos relacionados

Foi realizado um estudo que apresenta uma análise exploratória acerca dos contratos de financiamento imobiliário realizados no Brasil com recursos do Sistema Brasileiro de Poupança e Empréstimo. O propósito deste estudo foi investigar o comportamento e prever os financiamentos habitacionais no Brasil, por meio de um modelo para séries temporais. Para isto, foram utilizados os registros mensais, de janeiro/2010 a março/2017, obtidos na Câmara Brasileira da Indústria da Construção. Segundo Melchior *et al.*, (2019), foram ajustados modelos por meio da metodologia ARIMA e como melhor modelo, estimou-se o ARIMA (1,2,1) e através deste, constatou-se que o comportamento da série refletiu o impacto político advindo das trocas de governo analisadas desde o governo Lula até o governo de Temer.

Segundo Moro *et al.*, (2018), o seu estudo foi desenvolvido para adequar um modelo de previsão utilizando a metodologia ARIMA de Box & Jenkins, a fim de identificar o de melhor acurácia para o mercado imobiliário de São Paulo. Para que o estudo se concretizasse, foram utilizados dados referentes à série temporal de vendas de unidades residenciais, fornecidos pelo SECOVISP entre os anos de 2004 e 2015. Os resultados implicam que é possível fazer uso de modelos de previsão de vendas no sector imobiliário e que modelos dessa classe podem ser úteis tanto no planejamento das incorporadoras como para o sector público, seja para facilitar simulações macroeconômicas de políticas na área de geração de empregos ou para nortear a formulação de políticas públicas na área de habitação. Por fim, o modelo que melhor se ajusta a previsão foi SARIMA(2,1,0)(1,0,0)[12]. Deste modo, enfatizou-se que o estudo do funcionamento do mercado habitacional brasileiro reveste-se de fundamental importância e relevante no cenário actual.

Capítulo 3

Material e Métodos

3.1 Material

Para o desenvolvimento desse estudo foram utilizados dados secundários, obtidos do Moza Banco da cidade de Maputo, que disponibilizou os registos mensais de crédito imobiliária, com esses dados, foi criada a série temporal que usou se para fazer as análises. Esta série temporal, apresenta observações no período de tempo equi-distribuídos, num total de 96 meses nos períodos de janeiro de 2012 a dezembro de 2020.

Para o processamento da série temporal do crédito imobiliário do Moza banco, na repartição da cidade de Maputo, foi utilizado o pacote estatístico **R** na sua versão 4.2.1., com o auxílio do RStudio, sendo que, de seguida os resultados foram analisados, interpretados. A redação do relatório final foi através do software de escrita denominado \LaTeX .

3.2 Métodos

Em qualquer análise de séries temporais, deve-se construir um gráfico de tempo dos dados e inspecionar o gráfico em busca de quaisquer anomalias. No entanto, a variabilidade nos dados aumenta com o tempo, será necessário transformar os dados para estabilizar a variância. Nesses casos, a classe de transformações de potência Box-Cox, poderia ser empregada. Além disso, pode-se sugerir uma transformação apropriada.

Assim sendo, Caso, após a aplicação do teste da raiz unitária e constatar se que a série de dados é não-estacionaria, deve ser procedido a transformação dos dados através da logaritmização, e ou o cálculo da 1ª ou 2ª diferença, até que se obtenha uma série estacionária, pois, só assim é possível aplicar a metodologia de Box-Jenkis (Mynbaev e Lemos, 2004).

De salientar que, a realização de todos os testes estatísticos, foram conduzidos usando o nível de significância de $\alpha = 5\% = 0.05$, o que leva a confiabilidade dos resultados obtidos, à cerca de 95% de confiança. Passa-se a apresentar os estágios seguidos para análise:

3.2.1 Transformação da série em estacionária

A maioria dos modelos de previsão necessitam trabalhar com séries estacionárias. Como diversos fenômenos são regidos em ambientes não estacionários, em muitos casos é necessário que a série temporal não estacionária seja transformada em uma série estacionária, a fim de que seja possível realizar previsões mais acuradas (Zhang, 2003).

Além de usar o logaritmo da série para torna-la estacionária, também existem outras técnicas comumente utilizadas para este fim, como fazer a transformação Box-Cox de modo a remover a variabilidade, a diferenciação e a remoção de tendência da série também podem ser aplicadas.

De acordo com Cowpertwait e Metcalfe (2009), a diferenciação remove tanto tendências estocásticas, quanto determinísticas. A diferenciação consiste em tomar sucessivas diferenças da série de dados estudada até que seja obtida uma série estacionária. A diferenciação de uma série é dada pela equação descrita em (2.30) na secção anterior.

Neste estudo, usou-se a transformação Box-Cox da série para torna-la estacionária. Em muitos casos, quando a série temporal original não é estacionária a sua primeira diferença já é estacionária (Gujarati e Porter, 2008). A este tipos de séries são comumente adota-se $d=1$, mas o processo da identificação do modelo continua.

3.2.2 Teste de estacionariedade

O teste de Dickey-Fuller Aumentado (ADF) foi escolhido neste trabalho, por ser um dos mais populares (Hyndman e Athanasopoulos, 2014) e pelo facto da componente irregular em que este teste será aplicado apresentar variância constante e da autocorrelação ser nula para a maior parte dos desfasamentos como descrito pela equação (2.18). As hipótese do polinômio autorregressivo a testar são:

H_0 : A série tem raiz unitária ($\gamma = 0$);

H_1 : A série não tem raiz unitária ($\gamma < 0$).

Outro motivo da escolha desse teste é devido a sua robustez, nesta verificação principalmente na presença de componentes deterministas. Foi realizado o mesmo teste para a parte sazonal da mesma série em análise.

Regra de decisão:

Rejeita-se H_0 , se a estatística $t > \text{Valor Crítico } \tau$ ou ainda, se o p-valor associado ao teste for inferior ao nível de significância ($p\text{-valor} < \alpha$), o que leva a concluir que a série em análise é não estacionária.

3.2.3 Estágios de interação dos modelos Box & Jenkins

O método do modelo matemático de Box & Jenkins, tem como objectivo detectar o comportamento dos valores da série temporal a fim de fornecer previsões futuras, portanto, este método segue quatro estágio ou etapas a seguir, que são:

1. Identificação do modelo a ser ajustado aos dados

Esta escolha é feita com base nas funções de autocorrelações e autocorrelações parciais estimadas. Neste primeiro passo de identificação, foi transformada através da logaritmização dos dados que apresentavam os seus dados na forma exponencia (como ilustra a figura (5.1) em anexo). No entanto, a diferenciação, a função de correlação amostral (ACF), e da correlação amostral parcial (PACF), são fundamentais na determinação das ordens de três componentes, sendo os dois últimos também são denominados “filtros”: a ordem p é associada aos parâmetros do filtro AR; a ordem q , está associada aos parâmetros do filtro MA; A ordem d é o parâmetro associado ao número de diferenciações necessárias para tornar a série estacionária (Morettin, 2006).

Através das FAC pode-se encontrar um padrão que se identifique com algum modelo em particular, sendo mais eficaz para identificar em particular os modelos $MA(q)$ e $AR(p)$. Onde as características especiais das FAC, com base nessas características que se seguem pode se optar pela sua escolha do modelo adequado:

- (a) Se a FAC for infinita em extensão e a decrescer como uma função exponencial e/ou função sinusoidal amortecida, possível a opção pelo modelo $AR(p)$;
- (b) Se a FAC for finita e apresenta um corte após a defasagem q , possível a opção pelo modelo $MA(q)$;
- (c) Se a FAC for infinita e decresce com características exponenciais e/ou sinusoidais amortecidas após a defasagem (q,p) , possível a opção pelo modelo $ARMA(p,q)$.

O mesmo acontece com a determinação dos possíveis parâmetros autorregressivos lidos na PACF, assim sendo, são estimados os possíveis modelos $ARIMA(p,d,q)$, para posterior verificar-se o melhor dentre eles.

2. Estimação dos parâmetros

Uma vez escolhido o modelo $ARIMA$, é necessário então estimar os parâmetros dos termos auto-regressivos e de médias móveis incluídos no modelo, de maneira a minimizar o erro global do modelo. Para isso, podem ser utilizados diferentes métodos, entre eles estão o método dos mínimos quadrados e métodos de estimação não-lineares. Ainda segundo Gujarati e Porter (2008), a estimação do parâmetro torna-se uma tarefa mais fácil com o apoio de pacotes estatísticos e por isso não é preciso muito aprofundamento nos conceitos relacionados a esta estimativa;

3. Verificação da adequabilidade do modelo

Após a estimação dos parâmetros, deve-se verificar se o modelo estimado se ajusta bem aos dados, para tal, é feita uma análise nos resíduos. Uma das técnicas que pode ser utilizada, caso o modelo se mostre inadequado é o super-ajustamento, no qual são adicionados parâmetros e o modelo é estimado. Examina-se então se estes parâmetros são significativos no ajuste através do teste “t”.

Modelo definitivo:

Para previsão ou controle. Verificar quais modelos têm as melhores medidas RMSE e MAPE (este não vale para dados próximos de zero, sendo preferível a utilização de outro método para a análise dos erros) e também foram usados os Critério de Informação de Akaike (AIC) e o Critério Bayesiano (BIC) para identificar a ordem do modelo ARMA a ser utilizado, minimizando uma função que penaliza o ajuste de modelos não parcimoniosos, ou seja, que possuem uma grande quantidade de parâmetros;

Segundo Agresti (2007), o melhor critério conhecido é o de informação de Akaike (AIC), pois, ele julga um modelo pela distancia, onde os seus valores ajustados tendem a ser os verdadeiros valores esperados, e o modelo ideal é aquele que tende a ter seus valores ajustados mais próximos das verdadeiras probabilidades de resultado. Por isso, para a escolha do melhor modelo estimado do crédito imobiliário do Moza banco da cidade de Maputo foi usado o critérios de informação de Akaike (AIC).

4. Previsão

Na fase final, depois de ter se selecionado o melhor modelo para a série temporal, e certificado de que o modelo escolhido pode ser considerado adequado, ele será usado para fazer previsões de valores futuros da série.

3.2.4 Diagnósticos do modelo estimado

Segundo Gujarati (2000), depois de escolher um modelo ARIMA em particular, e estimar seus parâmetros, em seguida investiga-se as estimativas dos resíduos, com intuito de avaliar se estes são um ruído branco, se são, pode-se aceitar o ajuste específico, e se não, deve-se começar tudo de novo até que poça se constatar que os resíduos do modelo estimado seja um ruído branco.

No entanto, para tal supõe-se que os resíduos tenham uma distribuição normal, sejam independentes e identicamente distribuídos, com a média zero e variância finita. E esses pressupostos são importantes para garantir que o modelo tem boa especificação. Assim, esse passo tem como objetivo investigar cada uma dessas afirmações, neste trabalho não houve exceção desses diagnósticos, onde foram realizados os seguintes testes:

1. Testes para detecção de Ruído Branco

Segundo Ferreira (2016), a estatística Q é usada com frequência para testar se a série é de ruído branco ou não, é verificado por meio do teste de Q_{bp} (Box-Pierce) ou pelo teste de Q_{lp} (Ljung-Box) quando amostra é grande. As estatísticas Q foram descritas pelas equações (2.36) e (2.37), estas estatísticas testam a hipótese conjunta de que todos os ρ_k até uma certa defasagem são simultaneamente iguais a zero ou se um determinado conjunto de auto-correlações de resíduos é, ou não, estatisticamente diferente de zero. Essa estatística em amostras grandes possui distribuição aproximadamente a χ_m^2 (qui-quadrado).

As hipóteses dos testes de Q_{bp} e Q_{lp} são:

$$H_0: \rho_k = 0; \quad k, j = 1, 2, 3, \dots, n$$

$$H_1: \rho_k \neq \rho_j, k \neq j.$$

2. Teste de Jarque-Bera

Neste estudo, foram feitas análise gráfica dos resíduos e para confirmar, também foi feito o teste de Jarque-Bera para certificar se de que os resíduos que resultaram da regressão do modelo estimado apresentam uma distribuição normal. Segundo Cromwell *et al.*, (1994) esse teste foi proposto pelos autores Jarque e Bera em 1980, e consistia em fazer as diferenças entre os coeficientes de assimetria e curtose dos dados $y_1, y_2, y_3 \dots, y_n$ e aqueles da distribuição assumida normal.

As hipóteses do teste de Jarque-Bera são:

$$H_0: y_1, y_2, y_3 \dots, y_n \sim N(\mu, \sigma^2) = \text{A série é normalmente distribuída};$$

$$H_1: y_1, y_2, y_3 \dots, y_n \not\sim N(\mu, \sigma^2) = \text{A série não é normalmente distribuída}.$$

Regra de decisão:

Usando o nível de significância de 5%, rejeita-se a H_0 , se o valor os valores das estatísticas JB, Q_{bp} ou Q_{lp} for superior a estatística $\chi_{2,critico}^2$, ou então, se p-valor associado a cada estatística de teste obtido inferior ou igual ao valor de $\alpha = 5\%$.

Capítulo 4

Resultados e Discussão

4.1 Resultados

Nesta secção, são apresentados os resultados obtidos através do processamento da série temporal do crédito imobiliário fornecido pela Moza banco filiada na cidade de Maputo, onde foram analisada 96 observações desde Janeiro de 2012 à Dezembro de 2020.

4.1.1 Descrição do crédito imobiliário do Moza banco

Através da representação gráfica feita em (4.1), pode-se verificar um comportamento quase que repetitivo ao longo dos anos, onde o crédito imobiliário apresentou uma tendência que variava com o tempo, caracterizado por subidas e descidas, com mesmo comportamento ao longo dos meses de cada ano, sugerindo a presença de sazonalidade, deixando assim, em aberto a necessidade de investigar a presença de sazonalidade não estacionariedade da série em análise.

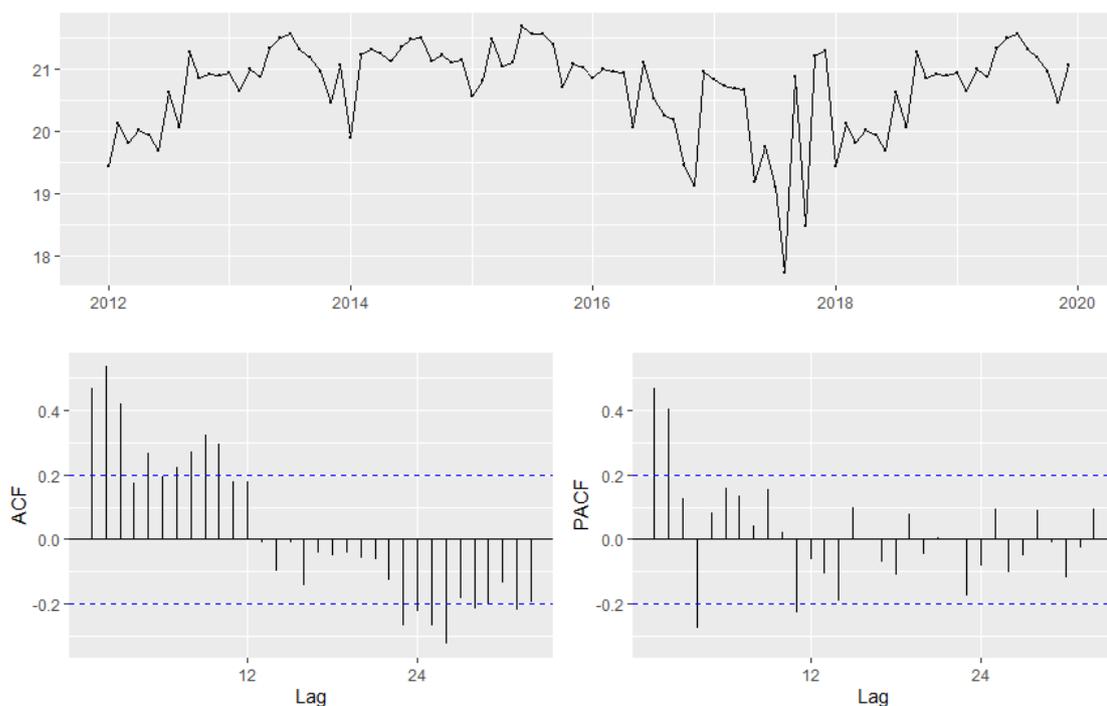


Figura 4.1: Evolução do crédito imobiliário na Cidade de Maputo

O crédito imobiliário da cidade de Maputo, apresenta uma série temporal que a priori sugere a não estacionariedade, pois, ela apresenta momentos de queda e subida na sua curva. Uma verificação mais formal pode ser feita através do teste da raiz unitária. Realizado o teste de Dickey-Fuller Aumentado (ADF) e os resultados tabulados em (4.1), em que a sua execução foi feita considerando o intercepto e tendência, pois, podem existir algumas variações do crédito imobiliário, que poderia ser causado pelos ciclos ou sazonalidade.

Tabela 4.1: Teste de ADF do crédito imobiliário

Série	Estatística t	Lags	p-valor
Crédito	-0.163	1	0.8709

De acordo com os resultados descritos na tabela (4.1), tem-se evidências suficientes para concluir que, o logaritmo da série do crédito imobiliário é não estacionária em nível. Em relação a sazonalidade, pode-se verificar alguma aleatoriedade do crédito imobiliário nos períodos mensais de cada ano em análise, de acordo com o gráfico (4.2), o comportamento desta série quando repartida em 12 meses dos anos 2012 à 2020, nota-se que cada ano apresenta o seu próprio comportamento.

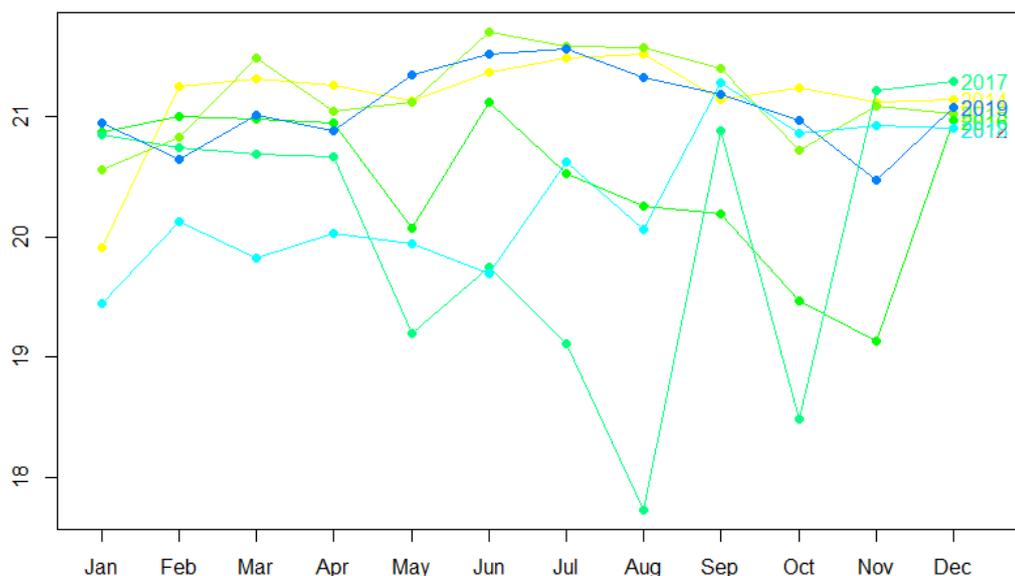


Figura 4.2: Representação da sazonalidade do crédito imobiliário

Verificada a não estacionariedade da série em nível depois da logaritmização, há necessidade de continuar com as transformações, sendo que desta vez, fez a remoção da variabilidade ou variância, pois, é a única coisa que pode se melhorar, uma vez que, os dados de crédito imobiliária não apresentam nenhuma tendência crescente e nem decrescente.

Feita a transformação Box-Cox da série do logaritmo do crédito imobiliário adquirido pelos clientes do Moza banco, foi possível verificar na representação (4.3), um comportamento aleatório das observações, sendo que, torna-se importante ter a certeza sobre a estacionariedade dessa série, por isso, passou se a fazer o teste de ADF.

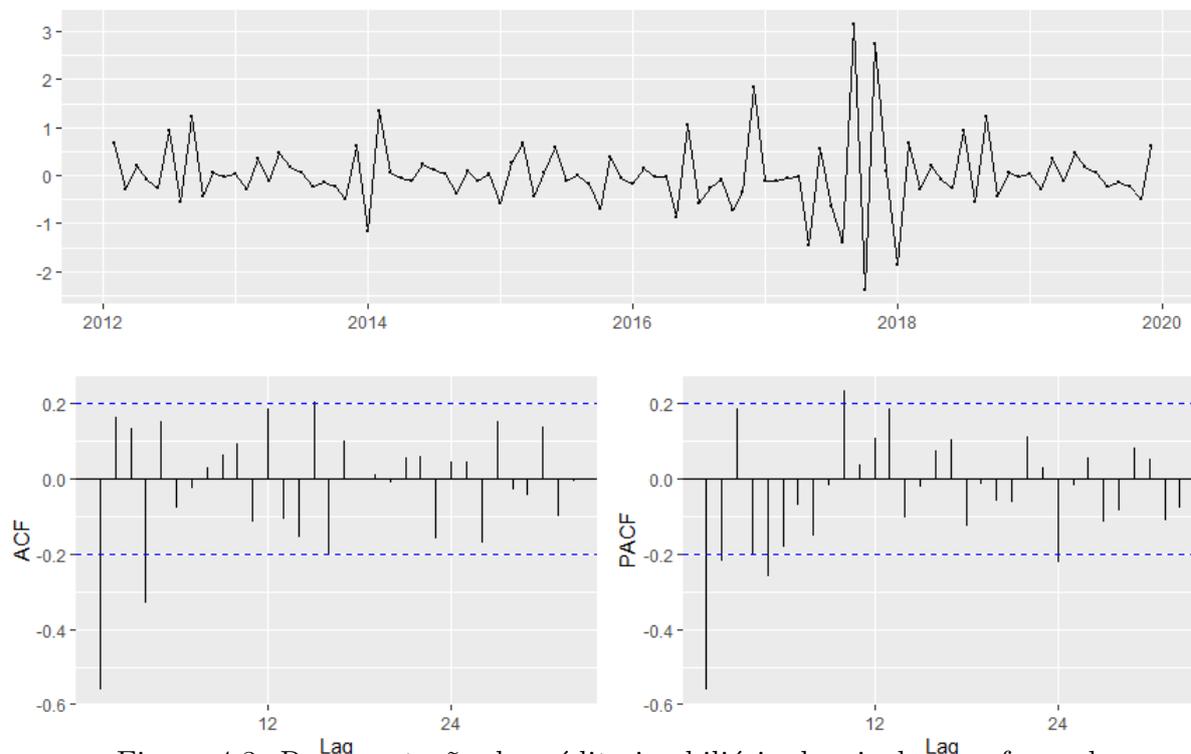


Figura 4.3: Representação do crédito imobiliário depois de transformada

Os resultados do teste de raiz unitária na série transformada do crédito imobiliário fornecido aos clientes do Moza banco, foram tabulados em (4.2) e demonstraram que, a série em análise é estacionária tornou se estacionária, isto é, ela pode ser considerada $I(0)$ depois de removida variância e tendência exponencial que existia na série.

Tabela 4.2: Teste de ADF do Crédito imobiliário depois de Cox-Box

Série	Estatística t	Lags	p-valor
Crédito	-3.464	3	0.000895 ***

Por conseguinte, passa-se a proceder com a identificação dos parâmetros p e q , que poderão fazer parte dos modelos sugestivos para efectuar a previsão dos valores de crédito imobiliário.

4.1.2 Identificação dos parâmetros do modelo adequado

A melhor recomendação é começar com defasagens suficientemente grandes, e então reduzi-las por algum critério estatístico, como por exemplo o de informação de Akaike ou o critério de informação Schwarz.

No entanto, como sugere a figura (4.3) a primeira defasagem é que a suficientemente grande, tanto no correlograma da função de autocorrelação, assim como na função da autocorrelação parcial, deste modo, as melhores sugestões dos parâmetros por aplicar no modelo ARIMA seriam $p = 1$ e $q = 1$, e assim, seriam mudados alguns parâmetros p e q de forma decrescente como sugere a figura (4.3). Mas neste estudo, contou se com o auxílio computacional, foi empregue o método **Auto.arima()** e escolha do melhor modelo pode ser descrita de seguida.

4.1.3 Estimação e escolha do melhor modelo

Usado o comando **auto.arima()**, pode-se ajustar diversas combinações dos parâmetros e os modelos sugestivos ajustados são apresentados na tabela (4.3), estes modelos vem acompanhados dos seus valores do critério de informação de Akaike para ajudar na selecção do melhor modelo estimado.

Tabela 4.3: Modelos ARIMA estimados

ARIMA (p,d,q)(P,D,Q)s	AIC
ARIMA(2,0,2)(1,0,1)[12]	177.839
ARIMA(0,0,0)	216.0203
ARIMA(1,0,0)(1,0,0)[12]	192.8076
ARIMA(0,0,1)(0,0,1)[12]	202.5661
ARIMA(0,0,0)	856.4211
ARIMA(2,0,2)(0,0,1)[12]	175.4816
ARIMA(2,0,2)	175.8087
ARIMA(2,0,2)(0,0,2)[12]	177.835
ARIMA(2,0,2)(1,0,0)[12]	175.6539
ARIMA(2,0,2)(1,0,2)[12]	180.2691
ARIMA(1,0,2)(0,0,1)[12]	173.312**
ARIMA(1,0,2)(1,0,1)[12]	175.6101
ARIMA(1,0,2)(0,0,2)[12]	175.6031
ARIMA(1,0,2) with	173.5904
ARIMA(1,0,2)(1,0,0)[12]	173.4916
ARIMA(1,0,2)(1,0,2)[12]	177.9769
ARIMA(0,0,2)(0,0,1)[12]	178.4114
ARIMA(1,0,1)(0,0,1)[12]	181.8998
ARIMA(1,0,3)(0,0,1)[12]	174.3927
ARIMA(0,0,3)(0,0,1)[12]	174.2842
ARIMA(2,0,1)(0,0,1)[12]	179.0769
ARIMA(2,0,3)(0,0,1)[12]	Inf(∞)

Como pode-se ver nas tabelas acima, foram listados 22 modelos ajustados, com diferentes parâmetros sugestivos e de acordo com os valores de AIC, com ajuda desses valores pode se fazer a selecção do melhor modelo.

Já que a série em análise apresenta a sazonalidade mensal por ano, o modelo pode ser denotado por SARIMA(p,d,q)x(P,D,Q)[s], em que a sua parte da tendência da série foi estimada como um modelo autorregressivo de médias móveis (ARMA), enquanto que, da parte sazonal foi estimado um modelo de médias móveis. Desta forma, pode-se verificar através na tabela (4.3), que o modelo que apresenta o menor valor de AIC é o SARIMA(1,0,2)(0,0,1)[12], com o valor de AIC=173,312.

Tabela 4.4: Coeficientes estimados pelo modelo escolhido

Coeficientes	parâmetros	Estimativa	Erro padrão	p-valor
AR1	$\phi(B)$	0.4894	0.1456	0.0007743
Sazonal MA1	$\Theta_Q(B^s)$	-0.8617	0.8140	0.2897617

Na tabela (4.4), foram apresentados os coeficientes da modelo autorregressivo de primeira ordem e também da parte sazonal que foi estimado a partir do modelo de médias móveis de primeira ordem, em análise da significância, pode-se constatar que a parte Autorregressiva de primeira ordem revelou-se ser estatisticamente significativa.

Para poder avaliar o desempenho do modelo escolhido (SARIMA(1,0,2)(0,0,1)[12]), são apresentadas algumas medidas dos erros estimados pelo modelo. Na tabela (4.5), foram tabulados valores do MPE, RMSE e MAPE, onde verificou se que o modelo SARIMA(1,0,2)(0,0,1)[12], que apresentou o menor valor do AIC, apresentou o seu MAPE de 0.213231 (21,32%), o que quer dizer que, as previsões feitas pelo modelo em análise, são considerados potencialmente razoáveis, pois, o valor de MAPE é inferior a 30% (0.3).

Tabela 4.5: Medidas dos erros estimados através dos coeficientes

Modelos	MPE	RMSE	MAPE
ARIMA(1,0,2)(0,0,1)[12]	0.00011	0.5541543	0.213231**
ARIMA(1,0,0)(1,0,0)[12]	0.4517138	0.6299599	2.226689
ARIMA(0,0,1)(0,0,1)[12]	0.5001311	0.6618552	2.465172
ARIMA(2,0,2)(0,0,1)[12]	0.4101445	0.5535909	2.012553

Após se estimar o modelo tem que se verificar se ele representa, ou não, adequadamente, os dados. Para tal, serão respondido esse objetivo através da análise residual, onde vários testes estão disponíveis na literatura, alguns deles citados nos métodos e seus resultados são apresentados a seguir.

4.1.4 Diagnóstico do modelo através dos resíduos

A figura (4.4), apresenta uma representação gráfica dos resíduos, desde a sua disponibilidade, a função de autocorrelação e o histograma, com essas visualizações pode-se verificar que os resíduos estão disponíveis de forma aleatória, todas as defasagens estão dentro dos limites de especificação do intervalo de confiança de 95%, e o histograma também sugere a normalidade dos resíduos.

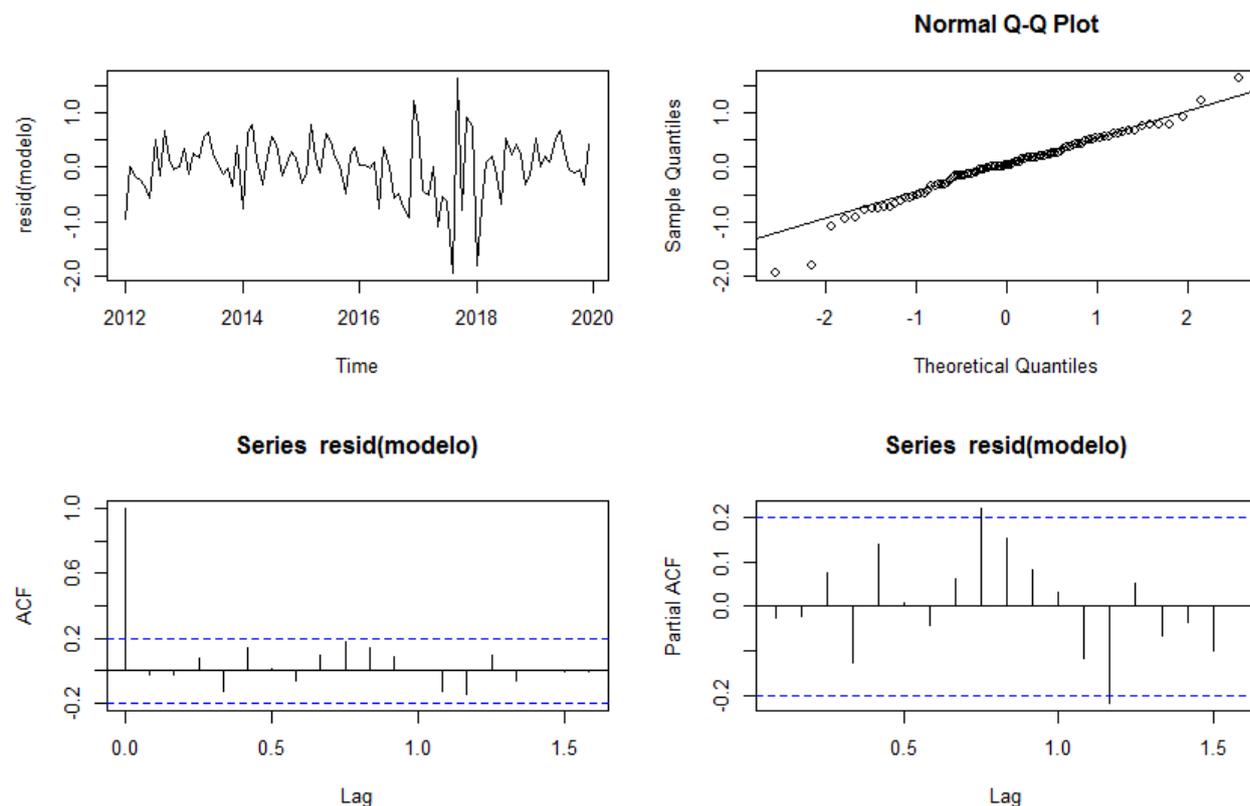


Figura 4.4: Resíduos do modelo SARIMA estimado

Para efeitos de confirmação das sugestões verificadas na figura (4.4), são apresentados de seguida os testes formais destes resíduos. Começou se pela mais simples e que menos influência pode ter nos resultados, que é o que testa a distribuição normal nos resíduos do modelo estimado.

Tabela 4.6: Resultado do Teste de Jarque-Bera

Estatística Q_{lb}	df	total lags usados	p-valor
11.583	10	12	0.3139

De acordo com a tabela (4.6), com os resultados do teste de Jarque-Bera, demonstraram que os resíduos do modelo estimado apresentam uma distribuição normal, pois, o p-valor que resultou do teste é superior ao nível de significância de $\alpha = 0.05$ ($0.3139 > 0.05$), o que leva a não rejeição da hipótese nula de que dos resíduos estão normalmente distribuídos.

Realizado o teste para as autocorrelações dos resíduos do modelo SARIMA(1,0,2)(0,0,1)[12], onde foram tabulados os resultados em (4.7) e com base nos p-valores que são superior ao $\alpha = 0.05$, assim, pode se constatar que as correlações parciais até os número de lags usados são iguais a zero, ou seja, não existem correlações parciais.

Tabela 4.7: Resultado do Teste de Box-Pierce dos resíduos

Estatística Q_{bp}	Total lags usados	p-valor
3.5296	5	0.6189
9.0003	10	0.5321
14.715	15	0.4721
16.11	20	0.7098
21.95	25	0.6386

O Teste de Ljung-Box é uma ferramenta diagnóstica usada para testar a falha do ajuste de um modelo de série temporal. Também usado para verificar a existência de autocorrelação parcial, assim sendo, já que os p-valores tabulados em (4.8) são superiores que $\alpha = 0.05$, isso quer dizer que, as autocorrelações são muito pequenas, ou seja, as correlações parciais até k lags são nulas ($\rho_k = 0$), concluindo-se deste modo que, o modelo SARIMA(1,0,2)(0,0,1)[12] não exhibe falha significativa de ajuste.

Tabela 4.8: Resultado do Teste de Ljung-Box dos resíduos

Estatística Q_{lb}	Total lags usados	p-valor
3.8481	5	0.5715
18.09	15	0.258
20.132	20	0.4497
29.909	25	0.2277

Deste modo, de acordo com os testes de Box Pierce e Ljung-Box, que foram tabulados em (4.7) e (4.8), verificou-se que, com estes resultados é permitido aceitar a hipótese nula de que os resíduos são ruído branco. Depois dessa análise residual, passa-se para a previsão de observações futuras.

4.1.5 Análise da previsão do crédito imobiliário

Realizar previsão da demanda do crédito imobiliário é uma atividade importante, pois, essa análise pode revelar as tendências da procura desse crédito e contribuir no planejamento estratégico da empresa (Moza banco da cidade de Maputo). Desta maneira, é ilustrada nessa representação gráfica a na linha central a previsão através do modelo estimado e nas laterais o intervalo de confiança a 95%, podendo um desses extremos do intervalo de confiança as previsões são aceitáveis.

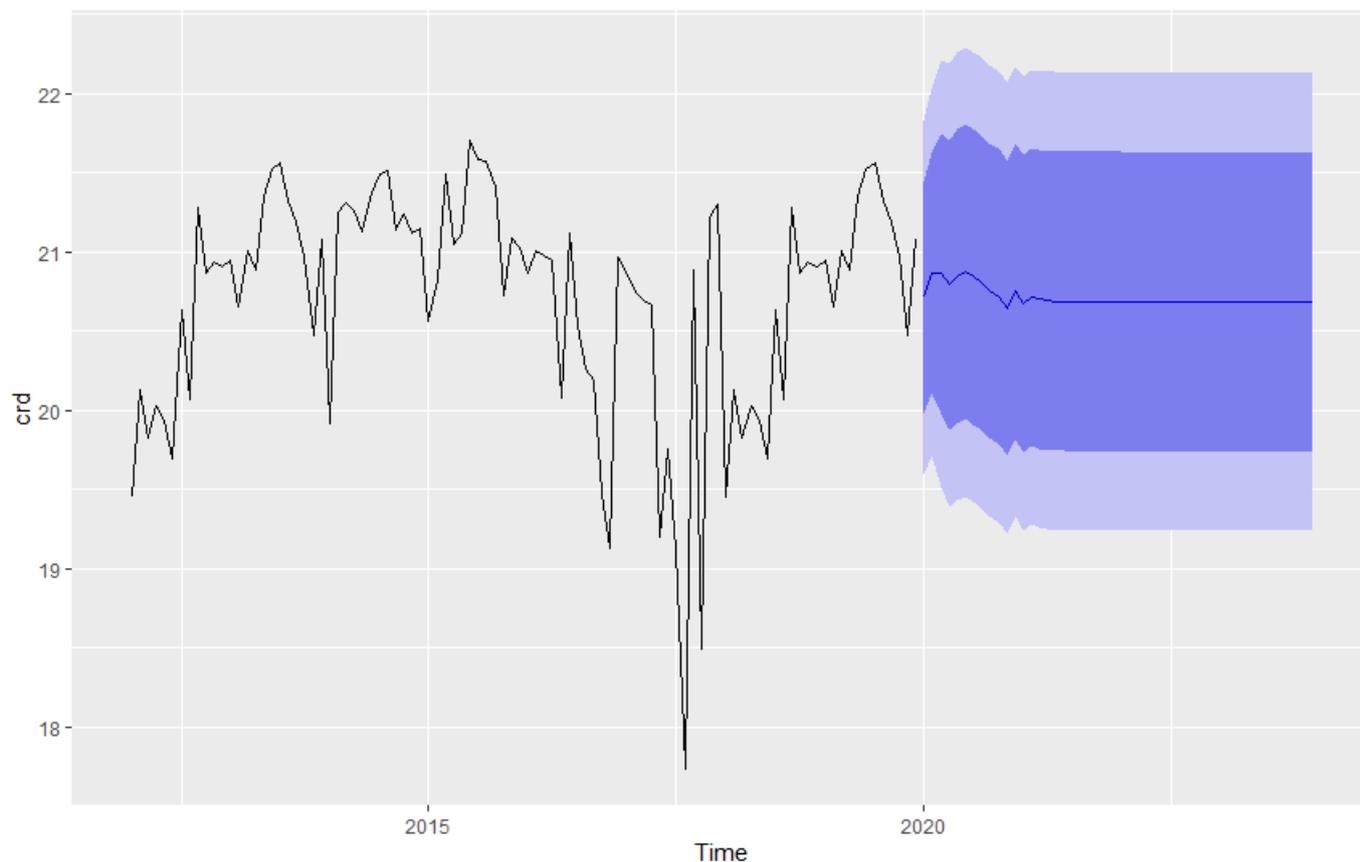


Figura 4.5: Previsão do crédito imobiliário

O mês de Janeiro teve uma previsão fora do intervalo de confiança, com uma diferença de 0,8319 com o limite superior e o mês de Junho superou o limite superior em cerca de 2,3288. A autora acredita que existe uma relação significativa das previsões superaram os seus limites com a subida aguda dos preços de combustíveis, que resultam da guerra da Rússia e Ucrânia, que resultam do barramento da exportação do combustível feito a Rússia.

Por conseguinte, os valores previstos da demanda do crédito imobiliário do Moza Banco da cidade de Maputo que foram descritos graficamente, foram transcrito em números na tabela (4.9), onde verificou alguma semelhança dos valores previstos estimados pelo modelo ajustado.

Tabela 4.9: Valores do Crédito previstos e observados

Mês/ano	Crédito Previsto	L_{infer} 95%	L_{Super} 95%	Crédito
Jan 2022	20.682.340	19.236.090	22.128.580	
Feb 2022	20.682.340	19.236.090	22.128.580	
Mar 2022	20.682.340	19.236.090	22.128.580	
Apr 2022	20.682.340	19.236.090	22.128.580	
May 2022	20.682.340	19.236.090	22.128.580	
Jun 2022	20.682.340	19.236.090	22.128.580	
Jul 2022	20.682.340	19.236.090	22.128.580	
Aug 2022	20.682.340	19.236.090	22.128.580	
Sep 2022	20.682.340	19.236.090	22.128.580	
Oct 2022	20.682.340	19.236.090	22.128.580	
Nov 2022	20.682.340	19.236.090	22.128.580	
Dec 2022	20.682.340	19.236.090	22.128.580	
Jan 2023	20.682.340	19.236.090	22.128.580	
Feb 2023	20.682.340	19.236.090	22.128.580	
Mar 2023	20.682.340	19.236.090	22.128.580	
Apr 2023	20.682.340	19.236.090	22.128.580	
May 2023	20.682.340	19.236.090	22.128.580	
Jun 2023	20.682.340	19.236.090	22.128.580	
Jul 2023	20.682.340	19.236.090	22.128.580	
Aug 2023	20.682.340	19.236.090	22.128.580	
Sep 2023	20.682.340	19.236.090	22.128.580	
Oct 2023	20.682.340	19.236.090	22.128.580	
Nov 2023	20.682.340	19.236.090	22.128.580	
Dec 2023	20.682.340	19.236.090	22.128.580	
Jan 2024	20.682.340	19.236.090	22.128.580	
Feb 2024	20.682.340	19.236.090	22.128.580	
Mar 2024	20.682.340	19.236.090	22.128.580	
Apr 2024	20.682.340	19.236.090	22.128.580	
May 2024	20.682.340	19.236.090	22.128.580	
Jun 2024	20.682.340	19.236.090	22.128.580	
Jul 2024	20.682.340	19.236.090	22.128.580	
Aug 2024	20.682.340	19.236.090	22.128.580	
Sep 2024	20.682.340	19.236.090	22.128.580	
Oct 2024	20.682.340	19.236.090	22.128.580	

Os valores previsto da aquisição do crédito imobiliário nos meses subsequentes desde 2022 a diante são constantes, o que leva a prever que o Moza banco, poderá disponibilizar o mesmo valor de 20.682.340mt mensalmente, aos clientes da cidade de Maputo que pretenderem adquirir crédito para aquisição ou reabilitação de algum bem imobiliário.

4.2 Discussão

Segundo o estudo realizado pelos autores Melchior *et al.*, (2019), através da metodologia Box & Jenkins foi verificado o comportamento e prever os financiamentos habitacionais no Brasil, onde a série foi duas vezes diferenciadas para que se tornasse estacionária, onde estimou se o ARIMA (1,2,1) e constatou se que o comportamento da série refletiu o impacto político advindo das trocas de governo analisadas desde o governo Lula até o governo de Temer. Em comparação com o modelo estimado a partir da demanda do crédito imobiliário da cidade de Maputo, verificou se que existe alguma diferença em relação a estacionariedade, pois, esse estudo é $I(0)$, ou seja, não apresenta raiz unitária como pode se ver pelo melhor modelo estimado que é SARIMA(1,0,2)(0,0,1)[12], já nesse estudo, acredita se que a situação das dívidas ocultas podem ter influenciado no comportamento dos valores previstos, que foram constantes para todo o intervalo dos valores previsto.

Por sua vez, de acordo com Moro *et al.*, (2018), para identificar o melhor modelo para o mercado imobiliário de São Paulo. Os resultados implicam que é possível fazer uso de modelos de previsão de vendas no sector imobiliário através da Metodologia Box & Jenkins, nesse estudo, enfatizou-se que o funcionamento do mercado habitacional brasileiro, onde o modelo que melhor se ajusta a previsão foi o SARIMA(2,1,0)(1,0,0)[12]. A série das vendas do sector imobiliário é $I(1)$, e a sua parte sazonal é que demonstrou ser $I(0)$. Embora as séries apresentem o comportamento sazonal, acredita se que, o comportamento dos valores previstos que são constantes, podem ser devido as políticas bancarias na expectativa de mitigar a inflação. Os resultados desses estudos, podem ser utilizadas para facilitar simulações macroeconômicas de políticas na área de geração de empregos, bem como na formulação de políticas públicas na área de habitação.

Capítulo 5

Conclusões e Recomendações

Neste capítulo, foram apresentadas as principais conclusões e recomendações consideradas pertinentes depois dos resultados obtidos a partir do estudo realizado, onde foi analisada a série da demanda do crédito imobiliário da Moza banco da cidade de Maputo.

5.1 Conclusões

Com base na análise da série da demanda do crédito imobiliário, composta por 96 observações, que resultaram de registos mensais dos clientes que procuraram o crédito no Moza banco entre 2012 à 2020, das análises foi possível descrever as seguintes conclusões:

- A maior e menor aquisição do crédito imobiliário disponibilizado pelo Moza banco na cidade de Maputo, foram verificados no segundo semestre de 2015 e 2017, além disso, a figura (4.1) demonstra algum comportamento aleatório das observações, o que sugere a estacionariedade da série da demanda do crédito imobiliário, facto confirmado pelo teste de raiz unitária do ADF, que confirmou a estacionariedade de série, o que quer dizer que, esta série é $I(0)$.
- Na etapa referente a estimação, foi possível selecionar adequadamente entre cerca os 22 modelos $ARIMA(p,d,q)$ e $SARIMA(p,d,q)(P,D,Q)$ [12], onde apenas um deles é que apresentou o menor critério de Informação de Akaike (AIC), levando a constatar que este seja o melhor modelo estimado. Deste modo, o modelo selecionado como o mais adequado para previsões foi o $SARIMA(1,0,2)(0,0,1)$ [12], com o $AIC = 173.312$, e verificou-se ainda que, este modelo apresentou um erro percentual médio absoluto de 21,32% que é a evidência para constatar que esse modelo fará previsões consideravelmente razoáveis, em comparação com os outros 21 modelos.
- As previsões da demanda do crédito imobiliário registadas para o período de Janeiro de 2022 ao mes de Outubro de 2024 é caracterizada por um valor previsto constante que é de 20.68230, esse facto levou a crer que o Moza banco da cidade de Maputo pode ter definido

um valor fixo para passar a disponibilizar aos credores que procuram o financiamento de crédito imobiliário.

5.2 Recomendações

Diante dos resultados obtidos, foram descritas as seguintes recomendações:

➤ Aos bancos comerciais

- A relevância desta monografia deve-se ao facto de que ira auxiliar aos gestores bancários na elaboração de melhores estratégias para a gestão de credito e minimizar os riscos de percas de investimentos.
- Sugere se a criação de políticas que melhorem a disponibilização de crédito imobiliário para jovens e regulação das taxas aplicadas no acto de pagamento, afinal de contas, na actual sociedade moçambicana, verifica-se um elevado número de jovens a criar a sua família em casa dos seus pais, situação agravada pelo custo de vida que os jovens enfrentam.

➤ À comunidade acadêmica

- São recomendados a utilizar dados actualizados do crédito imobiliário, com vista a obter informações mais actualizadas sobre a evolução ou comportamento da demanda do crédito imobiliário;
- Como proposta para estudos futuros, sugere-se investigar a relação de outras variáveis macroeconômicas com os financiamentos habitacionais utilizando-se a técnica de séries temporais baseada nos modelos de Vetores Autorregressivos (VAR);
- A utilização de dados com maior período de tempo faria com que o modelo representasse de forma mais fidedigna o comportamento real. Da mesma maneira, caberia a realização de um teste de causalidade entre a série de vendas de imóveis e lançamentos imobiliários, para buscar explicar da melhor forma este comportamento.

Referências

1. Agresti, A. (2007). An introduction to categorical data analysis. New Jersey, Florida, 2^a edição, Editora John Wiley and Sons;
2. Box, G. E. P. e Jenkins, G. M. (1970). Time Series Analysis: Forecasting and Control. San Francisco: Holden-day;
3. Box, G.E.P. e Jenkins, G.M. (1994). Times series analysis: forecasting and control. 3^a ed. Englewood Cliffs; Prentice Hall;
4. Cromwell, J. B., Labys W. C. & M. Terraza (1994): Univariate Tests for Time Series Models, Sage, Thousand Oaks, CA, pp.20–22;
5. Cowpertwait, P. e Metcalfe, A. (2009). Introductory Time Series with R., 1(3). Springer, Science+Business, LLC;
6. Enders, W. (1995). Applied Econometric Time Series. Wiley, New York;
7. Ehlers, R.S. (2005) Análise de Séries Temporais. Departamento de Estatística, UFPR. Disponível em <http://leg.est.ufpr.br/~ehlers/notas>. Acessado em: 21 Set. 2023;
8. Ferreira et al. (2016). Análise de Séries Temporais em R: um curso introdutório. <https://www.researchgate.net/publication/311111111>
9. Fonseca, J. S.; Martins, G. de A. e Toledo, G. L. (1985). Estatística aplicada. São Paulo: Atlas, p.267;
10. Freitas, A. A. C. (2007). Previsão de Séries Temporais via Seleção de Variáveis, Reconstrução Dinâmica, ARMA-GARCH e Redes Neurais Artificiais. Tese de Doutorado, Universidade Estadual de Campinas, São Paulo, Brasil;
11. Gujarati, D. N. (2000). Econometria Básica. 3^a ed. São Paulo: Pearson Makron Books;
12. Gujarati, D. N. (2006). Basic Econometrics, Nova York: McGraw-Hill;
13. Gujarati, D. N.; Porter, D. C. (2008). Basic econometrics. 5^a ed. McGraw-Hill New York;
14. Gujarati, D. N. e Porter, D. C. (2011). Econometria básica [recurso eletrônico]. 5^a ed. Porto Alegre: (Tradução de: Denise Durante, Mônica Rosemberg, Maria Lúcia G. L. Rosa). AMGH editora Ltad, New York: E-book;
15. Green, R. (1997). Follow the Leader: How Changes in Residential and Nonresidential Investment Predict Changes in GDP. (Siga o Líder: De que forma é que o Investimento Imobiliário Residencial e não Residencial Indica Alterações no PIB). Real Estate Economics, 25 (2): 253–70;

16. Hyndman, R. J. e Athanasopoulos, G. (2014). Forecasting: Principles and Practice. OTexts. Disponível em: <http://otexts.org/fpp/>;
17. Kirchner, R. M. (2006). Metodologia Box & Jenkins: Uma ferramenta de gestão, Santa Maria, Dissertação para obter o grau de Mestre em Engenharia da Produção, RS. Brasil;
18. Matos, O. C. (2000). Econometria Básica: teoria e aplicações. 3^a ed. São Paulo: Atlas;
19. Melchior, C.; Ricci, M. R.; Andrade, F. B. e Zanini, R. R. (2019). Roselaine Ruviaro Metodologia box-jenkins aplicada ao setor habitacional: um estudo de caso, recuperado em <https://doi.org/10.5585/ExactaEP.v17n4.8525>, acessado em 20/07/2023, Exacta, 17(4), pp. 283-298;
20. Morettin, P.A. e Toloí, C.M.C. (1987). Análise de Séries Temporais. pp. 357-407. São Paulo, editora atual;
21. Morettin, P. A. (2006). Econometria financeira: Um curso em séries temporais financeiras. São Paulo: Editora Edgard Blucher;
22. Morettin, P. A. e Toloí, C. M. C. (2004). Análise de Séries Temporais. São Paulo: Editora Edgard Blucher Lda;
23. Morettin, P. A. e Toloí, C. M. C. (2006). Instituto de Matemática e Estatística da Universidade de São Paulo . Site: Bibliografia <https://issuu.com/editorablucher/docs/issuu-analise-temporais-isbn9788521203896/5?e=1099747/5170484> consultado em Novembro de 2021;
24. Moro, M. F.; Vincezi, S. L.; Weise, A. D.; Flores, S. A. e Reis, C. C. C. (2018). A metodologia de box-jenkins aplicada à previsão de vendas para o mercado imobiliário de são paulo, Latin American journal of business management (LAJBM), v. 9, n. 1, pp. 185-202, jan-jun/2018, Taubaté, SP, Brasil;
25. Mynbaev, K. T. e Lemos, A. (2004). Manual de econometria. 1^a ed. Rio de Janeiro, FGV, 348p;
26. Nunes, V. P. (2016). Modelagem e Previsão do Índice Nacional de Preços ao Consumidor: O Uso da Metodologia de Boxx - Jenkins. in: Conferência Sul em Modelagem Computacional, 7^a ed., Rio Grande: Universidade Federal do Rio Grande (FURG), pp.776-782;
27. Lopes, R. D. (2002). Previsão de Autopeças : Estudo de caso em uma concessionária de veículos. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis;
28. Santos, A. V. (2003). Análise de modelos de séries temporais para a previsão mensal do imposto de renda. Dissertação submetida à coordenação do Curso de Pós-Graduação em Economia – CAEN, Universidade Federal do Ceará - FORTALEZA – CEARÁ;

29. Shafer, S. M.; Meredith, J. R. (1998). *Operations Management*. New York: John Wiley & Sons;
30. Sousa, R. C. e Camargo, M. E. (1996). *Análise de séries temporais: Os modelos ARIMA, SEDIGRAF*;
31. Stock, J. H.; Watson, M. W. (2004). *Econometria*. São Paulo: Addison Wesley;
32. Thomas, D. P. (2009). Revisiting Pedagogy of the oppressed: Paulo Freire and contemporary african studies. *Review of african political economy*, v. 36, n. 120, pp. 253-269, Doi: 10.1080/03056240903083268;
33. Tsay, R. S. (2001). *Analysis of Financial Time Series*. 1 ed. Wiley-Interscience;
34. Wanke, P.; Julianelli, L. (2006). *Previsão de vendas: processos organizacionais & métodos quantitativos e qualitativos*. São Paulo: Atlas,
35. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, v. 50, pp.159–175;

Anexos

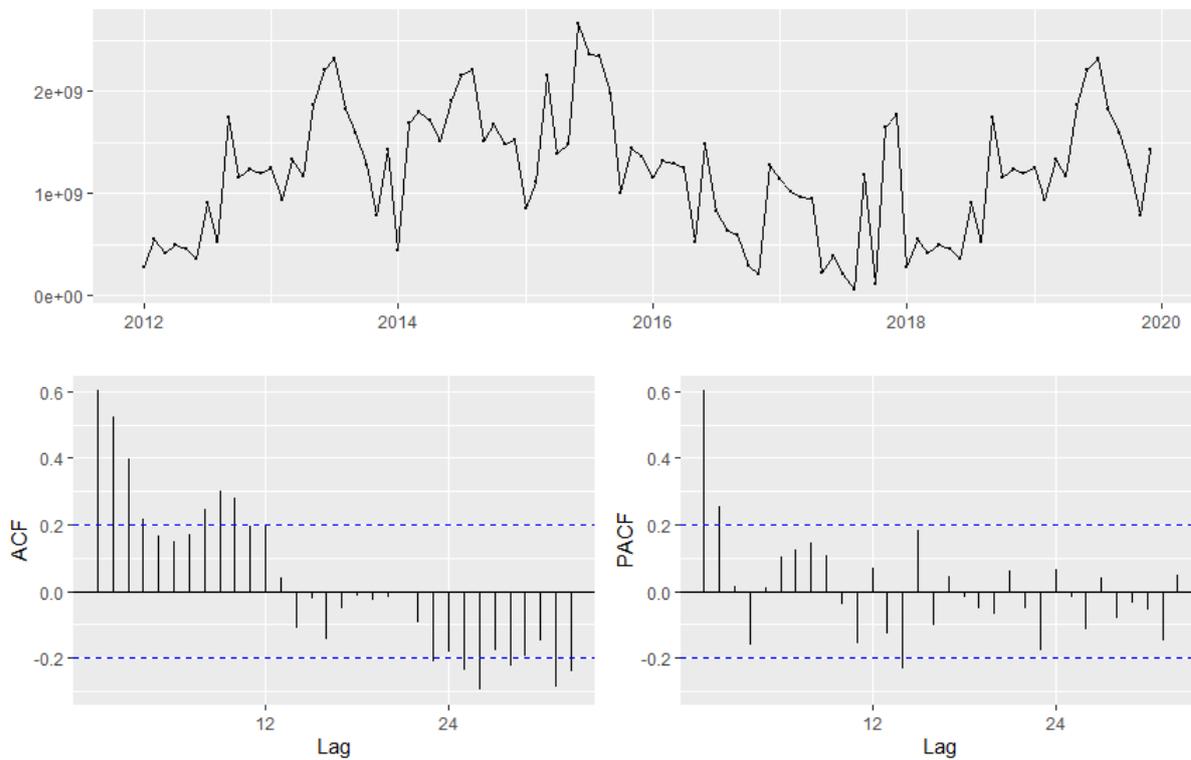


Figura 5.1: Representação do crédito imobiliário sem transformação

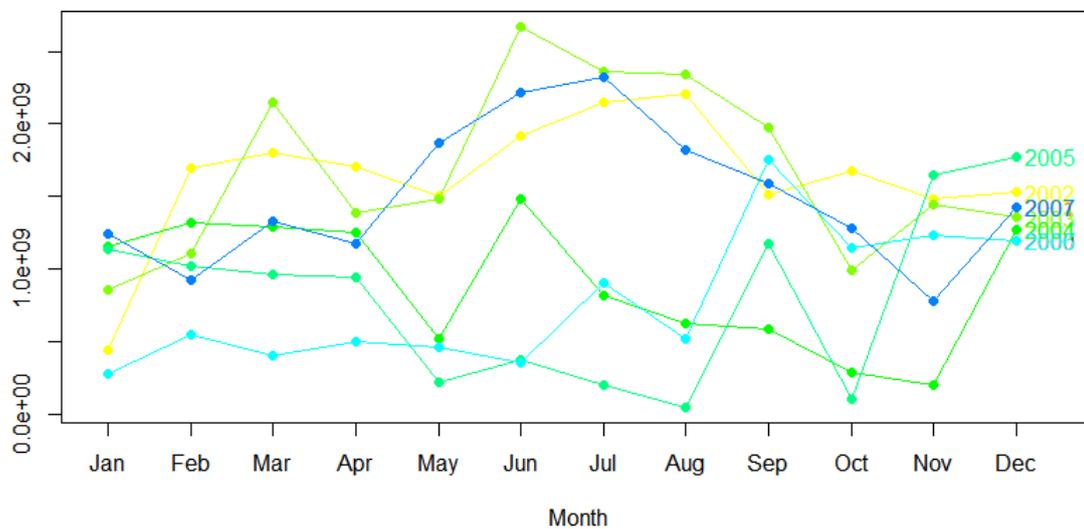


Figura 5.2: Sazonalidade do crédito imobiliário sem transformação

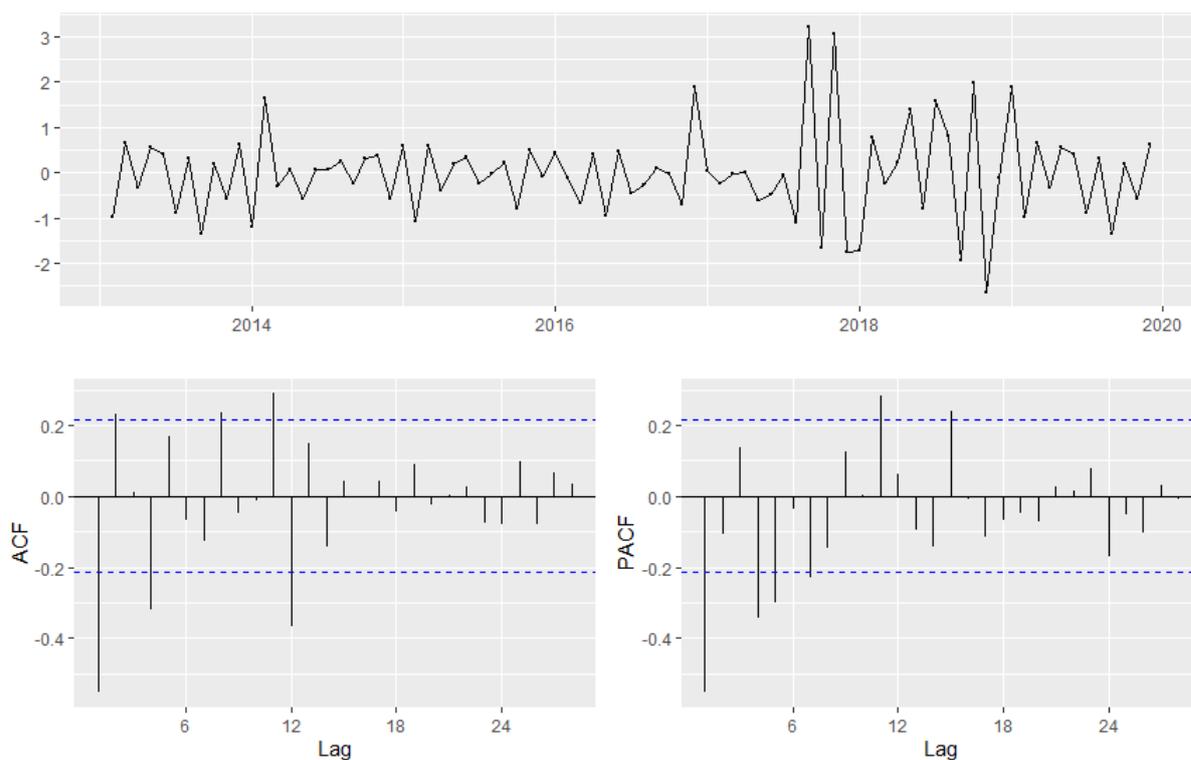


Figura 5.3: Sazonalidade mensal das 1^a diferenças do Crédito

Código usado para as análise

Importação dos dados

```
Credito<- read.csv[file.choose()]
Indice <- read.delim("C:/Users/fernando pc/Desktop/Faculdade/
Nelson/Credito.txt", delim = ";", escape_double = FALSE, + trim_ws = TRUE)
```

```
Credito
```

```
View(Credito)
```

Importação as bibliotecas

```
library(tseries)
```

```
library(forecast)
```

```
library(lmtest)
```

```
library(urca)
```

Criação de uma série e análise

```
crd=ts(Credito,start=c(2012,1),frequency=12)
```

```
ggtsdisplay(crd) # representação gráfica da série
```

```
seasonplot(crd, col=rainbow(12), year.labels = TRUE, type = "o", pch=16)
```

```
# verificação da sazonalidade
```

```
ndiffs(crd) % verificação o no de diferenciações necessárias para a série estacionaria
nsdiffs(crd) % verificação o no de diferenciações necessárias para manter a sazonalidade
da série estacionária série
```

Teste de raiz unitária

```
DFAj-ur.df(crd, type = "drift", selectlags = "AIC") # com constante
summary(DFA)
```

Transformação da séries e análise

```
lgcreditoj-log(Credito)
cred=ts(lgcredito,start=c(2012,1),frequency=12)
ggtsdisplay(cred) # representação gráfica da série transformada
seasonplot(cred, col=rainbow(12), year.labels = TRUE, type = "o", pch=16)
# verificação da sazonalidade
ndiffs(cred)
nsdiffs(cred)
```

Teste de raiz unitária depois da transformação

```
DFA1j-ur.df(cred, type = "drift", selectlags = "AIC") # com constante
summary(DFA1)
```

Ajuste dos modelos ARIMA sugestivos

```
auto.arima(cred, trace =TRUE, approximation = FALSE)
modeloj-Arima(cred, order=c(1,0,2), seasonal=c(0,0,1)) % Melhor modelo ajustado
summary(modelo)
```

Box-Pierce e Ljung-Box (Verificação dos presupostos)

```
T=length(modelo$residuals)
for(i in 1:floor(log(T)))
print(Box.test(modelo$residuals,lag=i,type="Box-Pierce"))
T=length(modelo$residuals)
for(i in 1:floor(log(T)))
print(Box.test(modelo$residuals,lag=i,type="Ljung-Box"))
```

Previsão dos proximos 48 meses a partir de 2022

```
modeloj-Arima(cred, order=c(1,0,2), seasonal=c(0,0,1))
prevj-forecast(modelo, h=48)
autoplot(prev)
prev
```

Análise residual

```
par(mfrow=c(2,2))  
plot(resid(modelo))  
qqnorm(resid(modelo))  
qqline(resid(modelo))  
acf(resid(modelo))  
pacf(resid(modelo))
```

Tabela 5.1: Crédito imobiliário

Jan/2012 - 2801000,00	Jan/2016 - 11574813,00
Fev/2012 - 5507335,00	Fev/2016 - 13230000,00
Mar/2012 - 4073000,00	Mar/2016 - 12883500,00
Abr/2012 - 4991406,65	Abr/2016 - 12519000,00
Mai/2012 - 4571955,95	Mai/2016 - 5234813,00
Jun/2012 - 3567816,76	Jun/2016 - 14854000,00
Jul/2012 - 9090961,75	Jul/2016 - 8226000,00
Jul/2012 - 5164853,95	Ago/2016 - 6291974,00
Ago/2012 - 17499660,50	Set/2016 - 5854000,00
Set/2012 - 11493729,16	Out/2016 - 2846000,00
Out/2012 - 12314000,00	Nov/2016 - 2031000,00
Nov/2012 - 11964707,00	Dez/2016 - 12729000,00
Dez/2012 - 12471000,00	Jan/2017 - 11374600,34
Jan/2013 - 9278572,00	Fev/2017 - 10173000,00
Fev/2013 - 13339000,00	Mar/2017 - 9677000,00
Mar/2013 - 11744000,00	Abr/2017 - 9448900,00
Mai/2013 - 18693000,00	Mai/2017 - 2176000,00
Jun/2013 - 22117000,00	Jun/2017 - 3788000,00
Jul/2013 - 23200000,00	Jul/2017 - 2001000,00
Ago/2013 - 18240000,00	Ago/2017 - 501000,00
Set/2013 - 15935391,78	Set/2017 - 11774000,00
Out/2013 - 12787350,00	Out/2017 - 1070000,00
Nov/2013 - 7775656,00	Nov/2017 - 16446000,00
Dez/2013 - 14295353,50	Dez/2017 - 17764000,00
Jan/2014 - 4460155,00	Jan/2018 - 2801000,00
Fev/2014 - 16925900,00	Fev/2018 - 5507335,00
Mar/2014 - 18025003,00	Mar/2018 - 4073000,00
Abr/2014 - 17100988,00	Abr/2018 - 4991406,65
Mai/2014 - 15053600,00	Mai/2018 - 4571955,95
Jun/2014 - 19141500,00	Jun/2018 - 3567816,76
Jul/2014 - 21518400,00	Jul/2018 - 9090961,75
Ago/2014 - 22084237,00	Ago/2018 - 5164853,95
Set/2014 - 15146000,00	Set/2018 - 17499660,50
Out/2014 - 16746398,00	Out/2018 - 11493729,16
Nov/2014 - 14854000,00	Nov/2018 - 12314000,00
Dez/2014 - 15275661,00	Dez/2018 - 11964707,00
Jan/2015 - 8527000,00	Jan/2019 - 12471000,00
Fev/2015 - 11107500,00	Fev/2019 - 9278572,00
Mar/2015 - 21529364,00	Mar/2019 - 13339000,00
Abr/2015 - 13857000,00	Abr/2019 - 11744000,00
Mai/2015 - 14813000,00	Mai/2019 - 18693000,00
Jun/2015 - 26686900,00	Jun/2019 - 22117000,00
Jul/2015 - 23595500,00	Jul/2019 - 23200000,00
Ago/2015 - 23455000,00	Ago/2019 - 18240000,00
Set/2015 - 19796000,00	Set/2019 - 15935391,78
Out/2015 - 9964000,00	Out/2019 - 12787350,00
Nov/2015 - 14466464,00	Nov/2019 - 7775656,00
Dez/2015 - 13563998,00	Dez/2019 - 14295353,50