

Universidade Federal de Minas Gerais
Departamento de Estatística
Programa de Pós-Graduação em Estatística

**PREVISÃO DA CONCESSÃO DE CRÉDITO À PESSOAS JURÍDICAS POR MEIO
DE MODELOS DE SÉRIES TEMPORAIS**

Henrique Celestino Ferreira

Belo Horizonte

2020

Henrique Celestino Ferreira

**PREVISÃO DA CONCESSÃO DE CRÉDITO À PESSOAS JURÍDICAS POR MEIO
DE MODELOS DE SÉRIES TEMPORAIS**

Versão Final

Monografia apresentada ao Programa de Pós-Graduação Lato-Sensu em Estatística do Departamento de Estatística da Universidade Federal de Minas Gerais como requisito para obtenção do título de Especialista em Estatística.

Orientadora: Ela Mercedes Medrano Toscano da Universidade Federal de Minas Gerais (UFMG) do Departamento de Estatística (DEST – UFMG)

Belo Horizonte

2020

© 2020, Henrique Celestino Ferreira
Todos os direitos reservados

Ficha catalográfica elaborada pela bibliotecária Irénquer Vismeg Lucas Cruz
CRB 6ª Região nº 819

Ferreira, Henrique Celestino

F383p Previsão da concessão de crédito a pessoas jurídicas por
meio de modelos de séries temporais/ Henrique Celestino Ferreira
— Belo Horizonte, 2020.
76 f. il.; 29 cm.

Monografia (especialização) - Universidade Federal de
Minas Gerais – Departamento de Estatística

Orientadora: Ela Mercedes Medrano Toscano

1. Estatística. 2. Análise de séries temporais.
3. Auto-regressão (Estatística). 4. Crédito bancário.
I. Orientadora. II. Título.

CDU 519.2(043)



Universidade Federal de Minas Gerais
Instituto de Ciências Exatas
Departamento de Estatística
Programa de Pós-Graduação / Especialização
Av. Pres. Antônio Carlos, 6627 - Pampulha
31270-901 – Belo Horizonte – MG


E-mail: pgest@ufmg.br
Tel: 3409-5923 – FAX: 3409-5924

ATA DO 211ª. TRABALHO DE FIM DE CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA DE HENRIQUE CELESTINO FERREIRA.

Aos dez dias do mês de julho de 2020, às 13:00 horas, com utilização de recursos de videoconferência a distância, reuniram-se os professores abaixo relacionados, formando a Comissão Examinadora homologada pela Comissão do Curso de Especialização em Estatística, para julgar a apresentação do trabalho de fim de curso do aluno **Henrique Celestino Ferreira**, intitulado: “Previsão da concessão de crédito a pessoas jurídicas por meio de modelos de séries temporais”, como requisito para obtenção do Grau de Especialista em Estatística. Abrindo a sessão, a Presidente da Comissão, Professora Ela Mercedes Medrano de Toscano – Orientadora, após dar conhecimento aos presentes do teor das normas regulamentares, passou a palavra ao candidato para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa do candidato. Após a defesa, os membros da banca examinadora reuniram-se sem a presença do candidato e do público, para julgamento e expedição do resultado final. Foi atribuída a seguinte indicação: o candidato foi considerado Aprovado condicional às modificações sugeridas pela banca examinadora no prazo de 30 dias a partir da data de hoje por unanimidade. O resultado final foi comunicado publicamente ao candidato pela Presidente da Comissão. Nada mais havendo a tratar, a Presidente encerrou a reunião e lavrou a presente Ata, que será assinada por todos os membros participantes da banca examinadora. Belo Horizonte, 10 de julho de 2020.

Profa. Ela Mercedes Medrano de Toscano (Orientadora)
Departamento de Estatística / UFMG

Profa. Sueli Aparecida Mingoti
Departamento de Estatística/UFMG



Prof. Roberto da Costa Quinino
Departamento de Estatística/UFMG



Universidade Federal de Minas Gerais
Instituto de Ciências Exatas
Departamento de Estatística
Programa de Pós-Graduação / Especialização
Av. Pres. Antônio Carlos, 6627 - Pampulha
31270-901 – Belo Horizonte – MG

E-mail: pgest@ufmg.br
Tel: 3409-5923 – FAX: 3409-5924

DECLARAÇÃO DE CUMPRIMENTO DE REQUISITOS PARA CONCLUSÃO DO CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA.

Declaro para os devidos fins que **Henrique Celestino Ferreira**, número de registro 2016673324, cumpriu todos os requisitos necessários para conclusão do curso de Especialização em Estatística, entregando a versão final do trabalho de conclusão de curso para sua orientadora, a professora Ela Mercedes Medrano de Toscano que aprovou a versão final. O trabalho foi apresentado no dia 10 de julho de 2020 com o título “Previsão da concessão de crédito a pessoas jurídicas por meio de modelos de séries temporais”,

Belo Horizonte, 19 de março de 2021

A handwritten signature in blue ink, which appears to read "Roberto da Costa Quinino".

Prof. Roberto da Costa Quinino
Coordenador do curso de
Especialização em Estatística
Departamento de Estatística / UFMG

AGRADECIMENTOS

A Deus, pelo dom da vida e do conhecimento.

A minha família, razão de minha existência.

A minha esposa, pelo incentivo e apoio incondicional.

Aos professores, pela dedicação e enormes contribuições para o meu aprimoramento e de todos os alunos.

Um agradecimento especial a professora Ela Mercedes, que apesar das dificuldades impostas por esse período de pandemia, não mediu esforços para me auxiliar na elaboração deste trabalho.

Ao professor Roberto Quinino, pela oportunidade.

Por fim, agradeço a todos que contribuíram, direta ou indiretamente para o alcance desse objetivo.

RESUMO

O presente trabalho teve por objetivo modelar séries de concessão de crédito às pessoas jurídicas através de técnicas de análise de séries temporais e realizar previsões a respeito do seu comportamento. Foram utilizados métodos de previsão baseadas nos modelos Auto Regressivos Integrados de Médias Móveis Sazonais (SARIMA) e Alisamento Exponencial de Holt-Winters. A partir da análise dos dados foi possível perceber a importância dos métodos estatísticos preditivos, em meio a relevância do processo de intermediação financeira. O desenvolvimento de mecanismos de controle, identificação e predição se tornam bem mais eficientes quando apoiados em metodologias econométricas. Enfim, por meio de todo o estudo realizado foi possível confirmar que as previsões geradas se mostraram aderentes ao processo de concessão de crédito no período de março de 2011 até novembro de 2019.

Palavras Chave: Crédito bancário; Modelos de previsão; Modelo SARIMA; Alisamento Exponencial de Holt-Winters.

ABSTRACT

The aim of this study was to model the series of banking credit concessions to firms and to generate forecasts about the behavior of that series. Forecasting methods based on the Integrated Auto Regressive Seasonal Moving Averages (SARIMA) and Holt-Winters Exponential Smoothing models were used. From the analysis of the data, it was possible to perceive the importance of statistical predictive methods, amidst the relevance of the financial intermediation process. The development of control, identification and prediction mechanisms becomes much more efficient when supported by econometric methodologies. Finally, through the entire study carried out, it was possible to confirm that the forecasts generated were adherent to the credit granting process from March 2011 to November 2019.

Keywords: Bank credit; Forecasting models; SARIMA model; Holt-Winters Exponential Smoothing

LISTA DE FIGURAS

FIGURA 1 - Análise Exploratória <i>CréditoTotal</i>	36
FIGURA 2 - Série de valores do <i>CréditoTotal</i> (período Março-2011 a Julho-2019).....	37
FIGURA 3 - Boxplot por ano e por mês da série <i>CréditoTotal</i>	37
FIGURA 4 - FAC e FACP da série <i>Crédito Total</i>	38
FIGURA 5 - <i>CréditoTotal</i> diferenciada	39
FIGURA 6 - FAC da Série <i>CréditoTotal</i> não sazonal (d=1 e D=1).....	39
FIGURA 7 - FACP da Série <i>CréditoTotal</i> não sazonal (d=1 e D=1)	39
FIGURA 8 - <i>CréditoTotal</i> e ajustados pelo modelo SARIMA (2,1,0) (1,1,0) sazonalidade = 12.....	41
FIGURA 9 - FAC e FACP dos resíduos do modelo SARIMA(2,1,0) (1,1,0) sazonalidade=12.....	42
FIGURA 10 - Análise de resíduos do modelo SARIMA(2,1,0) (1,1,0) sazonalidade=12.....	42
FIGURA 11 – Comparativo entre os valores da série <i>CréditoTotal</i> , no período de 06/2019 até 11/2019 e os valores previstos pelo modelo SARIMA(2,1,0) (1,1,0) sazonalidade =12.....	43
FIGURA 12 - FAC e FACP dos resíduos SARIMA (2,1,0) (0,1,1) sazonalidade = 12.....	45
FIGURA 13 - Análise de Resíduos do modelo SARIMA (2,1,0) (0,1,1) sazonalidade = 12.....	45
FIGURA 14 – <i>CréditoTotal</i> e ajustados pelo modelo SARIMA (2,1,0) (0,1,1) sazonalidade = 12.....	46

FIGURA 15 - Comparativo entre os valores da série <i>CréditoTotal</i> , no período de 06/2019 até 11/2019 e os valores previstos pelo modelo SARIMA (2,1,0) (0,1,1) sazonalidade = 12	46
FIGURA 16 - Série <i>CréditoTotal</i> e ajustados pelo método Holt-Winters.....	47
FIGURA 17 Comparativo entre os valores da série <i>CréditoTotal</i> , no período de 06/2019 até 11/2019 e os valores previstos do modelo Holt-Winters.....	47
FIGURA 18 - Análise exploratória <i>CréditoCP</i>	49
FIGURA 19 - Série de valores do <i>CréditoCP</i> (período Março-2011 a Julho-2019)	50
FIGURA 20 - Boxplot por ano e mês da série <i>CréditoCP</i>	50
FIGURA 21 - FAC e FACP da série <i>CréditoCP</i>	51
FIGURA 22 - Série <i>CréditoCP</i> diferenciada.....	51
FIGURA 23 - FAC da Série <i>CréditoCP</i> (d=1 e D=1)	52
FIGURA 24 - FACP da Série <i>CréditoCP</i> não sazonal (d=1 e D=1)	52
FIGURA 25 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12	54
FIGURA 26 - Análise de resíduos do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12	54
FIGURA 27 - <i>CréditoCP</i> e ajustados do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12	55
FIGURA 28 - Previsões do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12	55
FIGURA 29 - <i>CréditoCP</i> e ajustados pelo modelo SARIMA (0,1,1) (2,1,0) sazonalidade = 12	57
FIGURA 30 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1) (2,1,0) sazonalidade = 12	57

FIGURA 31 - Análise de resíduos do modelo SARIMA (0,1,1) (2,1,0) sazonalidade = 12	58
FIGURA 32 - Previsões do modelo SARIMA (0,1,1) (2,1,0) sazonalidade = 12	58
FIGURA 33 - Série <i>CréditoCP</i> e valores ajustados pelo modelo Winters	59
FIGURA 34 - Previsões do modelo Holt-Winters Aditivo	60
FIGURA 35 - Análise exploratória <i>CréditoLP</i>	62
FIGURA 36 - Série de valores do <i>CréditoLP</i> (período Março-2011 a Julho-2019)	63
FIGURA 37 - Boxplot por ano e por mês da série <i>CréditoLP</i>	63
FIGURA 38 - FAC e FACP da série <i>CréditoLP</i>	64
FIGURA 39 - Série <i>CréditoLP</i> diferenciada	64
FIGURA 40 - FAC da Série <i>CréditoLP</i> não sazonal (d=1 e D=1)	65
FIGURA 41 - FACP da Série <i>CréditoLP</i> não sazonal (d=1 e D=1)	65
FIGURA 42 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1)(0,1,1) sazonalidade = 12	66
FIGURA 43 - Análise de resíduos do modelo SARIMA (0,1,1) (0,1,1)	67
FIGURA 44 - <i>CréditoLP</i> e ajustados do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12	67
FIGURA 45 - Previsões do modelo SARIMA(0,1,1) (0,1,1) sazonalidade = 12	68
FIGURA 46 - <i>CréditoLP</i> e ajustados pelo modelo SARIMA (0,1,1) (1,1,0) sazonalidade = 12	69
FIGURA 47 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1) (1,1,0) sazonalidade = 12	69

FIGURA 48 - Análise de resíduos do modelo SARIMA (0,1,1) (1,1,0) sazonalidade = 12	70
FIGURA 49 - Previsões do modelo SARIMA(0,1,1) (1,1,0) sazonalidade =1270	
FIGURA 50 - <i>CréditoLP</i> e ajustados pelo modelo Holt-Winters.....	71
FIGURA 51 - Previsões Holt-Winters Aditivo	72

LISTA DE TABELAS

TABELA 1 - Comportamento teórico de FAC e FACP para alguns modelos..	26
TABELA 2 - Valores de AIC, BIC e Teste de normalidade para diferentes modelos univariados de <i>CréditoTotal</i>	40
TABELA 3 - Resultados da estimação do modelo SARIMA (2,1,1) (1,1,0) sazonalidade = 12 para a série <i>CréditoTotal</i> , no período de março/2011 até maio/2019	41
TABELA 4 - Comparativo entre os valores da série <i>CréditoTotal</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(2,1,0) (1,1,0) sazonalidade =12	43
TABELA 5 -Resultados da estimação do modelo SARIMA(2,1,0) (0,1,1) sazonalidade =12 para a série <i>CréditoTotal</i> no período de março/2011 até maio/2019	44
TABELA 6 - Comparativo entre os valores da série <i>CréditoTotal</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(2,1,0) (0,1,1) sazonalidade = 12	46
TABELA 7- Comparativo entre os valores da série <i>CréditoTotal</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo Holt-Winters Aditivo.....	48
TABELA 8 - Medidas de Acurácia para a série <i>CréditoTotal</i> (Período amostral)	48
TABELA 9 - Medidas de Acurácia para a série <i>CréditoTotal</i> (Período de validação).....	48
TABELA 10 - Valores de AIC, BIC e Teste de normalidade para diferentes modelos univariados de <i>CréditoCP</i>	53
TABELA 11 -Resultados da estimação do modelo SARIMA(0,1,1) (0,1,1) sazonalidade = 12	53

TABELA 12 - Comparativo entre os valores da série <i>CréditoCP</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (0,1,1) sazonalidade = 12	55
TABELA 13 - Resultados da estimação do modelo SARIMA(0,1,1) (2,1,0) sazonalidade = 12	56
TABELA 14 - Comparativo entre os valores da série <i>CréditoCP</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (2,1,0) sazonalidade = 12	58
TABELA 15 - Comparativo entre os valores da série <i>CréditoCP</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo Holt-Winters Aditivo.....	60
TABELA 16 - Medidas de Acurácia (Período amostral).....	60
TABELA 17 - Medidas de Acurácia (Período de validação).....	61
TABELA 18 - Resultados da estimação do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12	66
TABELA 19 - Comparativo entre os valores da série <i>CréditoLP</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (0,1,1) sazonalidade = 12	68
TABELA 20 - Resultados da estimação do modelo SARIMA(0,1,1) (1,1,0) sazonalidade = 12	68
TABELA 21 - Comparativo entre os valores da série <i>CréditoLP</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (1,1,0) sazonalidade = 12	71
TABELA 22- Comparativo entre os valores da série <i>CréditoLP</i> , no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo Holt-Winters	72
TABELA 23 - Medidas de Acurácia (Período amostral).....	72
TABELA 24 -Medidas de Acurácia (Período de validação).....	73

SUMÁRIO

1. INTRODUÇÃO	11
1.1. Justificativa	13
1.2. Objetivo Geral	14
1.3. Objetivos Específicos.....	14
2. FUNDAMENTAÇÃO TEÓRICA	15
2.1. O Processo De Intermediação Financeira	15
2.2. Considerações Sobre Crédito Bancário	17
2.3. Panorama Do Mercado De Crédito	18
3. METODOLOGIA	21
3.1. Séries Temporais	22
3.2. Utilização de operadores	23
3.3. Função de auto correlação e Função de auto correlação Parcial	23
3.4. Modelos de Box-Jenkins.....	25
3.4.1. Modelos ARIMA.....	25
3.4.1.1. Identificação de Modelos ARIMA.....	26
3.4.1.2. Estimação de Parâmetros.....	27
3.4.2. Modelos SARIMA.....	28
3.4.2.1. Identificação e Estimação de modelos SARIMA.....	30
3.5. Modelos Alisamento Exponencial de Holt - Winters Aditivo.....	31
3.6. verificação e escolha dos modelos.....	32
4. ANÁLISE DOS RESULTADOS	35
4.1. Concessões De Crédito - Total	36
4.2. Concessões de crédito - capital de giro curto prazo.....	49
4.3. Concessões de crédito - Capital de giro Longo Prazo	62
5. CONSIDERAÇÕES FINAIS	73
REFERÊNCIAS.....	75

1. INTRODUÇÃO

O processo de intermediação de recursos pelas instituições financeiras tem cada vez mais importância na atividade econômica agindo como um facilitador no que diz respeito ao repasse de recursos de agentes superavitários para agentes deficitários através das operações de crédito. Esse processo tem como objetivo fomentar atividades da economia por meio de aquisição de bens ou serviços, investimento em infraestrutura ou mesmo na gestão do fluxo de caixa dos agentes econômicos.

De forma geral, as instituições financeiras dependem de previsões assertivas a respeito do volume de concessões de crédito para viabilizar a correta destinação dos recursos financeiros entre o amplo portfólio de produtos oferecidos ao mercado. Assim, é possível maximizar os resultados sem que haja problemas com excesso de demanda causado por uma destinação de recursos inferior a necessidade do mercado e, no caso oposto, ociosidade na sua utilização, causado por uma concentração maior que a demanda exigida (ABITANTE, 2007).

Os agentes financeiros com estratégias bem definidas e que melhor se aproximam da realidade do mercado, tendem a obter resultados mais significativos. A tomada de decisão e a formulação dos objetivos estratégicos dependem da análise do desempenho passado e da projeção dos resultados futuros.

Diante desse cenário, a aplicação de métodos preditivos pode contribuir com o processo de intermediação financeira, facilitando a movimentação de recursos entre os agentes econômicos, baseado em metodologias estatísticas relacionadas ao comportamento do mercado de crédito.

Portanto, buscou-se reunir dados e informações com o propósito de responder ao seguinte problema de pesquisa: De que forma a análise de séries temporais pode contribuir para o aprimoramento do processo de concessão de crédito?

A proposta deste trabalho visa apresentar estudos acerca da estimação de modelos estatísticos de acompanhamento e previsão de séries referentes a concessão de crédito destinada as pessoas jurídicas. A intenção é utilizar a própria

série, construindo modelos univariados baseados no passado da série original através da metodologia de séries temporais ou através da técnica de alisamento exponencial.

A previsão e o acompanhamento de uma série de concessão de crédito é extremamente desafiadora e complexa, visto que a série depende ou está relacionada a diversos fatores macroeconômicos que muitas vezes não podem ser explicados unicamente observando o passado da série. O nível de investimento das empresas, a capacidade instalada por parte dos empresários, a taxa de câmbio, a estabilidade do mercado financeiro e de crédito e a taxa de juros são alguns exemplos extremamente típicos e que podem influenciar no comportamento da série.

Portanto, esta seção introdutória tem como objetivo apresentar a ideia geral do trabalho, que é a construção de modelos univariados, ou seja, aqueles que não utilizam outras variáveis que não as próprias séries de interesse, e a partir disso, verificar as limitações desses modelos com relação a sua utilização para fazer previsões.

Além desta introdução, o presente trabalho possui outras quatro seções. A seção 2 contém uma revisão bibliográfica acerca dos temas seguintes: o processo de intermediação financeira, algumas definições sobre o crédito bancário e por fim panorama sobre o mercado de crédito brasileiro. Na seção 3 é descrito o tipo de pesquisa e a metodologia econométrica de séries temporais utilizado no trabalho. Os resultados e discussões são apresentados na seção 4. Os modelos estimados e o desempenho relacionado as previsões também são discutidas nessa seção. Finalmente, a seção 5 conclui o estudo, apresentando as considerações finais sobre os objetivos propostos.

1.1. Justificativa

A atividade de intermediação de recursos financeiros na economia brasileira tem ganhado cada vez mais notoriedade, obrigando os órgãos regulatórios e as instituições financeiras à desenvolverem mecanismos de controle, identificação e predição mais eficientes e eficazes a respeito do comportamento dos agentes econômicos em relação a utilização do crédito bancário.

Para tanto, métodos estatísticos de previsão, se tornam cada vez mais necessários, em meio a relevância da intermediação financeira, já que facilitam a mensuração acerca do volume de concessões de créditos e conseqüentemente potencializam a otimização, por parte destas instituições, sobre a melhor forma de alocação dos recursos.

O que impulsionou a realização deste trabalho foi entender como a elaboração de métodos preditivos pode contribuir para o desenvolvimento de estratégias mais eficientes no processo de intermediação financeira, facilitando a movimentação de recursos entre os agentes econômicos, baseado em metodologias econométricas.

1.2. Objetivo Geral

O presente trabalho tem como objetivo geral modelar séries de concessão de crédito através de técnicas de análise de séries temporais e realizar previsões a respeito do seu comportamento.

1.3. Objetivos Específicos

- Apresentar o processo de intermediação financeira e os conceitos relacionados ao crédito bancário;
- Mostrar como os métodos de Séries Temporais de Box e Jenkins e Alisamento Exponencial de Holt-Winters, podem ser empregados na identificação de padrões e predição em séries de concessão de crédito;
- Avaliar a capacidade preditiva e as limitações dos modelos ajustados.

2. FUNDAMENTAÇÃO TEÓRICA

Nesta seção é apresentada uma breve revisão bibliográfica sobre assuntos que permitem o entendimento a respeito do crédito bancário e da intermediação financeira, dividida em três seções. A seção 2.1, trata sobre o processo de intermediação financeira. A seção 2.2 trata a respeito de algumas definições importantes relacionadas ao crédito bancário. Por fim, a seção 2.3 traz um breve panorama sobre a concessão de crédito recente no mercado brasileiro.

2.1. O Processo de Intermediação Financeira

A atividade de intermediação financeira está intimamente ligada a ideia de circulação de riqueza. A captação de recursos de agentes superavitários e a sua disponibilização para agentes deficitários permite que a economia se desenvolva com melhor fluidez e, além disso, remuneram as entidades responsáveis por esse processo por meio de cobrança de juros. O conceito de moeda, como função de intermediária de troca permitiu que a economia baseada no escambo evoluísse, na medida em que facilitava a especialização e a divisão do trabalho (SILVA, 2016).

Segundo Silva e Luiz (2018), o processo de intermediação financeira tem um custo, que é a taxa de juros ou o preço da moeda. Para que os agentes superavitários concordem em transferir seus recursos para os deficitários é necessário que sejam remunerados mediante essa taxa de juros. Isso ocorre diretamente através do sistema financeiro que recebe recursos oriundos da diferença entre a taxa de juros paga aos poupadores e a cobrada dos tomadores de empréstimos, também conhecido pelo termo inglês *spread*.

A partir do momento em que uma economia se desenvolve e se fortalece, existe também a necessidade de um sistema financeiro regido por uma série de instrumentos e instituições financeiras que permitam a regulação do mercado e a maximização de riquezas, através da troca de ativos financeiros. O Sistema Financeiro Nacional (SFN), coordena a atividade de intermediação financeira no Brasil, propiciando que os agentes econômicos, sejam eles, superavitários ou deficitários, conquistem seus objetivos estimulando a circulação de riqueza no país (NETO e SÉRGIO, 2009).

Segundo Lanzana (2017) para controlar a liquidez da economia o governo se utiliza da política monetária. O autor deixa claro que “com esse objetivo, o governo atua sobre a quantidade de moeda na economia, sobre a capacidade de concessão de empréstimos por parte dos bancos e, por consequência, sobre os níveis das taxas de juros. Na realidade, o mercado monetário é como outro qualquer, onde existe demanda (por moeda), oferta (de moeda) e preço de equilíbrio, que nada mais é do que a taxa de juros (LANZANA, 2017, p. 41)”.

Ainda, de acordo com Lanzana (2017, p. 7):

Para controlar as condições de crédito (custo, volume etc.), o governo utiliza a política monetária. Para isso, ele pode aumentar/diminuir o dinheiro que circula na economia (que o Banco Central emite), pode aumentar/diminuir a capacidade de os bancos emprestarem (obrigando os bancos a depositarem parcela maior ou menor de seus recursos no Banco Central, que é o depósito compulsório) e, ainda, atuar sobre as taxas de juros quando vende ou compra seus títulos no mercado. Pode também fixar a taxa de juros. Tudo isso se refere à política monetária.

Conforme explicado acima, a política monetária influencia diretamente na capacidade de concessão de crédito das instituições financeiras, seja atuando no controle da disponibilidade de recursos ou na definição da taxa de juros. Para Wooldridge (2016) uma abordagem econométrica se torna relevante, nestes casos, pois permite a criação de modelos econômicos, baseados em equações matemáticas que descrevam o conjunto de comportamentos que permitam a tomada de decisões nos negócios. A premissa básica que fundamenta esse modelo é a maximização de utilidade, considerando à restrição de recursos.

Silva (2016) afirma que os bancos prestam diversos serviços que complementam algumas necessidades das pessoas. Por outro lado, o desenvolvimento do sistema financeiro, em um ambiente cada vez mais globalizado, gera transações cada vez mais complexas e que estão sujeitas a risco de perdas que podem afetar diretamente a vida financeira dos envolvidos. O autor mostra que:

A intermediação financeira em suas operações básicas tem como matéria-prima os depósitos (dinheiro) efetuados pelos clientes, ao mesmo tempo em que os produtos finais são os empréstimos e financiamentos (dinheiro). O mercado financeiro torna-se cada vez mais sofisticado em termos de desenvolvimento tanto de novos produtos quanto nos instrumentos de gestão de risco (SILVA, 2016, p. 29).

Podemos perceber que conforme citado acima, a gestão de risco é extremamente importante para a solidez e a perenidade do mercado financeiro. Nesse sentido, a maximização de resultados, baseados em uma diminuição nos níveis de risco, oferece uma série de possibilidades para a criação de modelos econômicos tratáveis e previsões bem definidas.

2.2. Considerações Sobre Crédito Bancário

O crédito pode ter várias definições, a depender do contexto que é utilizado. No escopo desse trabalho pode ser entendido como uma fonte extra de recursos obtidos de terceiros com a finalidade de antecipar a realização de um objetivo. Nesse sentido pode-se dizer que consiste na entrega de um valor presente mediante promessa de pagamento (SILVA, 2016).

Como bem nos assegura Neto e Sérgio (2009) o crédito está ligado à vontade ou disposição de algum indivíduo, em ceder parte de seu patrimônio, mesmo que temporariamente, esperando que o retorno integral da parcela ocorra no período acordado. Assim, fica claro que o crédito tem um papel de facilitador das relações comerciais. Dessa forma, ele cumpre um importante papel, no momento em que permite a circulação de riqueza e o atendimento da necessidade de agentes econômicos. Nesse sentido, uma avaliação do risco, pressupõe informações cadastrais detalhadas e fidedignas, que permitam estimar a possibilidade de não devolução dos recursos e calcular a capacidade de cada tomador em se endividar. Sendo assim, a concessão de crédito relaciona-se diretamente com uma parcela de incerteza, por isso deve ser adequada e suficientemente ponderada, buscando minimizar os riscos a que as instituições financeiras estão expostas.

Conforme explicado acima, o crédito possui um importante viés social, influenciando na atividade financeira de empresas e no consumo das famílias. As instituições financeiras, por sua vez, utilizam-se desse instrumento como uma de suas principais fontes de receita, se beneficiando das elevadas taxas de juros, historicamente praticadas no país. Com isso, a correta alocação dos recursos para atendimento da demanda de crédito permite uma otimização dos lucros e uma proteção do patrimônio em caso de cenários desfavoráveis.

A concessão de crédito num banco comercial, portanto, consiste em emprestar dinheiro, isto é, colocar à disposição do cliente determinado valor

monetário em determinado momento, mediante promessa de pagamento futuro, tendo como retribuição por essa prestação de serviço determinada taxa de juros, cujo recebimento poderá ser antecipado, periódico ou mesmo ao final do período, juntamente com o principal emprestado. Existem, além da operação de empréstimo, diversas outras operações de crédito, como financiamento de bens para os clientes, concessão de fianças, desconto de duplicatas, aplicações compulsórias (SILVA, 2016, p. 49).

Fica evidente, que o crédito cumpre um importante papel no desenvolvimento da atividade econômica do país. O processo de intermediação financeira, abordado no item 2.1, se caracteriza como um dos pilares do desenvolvimento da economia, no momento em que permite a transferência dos recursos entre os agentes econômicos e ainda é um importante meio de alavancagem de resultados das instituições financeiras.

2.3. Panorama do Mercado De Crédito

O mercado de crédito brasileiro sempre se caracterizou pelo baixo volume de concessão e o elevado custo do crédito. Antes de julho de 1994, data da implementação do Plano Real, a inflação elevada permitia que as instituições financeiras concentrassem seus esforços na captação de recursos de terceiros e lucrassem com as transferências inflacionárias, deixando a concessão de crédito em segundo plano. A década de 1990 trouxe grandes expectativas de mudanças para esse mercado, pois além da estabilização dos preços com o plano real, houve abertura do mercado para participação de bancos estrangeiros, além de importantes mudanças na estrutura da política econômica.

Historicamente, o *spread* das instituições financeiras brasileiras sempre esteve entre um dos maiores do mundo. Isso significa que sempre houve um alto custo do crédito e uma reduzida remuneração aos depósitos à vista captados. A instituição do Plano Real, em 1994, contribuiu para que a concessão de crédito assumisse um lugar de destaque na estratégia dos agentes econômicos na medida em que trouxe uma estabilização dos preços, e conseqüente redução da receita obtida através de transferências inflacionárias (FABIANI, 2011).

A transição brasileira para um cenário de inflação controlada, apesar de alguns momentos de elevada volatilidade macroeconômica trouxeram uma nova perspectiva para o setor bancário. Aqueles que não se adaptaram ao novo panorama de baixa

inflação foram incorporados pelas instituições mais fortes ou por competidores estrangeiros beneficiados pela liberação bancária ocorrida após 1988. Contudo, a expectativa frustrada de expansão do crédito de maneira sustentável e que equiparasse o nível de crédito da economia brasileira ao de países desenvolvidos impactou negativamente a retomada do crescimento econômico no Brasil (BRUGNOLA, 2009).

A perspectiva de estabilidade de preços que antecedeu a implantação do Plano Real, a sua confirmação ao longo dos meses seguintes e a redução do *float*, importante fonte de receita das instituições financeiras, implicaram no desencadeamento de um processo de ajuste tanto na estrutura organizacional quanto na própria forma de atuação dessas instituições. Neste contexto, houve uma acentuada redução do número de instituições do sistema financeiro brasileiro a partir da implementação do plano (ABITANTE, 2007, p. 68).

De acordo com Brugnola (2009), a trajetória da taxa básica de juros e o aumento da liquidez na economia fizeram com que os bancos adotassem mudanças expressivas na estrutura patrimonial e alocação de ativos com aumento na participação de crédito em detrimento a ativos de maior liquidez, como títulos e valores mobiliários.

Alguns eventos levaram a essa tomada de decisão importante:

- Julho de 1994: estabilização inflacionária promovida pelo Plano Real;
- Julho de 1999: adoção do regime de metas de inflação;
- Abril de 2003: primeira trajetória de queda na taxa de juros após forte aumento em fins de 2002;
- Setembro de 2005: novo movimento de redução da taxa de juros.

O período de 2003 a 2008 foi marcado por uma expansão no crédito superior ao crescimento do PIB, alavancado pela concessão de crédito as pessoas físicas, que prevaleceram sobre as demais.

A evolução do crédito no período de 2008 até 2013 foi fundamental para a rápida reação, frente a crise econômica, contribuindo para o crescimento do país naquele momento. A utilização dos bancos públicos como instrumentos de política monetária, atuando na ampliação do crescimento do crédito e na redução do spread bancário se mostrou bastante eficiente (DIEESE, 2018)

Com base no autor Fabiani (2011, p. 17) "no Brasil, o mercado de crédito bancário é especialmente importante por se tratar da principal fonte de financiamento de pessoas físicas e jurídicas". Pode-se dizer que a atividade econômica está diretamente ligada ao mercado financeiro, sendo um dos principais responsáveis pela ampliação ou retração do crescimento da atividade econômica.

3. METODOLOGIA

De acordo com Köche (2002), a pesquisa experimental permite que o investigador, através da análise do problema e a criação de hipóteses, avalie a relação entre causas e efeitos de um determinado fenômeno, manipulando os possíveis fatores e as variáveis, avaliando de que forma elas se relacionam com as hipóteses preditas.

Para Prodanov e Freitas (2013, p. 51) a pesquisa aplicada objetiva gerar conhecimentos para aplicação prática dirigidos à solução de problemas específicos. Envolve verdades e interesses locais. Devido aos fins práticos que a estimação de modelos preditivos apresenta utilizaremos como natureza da pesquisa aplicada.

Dessa forma, o presente trabalho caracteriza-se como sendo uma pesquisa exploratória, já que “o objetivo principal desse tipo de pesquisa é justamente conhecer melhor o fenômeno ou algum aspecto específico dele.” (NIELSON, OLIVO e MORILHAS, 2018, p. 69).

A pesquisa quantitativa considera que tudo pode ser quantificável, as informações e opiniões podem ser traduzidas em números, usando recursos e técnicas estatísticas. Através da formulação de hipóteses e da classificação da relação entre as variáveis é possível evitar contradições no processo de análise e interpretação dos resultados. (PRODANOV e FREITAS, 2013)

Conforme citado acima, e devido ao uso de metodologia econométrica no tratamento dos dados apresentados, essa pesquisa terá uma abordagem quantitativa. Os tópicos que seguem descrevem os modelos univariados utilizados para a concessão do crédito bancário.

Finalmente, os dados a serem utilizados são de natureza não experimental, isto é, não são acumulados por meio de experimentos controlados de indivíduos, empresas ou segmentos da economia. (Dados não experimentais são, às vezes, chamados de dados observacionais ou dados retrospectivos para enfatizar o fato de que o pesquisador é um coletor passivo de dados) (WOOLDRIDGE, 2016, p. 26).

3.1. Séries Temporais

Uma série temporal é um conjunto de observações dos valores que uma variável assume em diferentes momentos do tempo (GUJARATI e PORTER, 2011, p. 45).

Para Morettin e Tolo (2018) uma série temporal Y_t pode ser escrita como uma soma de três componentes não observáveis,

$$Y_t = T_t + S_t + a_t$$

na qual T_t e S_t representam tendência e sazonalidade, respectivamente, enquanto que a_t é uma componente aleatória de média zero e variância constante σ^2 .

A análise de séries temporais pressupõe interesse na previsão de valores futuros, na análise descritiva da série ou mesmo na identificação de padrões relevantes nos dados. Para tanto, modelos probabilísticos ou modelos estocásticos, devem ser estimados de forma simples e parcimoniosa, permitindo, aos interessados a sua manipulação sem maiores dificuldades (MORETTIN e TOLOI, 2018).

Como bem nos assegura Morettin (2011), pode-se dizer que uma das premissas básicas que deve ser consideradas ao se analisar uma série temporal é que ela seja considerada estacionária, o que significa dizer, nesse caso, que o processo estocástico possui média e variância constante no tempo. É interessante, aliás, afirmar que caso não seja verificada a estacionariedade da série original, será necessário transformá-la de modo a atender tal condição. O mais importante, contudo, é lembrar que a violação dessa suposição pode resultar em inferências errôneas a respeito das relações entre as variáveis em todo esse processo.

Segundo (MORETTIN e TOLOI, 2018), a transformação mais comum, seria realizar as diferenciações sucessivas da série original até que fosse encontrada uma série estacionária, o que geralmente ocorre na primeira ou segunda diferenciação.

Dessa forma, dada a relevância dentro da metodologia de Box e Jenkins, as próximas seções abordarão a utilização de operadores, o conceito de Função de auto correlação (FAC) e Função de auto correlação parcial (FACP) e o conceito de “ruído branco”.

3.2. Utilização de operadores

A familiaridade com a notação de operadores é de extrema importância para o entendimento e compreensão das equações e formulas dos modelos construídos, em função de ser bastante utilizado por Box e Jenkins (2008) na descrição dos modelos. Na prática, três tipos de operadores são suficientes:

- Operador de retardo ou de translação para o passado denotado por B e definido por: $B^k Y_t = Y_{t-k}$
- Operador de diferença (Δ): $Z_t = \Delta Y_t = Y_t - Y_{t-1} = (1 - B)Y_t$ onde $\Delta = 1 - B$
- Operador de diferença sazonal (S): $Z_t = S Y_t = Y_t - Y_{t-S} = (1 - B^S)Y_t$ onde $\Delta = 1 - B^S$

3.3. Função de auto correlação e Função de auto correlação Parcial

As funções de auto correlação (FAC) e auto correlação parcial (FACP) são utilizadas para auxiliar na modelagem de estruturas de dependência naturalmente presentes em observações ordenadas no tempo.

A auto correlação serve para medir o comprimento da memória de um processo, ou seja, a extensão para qual o valor tomado no tempo t depende daquele tomado no tempo $t - k$,

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

Onde, $\rho_0 = 1$ e $\rho_{-k} = \rho_k$.

Segundo Gujarati e Porter (2011), na prática, apenas temos a realização(amostra) de um processo estocástico. Sendo assim a função de correlação amostral, com defasagem k é simplesmente a razão da covariância da amostra (com defasagem k) e a variância da amostral:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}, k = 0, 1, 2, \dots$$

Onde:

$$\hat{\gamma}_k = \frac{\sum (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{n}$$

$$\hat{\gamma}_0 = \frac{\sum(Y_t - \bar{Y})^2}{n}$$

Em que n é o tamanho da amostra e \bar{Y} é a média amostral.

Dessa forma, o gráfico da função de auto correlação amostral(FAC) é simplesmente um gráfico $\hat{\rho}_k$ versus k , também chamado de correlogramas. Pode-se, então calcular os intervalos de confiança com um nível de 5% de significância e testar a hipótese de que as correlações são estatisticamente diferentes de zero. Considerando que $\hat{\rho}_k \sim Normal(0, S_{\hat{\rho}_k})$, onde:

$$S_{\hat{\rho}_k} \cong \sqrt{\frac{1}{n} (1 + 2\hat{\rho}_1^2, \dots, \hat{\rho}_{k-1}^2)}$$

A auto correlação parcial permite identificar a variável no instante t e uma de suas defasagens, retirado o efeito de outras defasagens. Ela mensura a correlação linear entre Y_t e Y_{t-k} depois de removidas as dependências lineares das variáveis $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$. A auto correlação parcial no lag k pode ser estimada a partir do coeficiente de regressão:

$$Y_t = \phi_{1kk} Y_{t-1} + \dots + \phi_{1kk} Y_{t-k} + a_t$$

$$\hat{\phi}_{kk} = Corr(Y_t, Y_{t+k0} / Y_{t+1}, \dots, Y_{t+k-1})$$

Do mesmo modo que no caso anterior, as correlações amostrais parciais também seguem uma distribuição normal com desvio padrão $S_{\phi_{kk}} \cong \sqrt{\frac{1}{n}}$. Assim, também é possível testar a hipótese se as auto correlações parciais são estatisticamente diferentes de zero, calculando os limites com um nível de 5% de significância.

Durante o processo de modelagem, um dos principais objetivos é encontrar resíduos que se comportem como um processo ruído branco. Chama-se processo estocástico puramente aleatório ou de ruído branco se ele tem média constante, variância constante σ^2 e é serialmente não correlacionado. Caso um termo de erro seja distribuído independentemente e identicamente como uma distribuição normal com média zero e variância constante, tal processo é chamado de ruído branco gaussiano (GUJARATI e PORTER, 2011).

3.4. Modelos de Box-Jenkins

Box e Jenkins (2008) propõem ainda um método baseado em um ciclo interativo para a construção do modelo, composto por estágios: Especificação, identificação, estimação e verificação, onde, ao fim desta última etapa conclui-se, através da avaliação do modelo se o mesmo está adequado. Em caso negativo, retorna-se a fase inicial até que o modelo com os melhores parâmetros seja estimado.

A seguir estão definidos os estágios do ciclo interativo:

- Identificação do modelo com base na análise das funções de auto correlações(FAC), auto correlações(FACP) parciais e outros critérios;
- Estimação dos parâmetros do modelo estimado;
- Verificação do modelo ajustado, através da análise de resíduos;

3.4.1. Modelos ARIMA

A grande maioria das séries temporais encontradas na prática não são estacionárias, no entanto, como já foi mencionado, quando tomamos a série diferenciada ela se torna estacionária. Então podemos dizer que uma diferenciação de ordem “d” aplicada a série não estacionária, $Z_t = (1 - B)^d Y_t$ se torna estacionária e segue um modelo ARMA(p,q):

$$\Phi_p(B)Z_t = \Theta_q(B)a_t$$

então o modelo para a série Y_t é da forma:

$$\Phi_p(B)(1 - B)^d Y_t = \Theta_0 + \Theta_q(B)a_t$$

onde:

- $\Theta_0 = (1 - \phi_1 \dots - \phi_p)$ é a constante de processo;
- $\Phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p) = 0$ é o polinômio auto regressivo de ordem “p” com raízes fora do círculo unitário, condição de estacionariedade do processo.
- $\Theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q) = 0$ é o polinômio de médias móveis de ordem q com raízes fora do círculo unitário, condição de invertibilidade do processo,

- $\{a_t\}$ é um processo Ruído Branco com média zero $E(a_t) = 0$ e variância constante $Var(a_t) = \sigma^2$.

Este modelo é de forma geral da classe de modelos chamados, modelos auto regressivos de médias móveis $ARIMA(p, d, q)$.

3.4.1.1. Identificação de Modelos ARIMA

A identificação da ordem do modelo $ARIMA(p, d, q)$ pode ser feita através da análise das funções de auto correlação(FAC) e auto correlação parcial(FACP) e pode ser considerada uma das fases mais críticas ao se utilizar a modelagem ARIMA.

Para Franco (2011) se uma série é considerada não estacionária, todos os “lags” apresentarão valores absolutos altos para as auto correlações estimadas. Um processo estacionário é obtido a partir da aplicação do operador de diferença à série, até que o cálculo da sua auto correlação apresente características de um processo estacionário.

Identificado o grau d , o passo seguinte é a escolha dos graus p e q do modelo ARMA aplicado à série diferenciada. Essa identificação leva em consideração o comportamento dos estimadores das auto correlações ($\hat{\rho}_k$) e das auto correlações parciais($\hat{\phi}_{kk}$) com as funções teóricas correspondentes.

A TAB.1 apresenta os comportamentos esperados de FAC e FACP de alguns modelos da classe ARMA mais comuns.

TABELA 1 - Comportamento teórico de FAC e FACP para alguns modelos

Modelo	FAC	FACP
MA(1)	1 pico na lag1	Decrescimento exponencial
AR(1)	Decrescimento exponencial	1 pico no lag 1
MA(2)	1 pico no lag 1 e 1 pico no lag 2	Mistura de exponenciais ou ondas senóides amortecidas
AR(2)	Mistura de exponenciais ou ondas senóides amortecidas	1 pico no lag 1 e 1 pico no lag 2
ARMA(1,1)	Decrescimento exponencial	Decrescimento exponencial

3.4.1.2. Estimação de Parâmetros

Após a identificação de um modelo preliminar baseado na análise das funções de auto correlação(FAC) e auto correlação parcial(FACP), o próximo passo é a estimação dos parâmetros.

A estimação pode ser feita considerando um modelo $ARIMA(p, d, q)$, e colocando seus $p + q + 1$ parâmetros no vetor $\xi = (\phi, \theta, \sigma_a^2)$, onde $\phi = (\phi_1, \dots, \phi_p)$, $\theta = (\theta_1, \dots, \theta_q)$. Quando $d > 0$ supõe-se $\mu = 0$, caso contrário, deve-se considerar μ como mais um parâmetro a ser estimado, e dessa forma considerar $p + q + 2$ parâmetros a serem estimados (MORETTIN e TOLOI, 2018).

Pode-se estimar ξ empregando o método de máxima verossimilhança: dadas N observações Z_1, \dots, Z_N , $\eta = (\phi, \theta)$, e considerando a função de verossimilhança de $L(\xi|Z_1, \dots, Z_N)$ como sendo os valores que minimizam L ou $\ell = \log L$.

Morettin e ToloI (2018) toma d diferenças sazonais para alcançar a estacionariedade. Sendo $n = N - d$ observações denotadas por W_1, \dots, W_n onde $W_t = \Delta^d Z_t$, e como resulta de um modelo $ARMA(p, q)$ estacionário e invertível, considera então:

$$a_t = \tilde{W} - \phi_1 \tilde{W}_{t-1} - \dots - \phi_p \tilde{W}_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q}$$

onde: $\tilde{W} = W_t - \mu$

O cálculo, considerando o procedimento condicional é realizado sob a suposição de normalidade dos a_t , e a função de densidade conjunta de a_1, \dots, a_n é dada por:

$$f(a_1, \dots, a_n) = (2\pi)^{-n/2} (\sigma_a)^{-n} \exp \left\{ -\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2 \right\}$$

os estimadores dos parâmetros são obtidos maximizando-se a verossimilhança apresentada. Para isto, é necessário W_t e a_t , onde os valores iniciais desconhecidos são substituídos por valores que supomos serem razoáveis.

O procedimento não condicional, segundo demonstrado por Morettin e ToloI (2018), considera que o logaritmo da função de verossimilhança não condicional é dado por:

$$l(\xi) \cong -n \log(\sigma_a) - \frac{S(\boldsymbol{\eta})}{2\sigma_a^2}$$

em que

$$S(\boldsymbol{\eta}) = S(\phi, \theta) = \sum_{t=-\infty}^n [a_t(\boldsymbol{\eta}, W)]^2$$

é a soma de quadrados não condicional, com $[a_t(\boldsymbol{\eta}, W)] = E(a_t | \boldsymbol{\eta}, W)$.

O que significa dizer, que os estimadores de mínimos quadrados obtidos minimizando $S(\boldsymbol{\eta})$ serão boas aproximações para os estimadores de máxima verossimilhança.

Para calcular a soma de quadrados para um dado $\boldsymbol{\eta}$, utiliza-se a previsão para o passado (*backforecasting*), ou seja, gerando (prevendo) valores antes do início da série (MORETTIN e TOLOI, 2018).

3.4.2. Modelos SARIMA

A utilização dos modelos Auto Regressivos Integrados de Médias Móveis Sazonais (SARIMA) permite a obtenção de previsões baseados em valores passados e presentes, considerando a sazonalidade (s) observada na série. A simbologia $(P, D, Q)_s$ informa, respectivamente, a ocorrência de um processo auto regressivo sazonal (P), a aplicação de diferenças sazonais (D) e a ocorrência de um processo de média móvel sazonal (Q).

Assim sendo, conforme citado acima, uma série não estacionária, após de “d” diferenças não sazonais e/ou “D” diferenças sazonais pode se tornar estacionária e apresentar as características de uma componente auto regressivo de ordem p e de uma componente de médias móveis de ordem q , então temos um modelo sazonal denotado por $SARIMA(p, d, q,) (0, D, 0)_s$, da forma:

$$\Phi_p(B)W_t = \Theta_q(B)a_t$$

onde:

- $W_t = (1 - B)^d(1 - B^s)^D Y_t$ é a série diferenciada,
- $\Phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p = 0$ é o polinômio auto regressivo de ordem p com raízes fora do círculo unitário,

- $\Theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q) = 0$ é o polinômio de médias móveis de ordem q com raízes fora do círculo unitário e raízes não comuns,
- $\{a_t\}$ é um processo Ruído Branco com média zero $E(a_t) = 0$ e variância constante $Var(a_t) = \sigma^2$.

O modelo para a série não diferenciada, Y_t , é da seguinte forma:

$$\Phi(B)(1 - B)^d(1 - B^S)^D Y_t = \Theta_q(B)a_t$$

a série diferenciada também pode apresentar uma componente auto regressivo sazonal de ordem P e uma componente de médias móveis sazonal de ordem Q , então temos um modelo sazonal denotado por $SARIMA(0, \mathbf{d}, 0)(\mathbf{P}, \mathbf{D}, \mathbf{Q})_s$, da forma:

$$\Phi_P(B^S)W_t = \Theta_Q(B^S)a_t$$

onde

- $W_t = (1 - B)^d(1 - B^S)^D Y_t$ é a série diferenciada,
- $\Phi_P(B^S) = (1 - \phi_1 B^S - \dots - \phi_P B^{SP}) = 0$ é o polinômio auto regressivo sazonal de ordem P , com raízes fora do círculo unitário e
- $\Theta_Q(B^S) = (1 - \theta_1 B^S - \dots - \theta_Q B^{QS}) = 0$ é o polinômio média móvel sazonal de ordem Q , com raízes fora do círculo unitário e raízes não comuns.

O modelo para a série não diferenciada, Y_t , é como segue:

$$\Phi_P(B^S)(1 - B)^d(1 - B^S)^D Y_t = \Theta_q(B^S)a_t$$

Um modelo mais geral é quando a série não estacionária, após de " \mathbf{d} " diferenças não sazonais e/ou " \mathbf{D} " diferenças sazonais, apresenta componentes auto regressivos sazonais e/ou não sazonais, e também componente de médias móveis sazonais e/ou não sazonais, este modelo é denotado por $SARIMA(p, d, q)(P, D, Q)_s$, da forma:

$$\Phi_P(B^S)\Phi_p(B)W_t = \Theta_q(B)\Theta_Q(B^S)a_t$$

onde,

- $\Phi_p(B) = 0$ é o polinômio autorregressivo de ordem p ,

- $\Theta_q(B) = 0$ é o polinômio de médias móveis de ordem q com raízes fora do círculo unitário e sem raízes comuns;
- $\Phi_p(B^S) = 0$ é o polinômio autorregressivo sazonal de ordem P ;
- $\Theta_Q(B^S) = 0$ é o polinômio de médias móveis sazonal de ordem Q e
- $\{a_t\}$ é um processo Ruído Branco com média zero $E(a_t) = 0$ e variância constante $Var(a_t) = \sigma^2$.

3.4.2.1. Identificação e Estimação de modelos SARIMA

Para Morettin e Tolo (2018) “a estimação de máxima verossimilhança dos parâmetros μ , α_j , β_j , θ_j e ϕ_k , $i = 1, \dots, 6$, $j = 1, \dots, q$ e $k = 1, \dots, p$, é obtida por métodos similares àqueles discutidos na estimação dos parâmetros de um modelo ARMA”.

Segundo o autor, não há dificuldades adicionais para a construção dos modelos sazonais em comparação aos modelos ARIMA tradicionais. No entanto, tem-se que diferenciar a série em relação a ela mesma $(1 - B)$ e considerar também a diferença sazonal $(1 - B^S)$, para produzir estacionariedade e assim descobrir os valores d e D .

A formulação de um primeiro modelo SARIMA que descreva a série original pode ser obtido através da análise de FAC e FACP amostrais da série nos “lags” 1, 2, 3, ... para obtenção dos valores iniciais de p e q , e nos “lags” sazonais s , $2s$, $3s$, ... para os valores de P e Q iniciais (MORETTIN e TOLOI, 2018).

A fase de identificação do modelo é complicada, pois há possibilidades de identificação de modelos diferentes para uma mesma série temporal. A utilização de critérios para a escolha de modelos concorrentes ou para comparar modelos para fins de previsão, em conjunto com a análise de FAC e FACP pode ser uma alternativa na busca por modelos eficientes e bem ajustados.

Entre estes critérios se destacam o Critério de informação de Akaike (CIA, do inglês AIC – *Akaike's Information Criterion*) e o Critério de Informação Schwarz (CIS, do inglês SIC – *Schwarz's Information Criterion* ou BIC – *Bayesian Information Criterion*). A maioria dos softwares estatísticos modernos já trazem embutidos em suas rotinas de regressão esses critérios e ambos visam minimizar a soma de quadrados dos resíduos (SQR). Dessa forma quanto mais baixo for o valor dessas estatísticas, melhor será o modelo. Contudo, deve-se advertir que esses critérios não

são absolutos, mas sim complementares a uma cuidadosa análise de especificação (GUJARATI e PORTER, 2011).

3.5. Modelos Alisamento Exponencial de Holt - Winters Aditivo

Para séries temporais que, além de uma tendência linear, apresentam a componente de sazonalidade, os modelos de Holt - Winters podem ser aplicados apropriadamente. Demandas do tipo sazonal são caracterizadas pela ocorrência de padrões cíclicos de variação que se repetem em intervalos relativamente constantes.

O modelo é baseado em três equações alisadoras: uma para o nível, outra para tendência e outra para sazonalidade, que estão descritas da seguinte maneira no instante t :

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1}$$

$$S_t = \delta(Y_t - L_t) + (1 - \delta)S_{t-1}$$

sendo:

- Nível da série: L_t
- Tendência da série: T_t
- Componente Sazonal da série: S_t
- Valor observado da série no tempo t : Y_t
- α, γ e δ constantes de alisamento, do nível, da tendência e da sazonalidade, respectivamente.

A escolha das constantes de alisamento α, β e γ envolve a minimização da soma de erros ao quadrado. A equação de previsão um passo à frente, a partir do instante de tempo t é:

$$\hat{Y}_t = L_{t-1} + T_{t-1} + S_{t-s}$$

Uma das desvantagens do método de alisamento é o fato dele não fazer nenhuma suposição acerca da distribuição dos dados. Dessa forma, não se pode ter certeza de que o modelo correto foi encontrado e, além disso, só é possível a construção de intervalos de confiança aproximados para as previsões.

3.6. Verificação e escolha dos modelos

Um maneira simples e eficiente de analisar se existe indícios de que o vetor de resíduos é puramente aleatório, e portanto, um ruído branco é avaliando as funções de autocorrelação(FAC) e autocorrelação parcial(FACP) dos erros para identificar se nenhuma correlação é significativa do ponto de vista estatístico.

Gujarati (2011) afirma que a significância estatística de qualquer função de correlação amostral, $\hat{\rho}_k$, pode ser julgada por seu erro padrão, ou seja, considerando que em amostras grandes, os coeficientes de correlação amostral são normalmente distribuídos com a média zero e a variância 1, o valor estimado de cada defasagem pode ser verificado significativo estatisticamente.

Contudo, podemos testar a hipótese conjunta de que todos os ρ_k até determinada defasagens são simultaneamente iguais a zero. Isso pode ser feito por meio da estatística Q desenvolvida por Box e Pierce, definida como:

$$Q = n \sum_{k=1}^m \hat{\rho}_k^2$$

Em que n representa o tamanho da amostra e m o tamanho da defasagem

Uma variante da estatística Q, de Box-Pierce, é a estatística Ljung-Box(LB), definida como:

$$LB = n(n+2) \sum_{k=1}^m \left(\frac{\hat{\rho}_k^2}{n-k} \right) \sim \chi^2 m$$

Embora nas amostras grandes, tanto a estatística Q quanto a LB seguem a distribuição qui-quadrado com m graus de liberdade, a estatística LB descobriu ter melhores (mais poderosos, no sentido estatístico) propriedades de amostras pequenas do que a estatística Q (GUJARATI e PORTER, 2011).

A suposição de normalidade também pode ser verificada através da construção de histogramas e de testes de normalidade para os resíduos. A análise desses gráficos permite também a verificação da presença de elementos discrepantes caso os resíduos não estejam situados dentro de um intervalo apropriado. Além disso, o gráfico de resíduos versus valores ajustados pode indicar a violação de variância

constante caso indique a presença de configurações especiais, indicando nesse caso que os erros são ou não correlacionados.

Além da análise de resíduos, deve-se também verificar se os parâmetros estimados pelo modelo (ϕ 's e θ 's) são estatisticamente diferentes de zero. Caso os p-valores encontrados nos testes sejam menores que o nível de significância estabelecido a hipótese nula de que os parâmetros estimados sejam iguais a zero deve ser rejeitada.

Após a estimação do modelo e a verificação dos parâmetros deve-se verificar se o mesmo cumpre as condições de estacionariedade e invertibilidade. Para Abitante (2007), em um modelo $AR(p)$, a condição de estacionariedade é de que todas as raízes do polinômio $\phi(B)$ caiam fora do círculo unitário. No caso do modelo de médias móveis, deve-se verificar a condição de invertibilidade do mesmo, que é análoga a condição de estacionariedade do modelo auto regressivo. Assim, para um $MA(q)$, a condição de invertibilidade é que todas as raízes do polinômio $\theta(B)$ caiam fora do círculo unitário.

A seleção dos modelos feita com base nos critérios de Akaike e Schwartz podem ser complementadas por algumas medidas relacionadas aos erros do modelo estimado. Elas podem ser utilizadas tanto na análise dos resultados do modelo, quanto na parte de avaliação da capacidade preditiva. Quanto menor o seu valor, melhor é o ajuste do modelo. Algumas delas são apresentadas a seguir:

- **MAE** – Erro absoluto médio:

$$MAE = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{m}$$

- **MAPE** – Erro percentual absoluto médio:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{m} \times 100, Y_t \neq 0$$

- **MPE** – Média percentual dos erros:

$$MPE = \frac{\sum_{t=1}^n \left(\frac{Y_t - \hat{Y}_t}{Y_t} \right)}{m} \times 100, Y_t \neq 0$$

- **RMSD** – Raiz do erro quadrado médio:

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

Onde:

Y_t é valor real no tempo t ;

\hat{Y}_t é o valor ajustado;

m o número de observações.

Para Wooldrige (2016) a previsão é essencialmente um problema que está fora da amostra, desta forma, mesmo que o modelo apresente um bom ajuste para os valores amostrais utilizados na estimação dos parâmetros, isso não significa necessariamente um bom desempenho da previsão. Em outras palavras, para uma boa análise da capacidade de previsão do modelo de série temporal ajustado é necessário ter um conjunto de valores da série que não foram utilizados na estimação dos parâmetros do modelo.

4. ANÁLISE DOS RESULTADOS

As bases de dados utilizadas neste trabalho foram retiradas do Sistema Gerenciador de Séries Temporais - v2.1, do Banco Central do Brasil. As séries que serão objeto deste estudo referem-se a indicadores relacionados a concessão de crédito para pessoa jurídica. Cada série possui um total de 105(cento e cinco) observações, das quais 99(noventa e nove) serão utilizadas para efeito de previsão amostral e as últimas 6(seis) para validação dos modelos obtidos.

As variáveis utilizadas no presente trabalho constituem séries históricas de periodicidade mensal, abrangendo o período de março/2011 até novembro/2019 com informações referentes ao volume de concessão de crédito às pessoas jurídicas. A seguir tem-se a descrição das mesmas (em parênteses tem-se as siglas que serão utilizadas para se referir as variáveis no decorrer do texto).

- 20635 - Concessões de crédito com recursos livres - Pessoas jurídicas – Total (*CréditoTotal*): valor das novas operações de crédito contratadas no período de referência com taxas de juros livremente pactuadas entre mutuários e instituições financeiras. Não inclui operações referenciadas em taxas regulamentares, operações vinculadas a recursos do Banco de Desenvolvimento Econômico e Social (BNDES) ou qualquer outras lastreadas em recursos compulsórios ou governamentais (BANCO CENTRAL DO BRASIL, 2019).
- 20639 - Concessões de crédito com recursos livres - Pessoas jurídicas - Capital de giro com prazo de até 365 dias (*CréditoCP*): operações de crédito destinadas ao financiamento de curto prazo das empresas, vinculado a contrato específico que estabeleça prazos, taxas e garantias, com prazo igual ou inferior a 365 dias. (BANCO CENTRAL DO BRASIL, 2019)
- 20640 - Concessões de crédito com recursos livres - Pessoas jurídicas - Capital de giro com prazo superior a 365 dias (*CréditoLP*): Operações de crédito de médio e longo prazo destinadas ao financiamento das atividades operacionais das empresas, vinculado a contrato específico que estabeleça prazos, taxas e garantias, com prazo superior a 365 dias. (BANCO CENTRAL DO BRASIL, 2019)

4.1. Concessões De Crédito - Total

Através da análise exploratória da série de *CréditoTotal* é possível identificar características importantes relacionadas aos dados e dessa forma auxiliar na condução e elaboração de modelos preditivos mais assertivos.

A FIG. 1 apresenta as estatísticas descritivas referentes a série Concessão de crédito total, no período de março de 2011 até novembro de 2019. A média dos valores concedidos a título de empréstimo para pessoas jurídicas foi de R\$ 121849 milhões de reais com um desvio padrão de R\$ 13487 milhões de reais. O valor máximo e o mínimo concedidos foram de R\$ 153057 e R\$ 86900 milhões de reais, volume emprestado respectivamente em dezembro de 2018 e fevereiro de 2017.

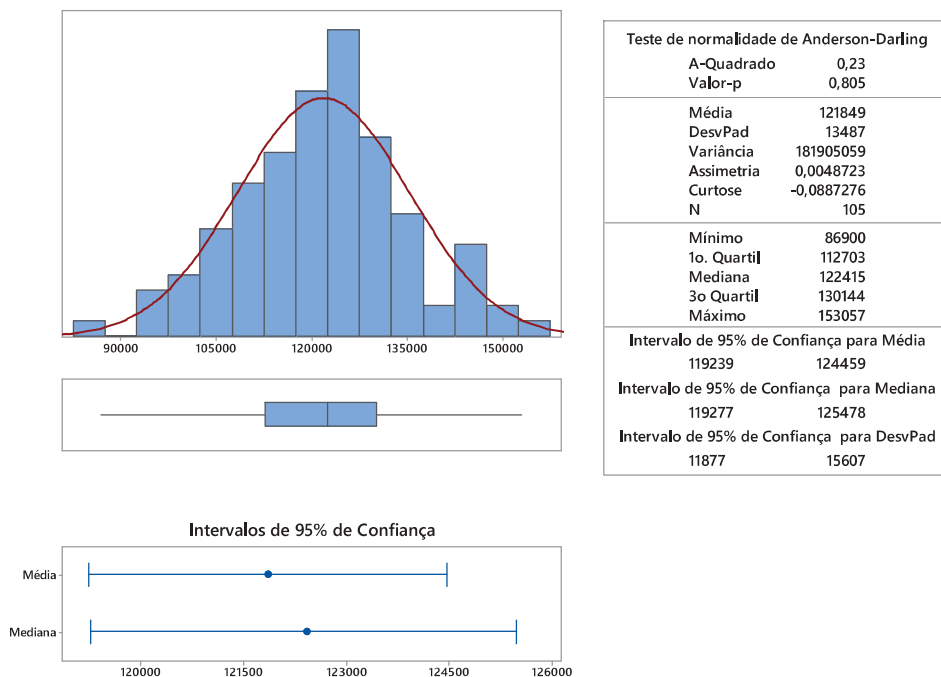


FIGURA 1 - Análise Exploratória *CréditoTotal*

Pelo teste de Anderson – Darling, ao nível de significância de 5%, a hipótese de normalidade não deve ser rejeitada. A série apresenta distribuição próxima a curva normal, menos apontada (Curtose = $-0,0887 < 0$) e com ligeira assimetria à esquerda (Assimetria = $0,0048$).

A FIG. 2, mostra o gráfico da série temporal *CréditoTotal* no período de março de 2011 a julho de 2019 e revela que os dados não variam em torno de um valor médio, ou seja, a série não é estacionária em relação à média.




FIGURA 2 - Série de valores do *CréditoTotal* (período Março-2011 a Julho-2019)

Nota-se uma tendência crescente de março de 2011 até dezembro de 2014, provocada pela decisão política do governo em utilizar os bancos públicos para oferta de crédito no país, com o objetivo de reverter o ciclo econômico através da elevação do crédito. No entanto, a recessão econômica de 2015 e 2016 certamente gerou um cenário devastador para empresas nos mais diversos setores de atividade, ocorrendo a reversão e diminuição significativa nos volumes de concessão de crédito, chegando ao seu menor valor em fevereiro de 2017 (DIEESE, 2018). A partir desse ponto, pode-se perceber uma recuperação e a retomada progressiva no volume de concessões.




FIGURA 3 - Boxplot por ano e por mês da série *CréditoTotal*

A FIG. 3, quando apresenta o gráfico de Boxplot por ano, reforça o que foi mencionado a respeito da tendência e através da sua análise, pode-se identificar a presença de valores atípicos nos anos de 2013, 2014 e também em 2018.

No gráfico de Boxplot por mês, observa-se que as medianas relacionadas ao crédito concedido por mês não estão alinhadas, indicando uma variação sazonal mensal, com uma maior variabilidade nos meses de abril, julho e outubro. O aumento no volume de crédito concedido pode ser facilmente identificado em dezembro, mês em que se concentram as despesas com pessoal e o maior volume de vendas e prestação de serviços nas empresas, impulsionadas pelo aquecimento do mercado em função das festividades de fim de ano.

Nesta etapa, serão feitas considerações acerca da estacionariedade da série, levando em consideração aspectos identificados na fase preliminar, onde se executou a análise exploratória dos dados.







FIGURA 4 - FAC e FACP da série Crédito Total

Nesse sentido, a FIG. 4 apresenta a função de auto correlação (FAC) e auto correlação parcial FACP da série de Concessão total de crédito com recursos livres, para pessoas jurídicas. Pode-se observar que as primeiras correlações apresentadas em FAC são significativamente diferentes de zero, ao nível de 5% de significância e em FACP observa-se correlações significativamente diferentes de zero, compreendidas fora do intervalo de confiança de 95%.

Tais fatos, corroboram com as evidências apontadas na análise exploratória, indicando que a série não é estacionária em média e existe a necessidade de se considerar a presença de tendência e sazonalidade. Dessa forma, aplicou-se o operador de diferenças para tornar a série estacionária, ou seja, oscilando em torno de uma média constante. A tendência foi eliminada com apenas uma diferença, conforme ilustrado na FIG. 5.

FIGURA 5 - *CréditoTotal* diferenciada

Tomando uma diferença de ordem 12 para eliminar a sazonalidade, verificou-se nas funções de autocorrelação (FAC) e autocorrelação parcial (FACP) da série diferenciada, mostradas nas FIG. 6 e FIG.7, respectivamente, a existência de “lags” múltiplos de 12 significativos, o que implica incluir no modelo uma componente sazonal estocástica, além da determinística, que foi eliminada ao se considerar uma diferença sazonal.

FIGURA 6 - FAC da Série *CréditoTotal* não sazonal (d=1 e D=1)FIGURA 7 - FACP da Série *CréditoTotal* não sazonal (d=1 e D=1)

A estimação do modelo univariado levou em consideração a análise de FAC e FACP da série *CréditoTotal*. A FAC apresenta um comportamento decrescente e a FACP é truncada a partir do *lag* 2. No entanto, deve-se considerar o comportamento das *lags* múltiplas de 12, que se destacam por estarem próximas do intervalo de confiança, indicando que o processo gerador da série possa ser um SARIMA(0,1,1)(0,1,1)₁₂. A fim de complementar o processo de identificação, foram calculados os critérios AIC e BIC para modelos SARIMA alternativos estimados para a série, e a posterior verificação do ajuste dos resíduos. Os valores dos critérios são apresentados na TAB. 2.

TABELA 2 - Valores de AIC, BIC e Teste de normalidade para diferentes modelos univariados de *CréditoTotal*

Modelo Potencial	AIC	BIC
SARIMA(2,1,0) (0,1,1)	567,06	576,87
SARIMA(2,1,1) (0,1,1)	568,92	581,19
SARIMA(2,1,0) (1,1,0)	570,38	580,2
SARIMA(0,1,1) (0,1,1)	583,03	590,39
SARIMA(0,1,1) (0,1,0)	588,89	593,8

Segundo o método proposto por Box e Jenkins (2008), discutido na seção 3.4, após a identificação do modelo com base na análise de FAC e FACP e a estimação dos parâmetros verificou-se através da análise de resíduos que o modelo não estava bem ajustado. Dessa forma, o ciclo iterativo foi retomado e optou-se por estimar os modelos com as menores valores das estatísticas AIC e BIC, que cumprissem as premissas estabelecidas na metodologia Box e Jenkins.

O modelo SARIMA(2,1,0)(1,1,0)₁₂ foi um dos que apresentou os melhores resultados do ponto de vista da significância dos parâmetros e performance dos resíduos. A sua equação é a seguinte:

$$(1 + 0,3695B^{12})(1 + 0,8823B + 0,5477B^2)(1 - B)(1 - B^{12})Y_t = a_t$$

$$Y_t = 0,1177Y_{t-1} - 0,3346Y_{t-2} + 0,5477Y_{t-3} - 0,8823Y_{t-13} - 0,3346Y_{t-14} - 0,5477Y_{t-15} \\ - 0,3695Y_{t-12} + 0,3695Y_{t-13} + 0,3695Y_{t-24} + 0,3695Y_{t-25} + 0,326Y_{t-13} \\ + 0,326Y_{t-14} + 0,326Y_{t-25} - 0,326Y_{t-26} + 0,2024Y_{t-14} + 0,2024Y_{t-15} \\ - 0,2024Y_{t-26} + 0,2024Y_{t-27} + a_t$$

TABELA 3 - Resultados da estimação do modelo SARIMA (2,1,1) (1,1,0) sazonalidade = 12 para a série *CréditoTotal*, no período de março/2011 até maio/2019

Modelo: SARIMA(2,1,0)(1,1,0)₁₂				
Variável	Coefficiente	Erro Padrão	Estatística-t	Valor-p
AR(1)	-0,8823	0,0955	-9,24	0,000
AR(2)	-0,5477	0,0960	-5,71	0,000
SMM(1)	-0,3695	0,1074	-3,44	0,001
AIC	570,38	Estatística-Q de Ljung-Box dos resíduos		
AICc	570,87	Q(k)	Qui-Quadrado	Valor-p
BIC	580,2	Q(12)	8,6	0,478
N. Observ	99	Q(24)	13,4	0,895
		Q(36)	25,8	0,808
		Q(48)	36,9	0,800

Os resultados dos parâmetros estimados e de outras características e informações do modelo são apresentados pela TAB. 3, e mostram que os coeficientes, ao nível de significância de 5%, são todos significativamente diferentes de zero. Além disso, o ajuste do modelo cumpre as condições de estacionariedade e invertibilidade, ou seja:

$$-1 < \phi_2 = -0,5477 < 1$$

$$\phi_2 - \phi_1 = 0,3346 < 1$$

$$\phi_2 + \phi_1 = -1,43 < 1$$

A FIG. 8 traz a série original e os valores ajustados pelo modelo SARIMA(2,1,0)(1,1,0)₁₂, considerando as 99 observações da série original. Nota-se que os valores ajustados acompanharam bem de perto os dados no período amostral.




FIGURA 8 - *CréditoTotal* e ajustados pelo modelo SARIMA (2,1,0) (1,1,0) sazonalidade = 12

Com relação ao comportamento dos erros, a os correlogramas de FAC e FACP e as estatísticas de Ljung-Box, até a *lag* 48 indicam que as correlações dos resíduos não são estatisticamente significantes. Apesar de uma correlação dos resíduos estar bem próxima do limite superior do intervalo de confiança, o que indica um pequeno problema em relação a suposição de ruído branco, isso não compromete a análise de resíduos, conforme mostrado na FIG. 9.

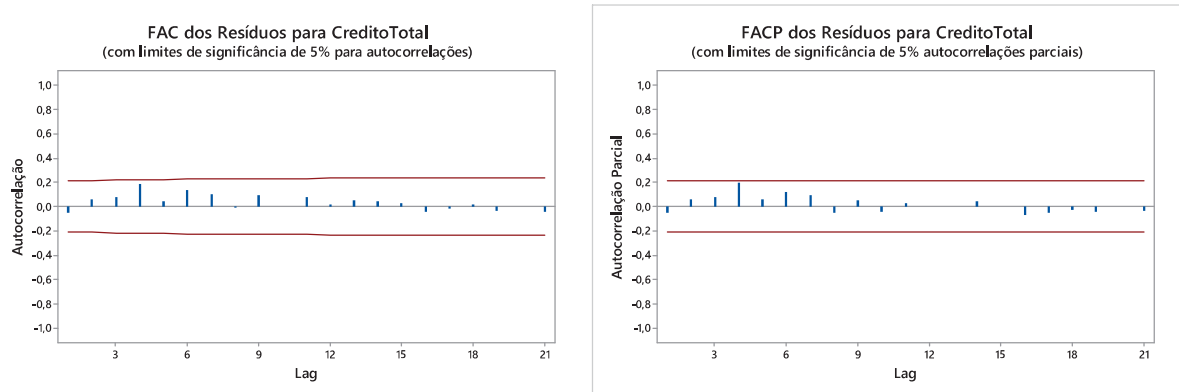


FIGURA 9 - FAC e FACP dos resíduos do modelo SARIMA(2,1,0) (1,1,0) sazonalidade=12

A análise de resíduos feita a partir dos gráficos apresentados na FIG.10 revelam que além de o modelo acompanhar bem a série original, os erros estão bem distribuídos em torno da média zero, e também atendem a condição de normalidade, tendo em vista, segundo o teste Anderson- Darling que o valor-p = 0,569 > $\alpha = 0,05$.

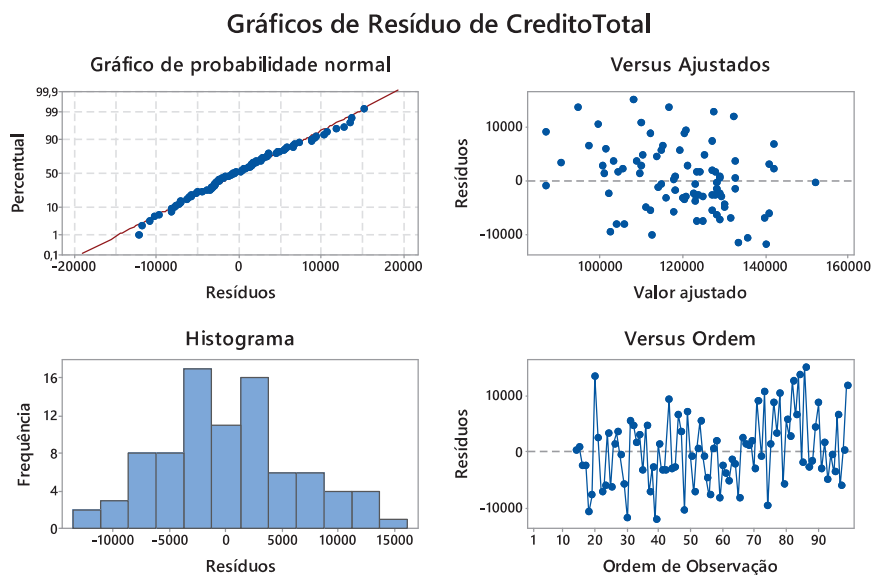


FIGURA 10 - Análise de resíduos do modelo SARIMA(2,1,0) (1,1,0) sazonalidade=12

Contudo, os dados do período de validação ficaram entre as estimativas intervalares do modelo SARIMA(2,1,0)(1,1,0)₁₂. Contudo, o mês de setembro/2019

apresentou um valor bem próximo ao limite superior dessas estimativas, conforme apresentado na FIG. 11:




FIGURA 11 – Comparativo entre os valores da série *CréditoTotal*, no período de 06/2019 até 11/2019 e os valores previstos pelo modelo SARIMA(2,1,0) (1,1,0) sazonalidade = 12

A TAB. 4 apresenta os valores das previsões, em milhões e também o erro de previsão, considerando a proporção do valor realizado. Conforme já mencionado o mês de setembro/2019 foi o que apresentou a maior discrepância em relação ao valor real obtido. Também vale destacar que a previsão para junho/2019 ficou bem próxima ao valor real.

TABELA 4 - Comparativo entre os valores da série *CréditoTotal*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(2,1,0) (1,1,0) sazonalidade = 12

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 141.549,00	R\$ 142.288,08	0,52%
jul./19	R\$ 135.449,00	R\$ 130.163,69	-3,90%
ago./19	R\$ 139.675,00	R\$ 145.419,69	4,11%
Set/19	R\$ 149.510,00	R\$ 134.155,35	-10,27%
Out/19	R\$ 147.031,00	R\$ 142.249,09	-3,25%
nov./19	R\$ 148.522,00	R\$ 141.650,88	-4,63%

O segundo modelo encontrado e que melhor cumpriu as premissas estabelecidas pela metodologia Box-Jenkins foi o SARIMA(2,1,0)(0,1,1)₁₂. Ele apresentou menores valores para as estatísticas AIC e BIC que o modelo anterior e a sua equação é mostrada a seguir:

$$(0,1172B + 0,5428B^2)(1 - B)(1 - B^{12})Y_t = (0,1765B^{12})a_t$$

$$Y_t = -0,4252Y_{t-1} + 1,4252Y_{t-2} + Y_{t-12} - 0,4252Y_{t-13} - 1,4252Y_{t-14} + a_t$$

Na TAB. 5 são apresentados os resultados do ajuste do modelo. Os coeficientes são estatisticamente significantes e atendem as condições de estacionariedade e invertibilidade:

$$-1 < \phi_2 = -0,5428 < 1$$

$$\phi_2 - \phi_1 = 0,3396 < 1$$

$$\phi_2 + \phi_1 = -1,4252 < 1$$

$$-1 < \theta = 0,8235 < 1$$

Considerando $\alpha = 0,05$ e os correlogramas dos resíduos, apresentados na FIG. 12, bem como as estatísticas de Ljung-Box até o lag 48 indicam que as correlações dos resíduos não são estatisticamente significativas.

TABELA 5 -Resultados da estimação do modelo SARIMA(2,1,0) (0,1,1) sazonalidade =12 para a série *CréditoTotal* no período de março/2011 até maio/2019

Modelo: SARIMA(2,1,0)(0,1,1)₁₂				
Variável	Coefficiente	Erro Padrão	Estatística-t	Valor-p
AR(1)	-0,8824	0,0932	-9,47	0,0000
AR(2)	-0,5428	0,0924	-5,88	0,0000
SMA(1)	0,8235	0,0861	9,56	0,0000
AIC	567,06	Estatística-Q de Ljung-Box dos resíduos		
AICc	567,55	Q(k)	Qui-Quadrado	Valor-p
BIC	576,87	Q(12)	14,6	0,102
N. Observ	99	Q(24)	24,3	0,280
		Q(36)	43,2	0,110
		Q(48)	58,1	0,090

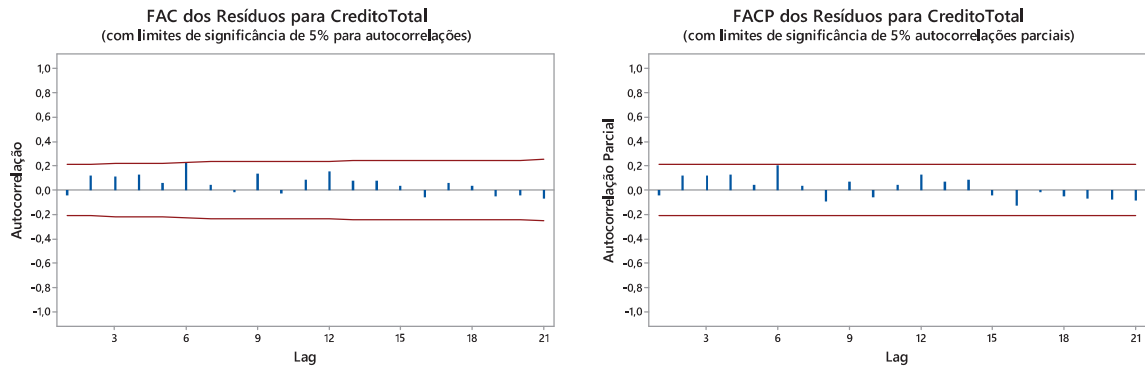


FIGURA 12 - FAC e FACP dos resíduos SARIMA (2,1,0) (0,1,1) sazonalidade = 12

A FIG. 13, mostra os gráficos dos resíduos e através de sua análise em conjunto com o teste de normalidade de Anderson-Darling (Valor-p= 0,675 > $\alpha= 0,05$) chega-se à conclusão que de fato o vetor de resíduos do segundo modelo também é um ruído branco gaussiano, apesar de uma correlação estar bem próxima do limite superior do intervalo de confiança.

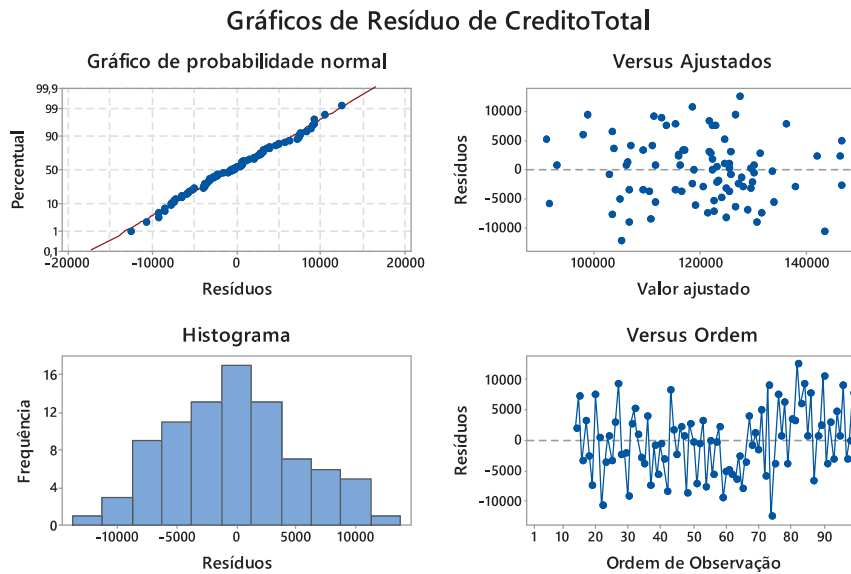


FIGURA 13 - Análise de Resíduos do modelo SARIMA (2,1,0) (0,1,1) sazonalidade = 12

O modelo SARIMA(2,1,0)(0,1,1)₁₂ se mostrou bastante satisfatório e os valores ajustados acompanharam bem a série original, conforme pode ser observado na FIG. 14.




FIGURA 14 – *CréditoTotal* e ajustados pelo modelo SARIMA (2,1,0) (0,1,1) sazonalidade = 12

Com relação as previsões do modelo SARIMA(2,1,0)(0,1,1)₁₂, o gráfico apresentado pela FIG.15 e a TAB. 6 revelam que as previsões estão mais distantes dos valores reais quando comparado ao primeiro modelo ajustado. Além disso, observa-se que a observação referente a setembro/2019 está situada fora da estimativa intervalar, e junto com ela, as duas observações apresentam um erro de previsão considerável.

TABELA 6 - Comparativo entre os valores da série *CréditoTotal*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(2,1,0) (0,1,1) sazonalidade = 12

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 141.549,00	R\$ 139.806,11	-1,23%
jul./19	R\$ 135.449,00	R\$ 128.707,35	-4,98%
ago./19	R\$ 139.675,00	R\$ 137.738,80	-1,39%
set./19	R\$ 149.510,00	R\$ 134.452,25	-10,07%
out./19	R\$ 147.031,00	R\$ 136.574,59	-7,11%
Nov./19	R\$ 148.522,00	R\$ 137.434,98	-7,46%




FIGURA 15 - Comparativo entre os valores da série *CréditoTotal*, no período de 06/2019 até 11/2019 e os valores previstos pelo modelo SARIMA (2,1,0) (0,1,1) sazonalidade = 12

Para o terceiro modelo ajustado utilizou-se o método de alisamento exponencial de Holt - Winters aditivo. Para isso, realizou-se uma procura iterativa das constantes de suavização com a intenção de minimizar a soma de quadrados dos erros. A equação do modelo ajustado é mostrada a seguir:

$$L_t = 0,2280(Y_t - S_t) + (1 - 0,2280)(L_t + T_{t-1})$$

$$T_t = 0,0688(L_t - L_{t-1}) + (1 - 0,0688)T_{t-1}$$

$$S_t = 0,0001(Y_t - L_t) + (1 - 0,0001)S_{t-s}$$

A FIG. 16 apresente a série original de dados em relação as observações ajustadas pelo terceiro modelo, através da análise da figura pode-se observar que os ajustes se adaptaram bem à série original.




FIGURA 16 - Série *CreditoTotal* e ajustados pelo método Holt-Winters

Os dados do período de validação ficaram entre as estimativas intervalares do modelo Holt - Winters, com destaque para o valor observado em setembro de 2019, que ficou bem próximo do limite superior, conforme revela a FIG.17:




FIGURA 17 Comparativo entre os valores da série *CreditoTotal*, no período de 06/2019 até 11/2019 e os valores previstos do modelo Holt-Winters

A TAB.7 mostra um comparativo entre os valores previstos pelo modelo e as observações da série *CréditoTotal* e complementam o que foi apresentado.

TABELA 7- Comparativo entre os valores da série *CréditoTotal*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo Holt-Winters Aditivo

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 141.549,00	R\$ 141.377,05	-0,12%
jul./19	R\$ 135.449,00	R\$ 129.467,70	-4,42%
ago./19	R\$ 139.675,00	R\$ 136.301,27	-2,42%
set./19	R\$ 149.510,00	R\$ 138.176,51	-7,58%
out./19	R\$ 147.031,00	R\$ 138.959,67	-5,49%
Nov./19	R\$ 148.522,00	R\$ 140.382,24	-5,48%

De acordo com as estatísticas dos erros, TAB. 8, o modelo 2, apresenta os menores valores em todas as estatísticas de erros do ajuste do modelo no período amostral. Na TAB. 9, são apresentadas as estatísticas dos erros de previsão no período de validação, e observamos que o modelo 3 é o que apresenta os menores erros de previsão, isto é, acompanha bem a variabilidade do período de validação.

TABELA 8 - Medidas de Acurácia para a série *CréditoTotal* (Período amostral)

	Estatísticas dos Erros no Período Amostral (n=99)		
	Modelo 1: SARIMA (2,1,0) (1,1,0)	Modelo 2: SARIMA (2,1,0) (0,1,1)	Modelo 3: Holt - Winters Aditivo ($\alpha=0,2280$, $\gamma=0,0688$, $\delta=0,0001$)
MAPE	4,2362	3,8132	4,1512
MPE	-0,006	-0,4569	0,3718
RMSD	6202,56	5453,42	5922,41
MAE	4995,75	4457,89	4870,10

TABELA 9 - Medidas de Acurácia para a série *CréditoTotal* (Período de validação)

	Estatísticas dos Erros de Previsão no Período Validação		
	Modelo 1: SARIMA (2,1,0) (1,1,0)	Modelo 2: SARIMA (2,1,0) (0,1,1)	Modelo 3: Holt - Winters Aditivo ($\alpha=0,2280$, $\gamma=0,0688$, $\delta=0,0001$)
MAPE	4,4476	5,3738	4,2505
MPE	2,9026	5,3738	4,2505
RMSD	7824,39	9230,66	7153,53
MAE	6462,79	7836,99	6178,59

4.2. Concessões de crédito - capital de giro curto prazo

De maneira análoga ao estudo realizado na seção 4.1 apresenta-se uma análise exploratória dos dados apresentados pela série de concessão de crédito com recursos livres para pessoas jurídicas com prazo de até 365 e que doravante será tratada apenas como *CréditoCP*.

Através da análise da FIG. 18 pode-se inferir que as observações referentes a série *CréditoCP*, não seguem uma distribuição normal tendo em vista o histograma dos dados apresentados e o teste de normalidade, que revela haver evidências para se rejeitar a hipótese nula de que os dados seguem uma distribuição normal, ao nível de significância de 5%.




FIGURA 18 - Análise exploratória *CréditoCP*

A distribuição é menos apontada do que a curva normal (curtose <0) e com uma assimetria a esquerda. Os dados têm média de R\$ 6544,2 milhões e um desvio padrão de R\$ 2311,2 milhões e o menor valor concedido nesse período foi de R\$ 2751 milhões enquanto que o máximo foi de R\$ 11937 milhões.

A FIG. 19 apresenta a série de concessão de crédito para pessoas jurídicas com prazo inferior a 365 dias. A partir da sua análise pode-se afirmar que os valores

não variam em torno de um valor central e por isso a série não pode ser considerada estacionária em média.





FIGURA 19 - Série de valores do CréditoCP (período Março-2011 a Julho-2019)

Percebe-se que a partir de janeiro de 2014 houve uma diminuição gradual no volume de concessões até chegar ao seu patamar mínimo em abril de 2018, onde começa uma recuperação nas concessões de curto prazo. Isso pode indicar uma dificuldade extra em relação a estimação de modelos e principalmente a realização de previsões, já que a tendência no período utilizado para previsões é totalmente oposta àquela apresentada pelo período amostral.

O Boxplot por ano é apresentado pela FIG. 20 (a) e reforça as ideias apresentadas a respeito da tendência. Observa-se uma grande dispersão dos dados no ano de 2012 e valores atípicos em 2011 e 2013.



(a) (b)
FIGURA 20 - Boxplot por ano e mês da série CréditoCP

A FIG. 20 (b) apresenta o Boxplot por mês. Através da sua análise pode-se que as medianas não estão alinhadas, o que revela indícios de sazonalidade, com uma marcada variação principalmente no mês de dezembro.

Assim como na seção 4.1, a próxima etapa tratará de detalhes e considerações a respeito da estacionariedade da série em discussão.

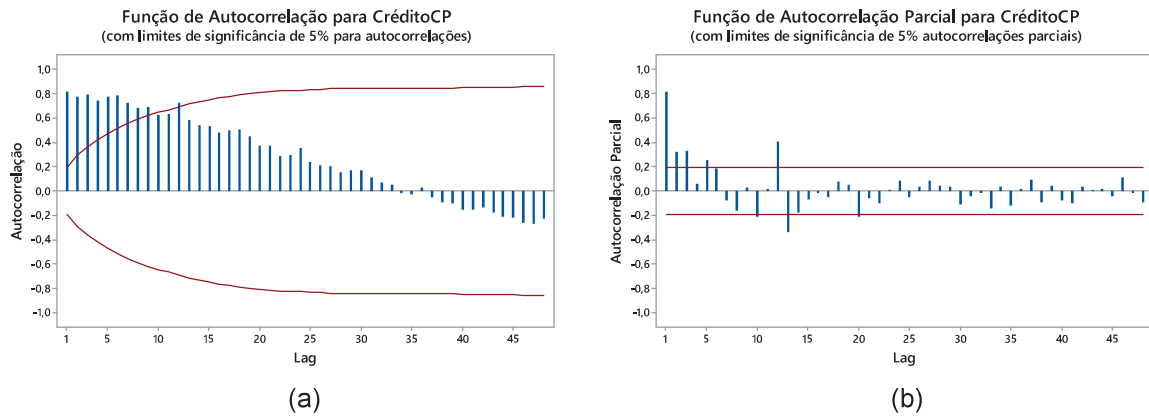


FIGURA 21 - FAC e FACP da série *CréditoCP*

Com esta intenção, a FIG. 21 (a) traz a função de auto correlação e através da sua análise nota-se que as primeiras 9 “lags” são significativamente diferentes de zero, ao nível de significância de 5%. Além disso o decaimento exponencial apresentado se mostrou bastante lento.

A função de auto correlação parcial (FACP) apresentou correlações fora do intervalo de 95% de confiança, conforme apresentado na FIG. 21 (b). Por tais motivos, conforme já mencionado na análise exploratória, a série não pode ser considerada estacionária em média e, além disso, tem-se evidências para considerar a presença de tendência e sazonalidade.

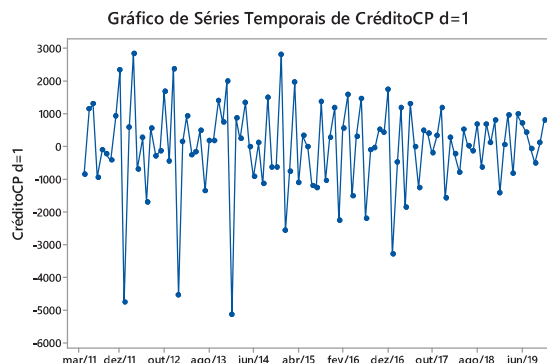


FIGURA 22 - Série *CréditoCP* diferenciada

A diferenciação da série em nível resolveu o problema da não estacionariedade. Os valores agora variam em torno da média zero, como pode ser visto no gráfico da série diferenciada apresentado pela FIG. 22. O primeiro modelo a

ser ajustado para a série *CréditoCP*, irá considerar os efeitos da sazonalidade estocástica.

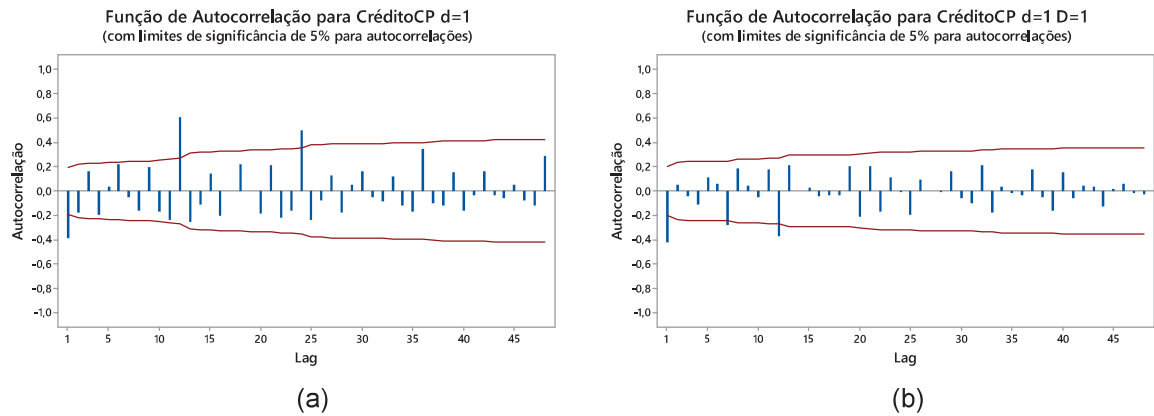


FIGURA 23 - FAC da Série *CréditoCP* (d=1 e D=1)

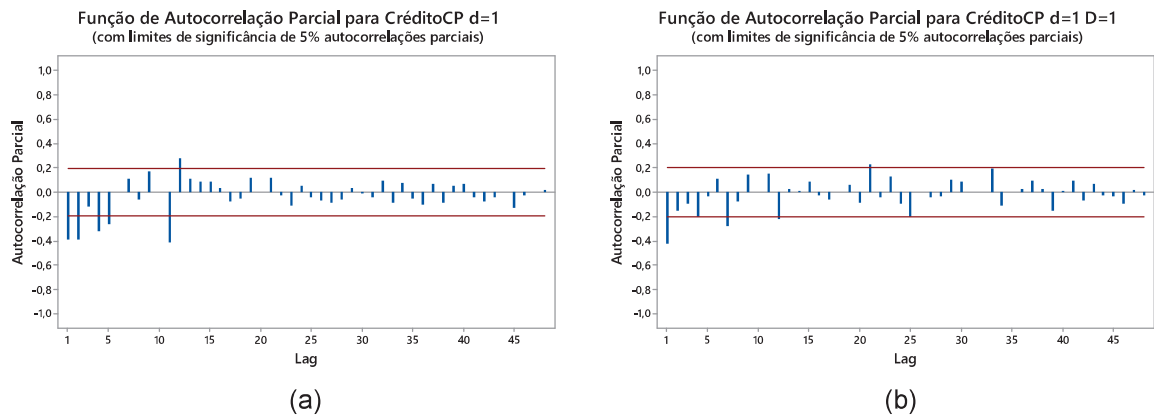


FIGURA 24 - FACP da Série *CréditoCP* não sazonal (d=1 e D=1)

A análise da FAC da série diferenciada d=1 é truncada a partir da primeira correlação e FACP mostra um leve decaimento. Deve-se considerar o comportamento das *lags* múltiplas de 12, indicando que o processo gerador da série possa ser um $SARIMA(0,1,1)(1,0,1)_{12}$. Já os correlogramas da série diferenciada considerando a sazonalidade, indicam um componente de média móvel sazonal e por isso o modelo $SARIMA(0,1,1)(0,1,1)_{12}$ também deve ser considerado. Diante da dificuldade de definição do modelo a ser ajustado, foram calculados os critérios AIC e BIC para modelos SARIMA alternativos estimados para a série, e a posterior verificação do ajuste dos resíduos. Os valores dos critérios são apresentados na TAB. 10 e mostram coerência com as análise de FAC e FACP, considerando que o modelo $SARIMA(0,1,1)(0,1,1)_{12}$ é o que apresenta os menores valores para os critérios

observadas. O modelo SARIMA(1,0,1)(0,1,1)₁₂, foi estimado mas não atendeu aos critérios de estacionariedade e invertibilidade.

TABELA 10 - Valores de AIC, BIC e Teste de normalidade para diferentes modelos univariados de *CréditoCP*

Modelo Potencial	AIC	BIC
SARIMA(0,1,1) (0,1,1)	226,29	233,65
SARIMA(1,0,1) (0,1,1)	229,43	239,29
SARIMA(0,1,1) (2,1,0)	230,64	240,46
SARIMA(0,1,1) (2,1,0)	234,60	241,96
SARIMA(0,1,1) (0,1,0)	243,56	248,47
SARIMA(0,1,1) (1,0,1)	260,3	270,64

Com tudo isso, os resultados do ajuste do modelo SARIMA(0,1,1)(0,1,1)₁₂ são apresentados na TAB. 11 e a sua equação é mostrada a seguir:

$$(1 - B)(1 - B^{12})Y_t = (0,3351B)(0,1416B^{12})a_t$$

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - 0,6649a_{t-1} - 0,8584a_{t-12} + 0,5707a_{t-13}$$

O modelo se mostrou bem ajustado. Os coeficientes atendem a condição de estacionariedade e invertibilidade, ou seja, estão compreendidos dentro do círculo unitário e são estatisticamente significativos ao nível de 5% de significância.

TABELA 11 -Resultados da estimação do modelo SARIMA(0,1,1) (0,1,1) sazonalidade = 12

Modelo: SARIMA(0,1,1)(0,1,1)₁₂				
Variável	Coefficiente	Erro Padrão	Estatística-t	Valor-p
MM(1)	0,6649	0,0802	8,29	0,0000
SMA(12)	0,8584	0,0832	10,32	0,0000
AIC	226,29	Estatística-Q de Ljung-Box dos resíduos		
AICc	226,58	Q(k)	Qui-Quadrado	Valor-p
BIC	233,65	Q(12)	6,9	0,734
N. Observ	99	Q(24)	15,1	0,856
		Q(36)	30,0	0,662
		Q(48)	39,7	0,732

As estatísticas de Ljung-Box revelam que as correlações dos resíduos até o “lag” 48 não são estatisticamente significativas e os correlogramas dos resíduos, mostradas na FIG. 25, revelam que se trata de um perfeito ruído branco gaussiano.

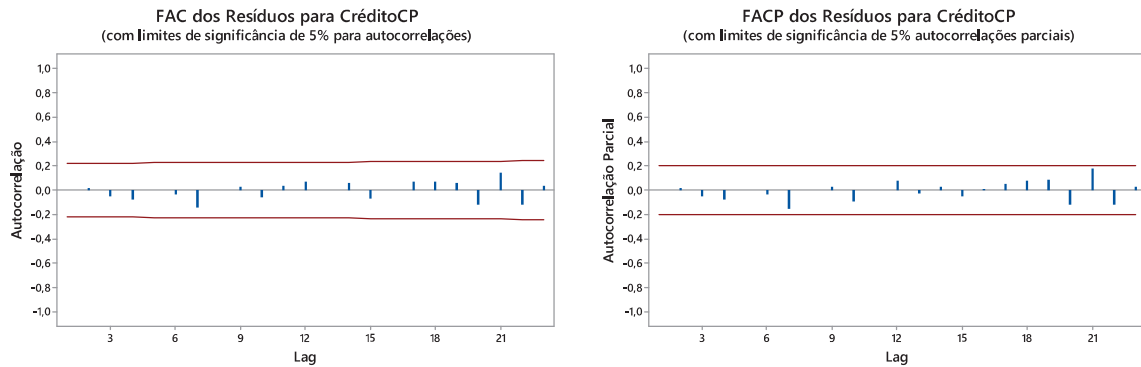


FIGURA 25 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12

A FIG. 26 mostra a análise dos resíduos e corrobora com as conclusões obtidas a respeito dos erros do segundo modelo. De fato, não há evidências para a rejeição da hipótese de normalidade, ao nível de significância de 5% se rejeitar a hipótese nula de normalidade ($\text{Valor-p} = 0,0398 > \alpha = 0,05$). Os erros estão bem distribuídos em torno da média zero e se aproximam bem da curva normal. O gráfico de resíduos versus ajustados não revela nenhum padrão que desabone a condição de normalidade mencionada.

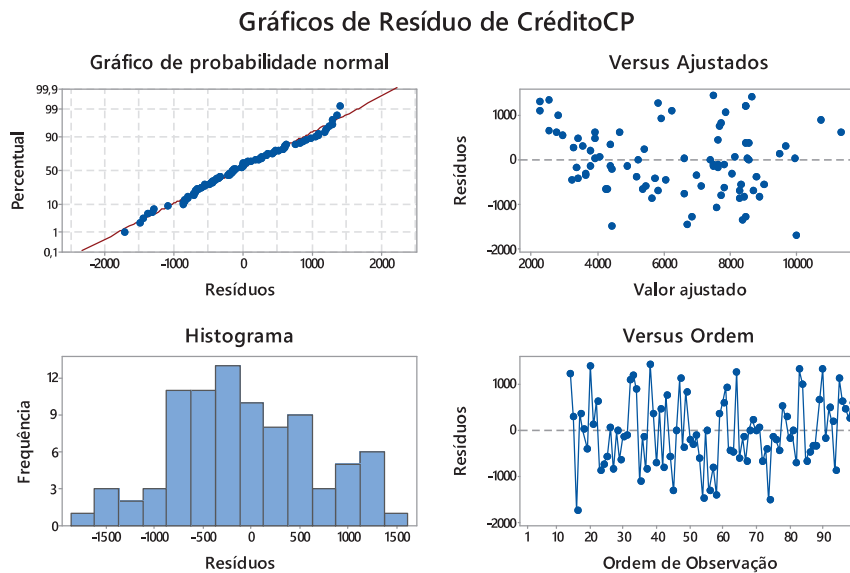


FIGURA 26 - Análise de resíduos do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12

A FIG. 27 apresenta os dados utilizados no período amostral e os valores ajustados pelo modelo. A análise preliminar do gráfico revela evidências de que o modelo SARIMA(0,1,1)(0,1,1)₁₂ acompanhou bem a série *CréditoCP*.




FIGURA 27 - CréditoCP e ajustados do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12

As previsões do modelo, são apresentadas na FIG. 28, e conforme já destacado na análise descritiva, as previsões não conseguiram acompanhar a as observações no período de validação, a maioria das observações ficaram fora das estimativas intervalares e, além disso, apresentaram valor considerável quando analisada a proporção do valor realizado, conforme mostra a TAB. 12.




FIGURA 28 - Previsões do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12

TABELA 12 - Comparativo entre os valores da série CréditoCP, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (0,1,1) sazonalidade =12

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 5.184,00	R\$ 4.177,04	19,42%
jul./19	R\$ 5.598,00	R\$ 3.296,08	41,12%
ago./19	R\$ 5.526,00	R\$ 3.212,91	41,86%
set./19	R\$ 5.017,00	R\$ 3.495,80	30,32%
out./19	R\$ 5.392,00	R\$ 3.671,20	31,91%
nov./19	R\$ 5.958,00	R\$ 3.895,12	34,62%

Como o segundo modelo apresentado na TAB. 10 não atendeu as premissas da metodologia de Box-Jenkins, optou-se por estimar um novo modelo tentando obter

um bom ajuste e também previsões que estivessem mais próximas dos valores observados no período de validação do que as do modelo anterior.

O modelo ajustado foi um SARIMA(0,1,1)(2,1,0)₁₂ dada pela expressão:

$$(1 + 0,6106B^{12} + 0,452B^{24})(1 - B)(1 - B^{12})Y_t = (1 - 0,6125B)a_t$$

$$Y_t = Y_{t-1} + 0,3894Y_{t-12} - 0,3894Y_{t-13} - 0,1586Y_{t-24} + 0,1586Y_{t-25} + 0,452Y_{t-36} - 0,452Y_{t-37} + a_t - 0,6125a_{t-1}$$

Os coeficientes do modelo atendem as condições de estacionariedade e invertibilidade, isso significa que estão compreendidos dentro do círculo unitário e são estatisticamente significativos, pois o valor-p de todos eles é menor que o nível de significância de 5%. Os resultados da estimação são apresentados na TAB. 13.

TABELA 13 - Resultados da estimação do modelo SARIMA(0,1,1) (2,1,0) sazonalidade = 12

Modelo: SARIMA(0,1,1)(2,1,0)₁₂				
Variável	Coeficiente	Erro Padrão	Estatística-t	Valor-p
SAR(12)	-0,6106	0,1013	-6,03	0,0000
SAR(24)	-0,4520	0,1062	-4,25	0,0000
MM(1)	0,6125	0,0876	6,99	0,0000
AIC	1323,65	Estatística-Q de Ljung-Box dos resíduos		
AICc	1324,18	Q(k)	Qui-Quadrado	Valor-p
BIC	1333,17	Q(12)	11,9	0,218
N. Observ	93	Q(24)	20,1	0,516
		Q(36)	43,2	0,111
		Q(48)	56,4	0,118

A FIG. 29 traz a série original e os valores ajustados pelo modelo SARIMA(0,1,1)(2,1,0)₁₂. Os dados no período amostral foram acompanhados bem de perto pelos valores ajustados, levando em consideração as 99 observações do período amostral.




FIGURA 29 - *CréditoCP* e ajustados pelo modelo SARIMA (0,1,1) (2,1,0) sazonalidade = 12

Considerando o comportamento dos erros, as estatísticas de Ljung-Box apresentaram valores-p maiores que $\alpha = 0,05$, o que significa que os resíduos são conjuntamente não correlacionados, conforme apontam os correlogramas dos resíduos apresentados na FIG. 30, uma correlação está bem próxima ao limite inferior do intervalo de confiança, o que indica um pequeno problema em relação a suposição de ruído branco, mas que não é comprometedora.

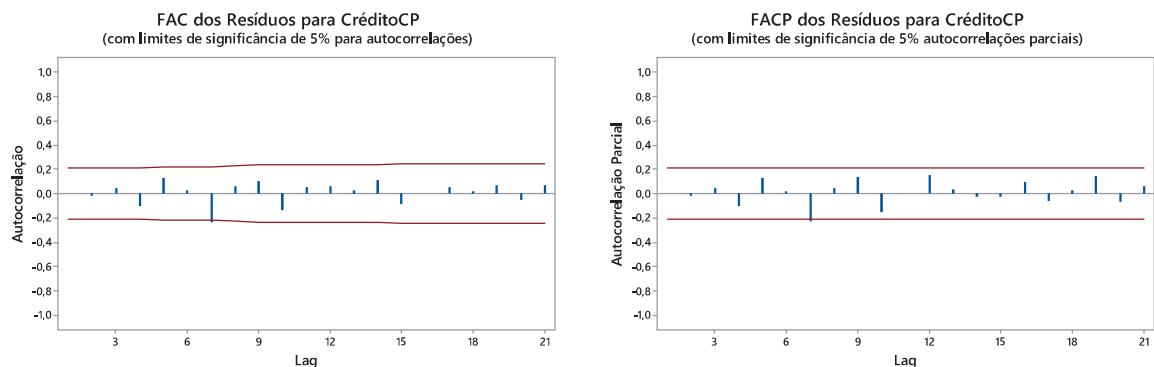


FIGURA 30 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1) (2,1,0) sazonalidade =12

Com relação a análise de resíduos, o teste de normalidade Anderson Darling revela não haver evidências para se rejeitar a hipótese nula de que os dados seguem uma distribuição normal (valor-p = 0,514 > $\alpha = 0,05$).

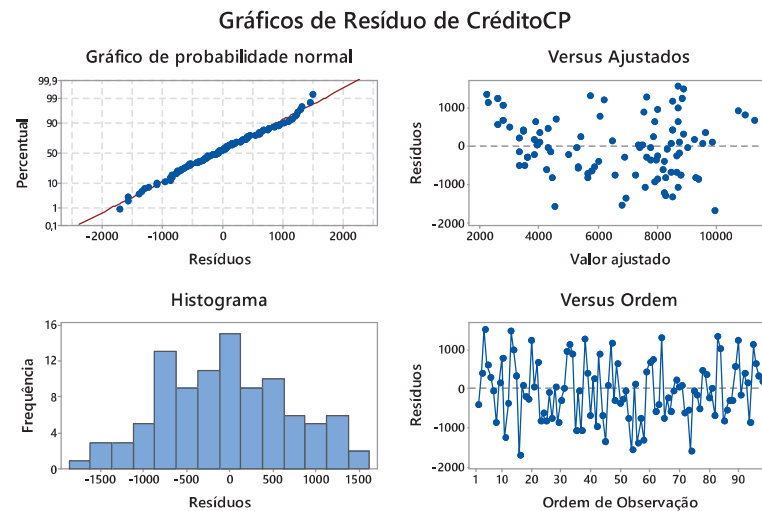


FIGURA 31 - Análise de resíduos do modelo SARIMA (0,1,1) (2,1,0) sazonalidade = 12

A FIG. 31 apresentou a análise de resíduos e mostra que os erros se aproximam bem a curva normal e estão bem distribuídos em torno da média zero, corroborando com o entendimento de que representam um ruído branco gaussiano.




FIGURA 32 - Previsões do modelo SARIMA (0,1,1) (2,1,0) sazonalidade = 12

TABELA 14 - Comparativo entre os valores da série *CréditoCP*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (2,1,0) sazonalidade =12

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 5.184,00	R\$ 4.638,29	10,53%
jul./19	R\$ 5.598,00	R\$ 3.394,73	39,36%
ago./19	R\$ 5.526,00	R\$ 3.680,59	33,40%
set./19	R\$ 5.017,00	R\$ 3.474,81	30,74%
out./19	R\$ 5.392,00	R\$ 3.941,01	26,91%
nov./19	R\$ 5.958,00	R\$ 4.225,53	29,08%

A FIG. 32 e a TAB. 14, mostram que as previsões obtidas pelo modelo SARIMA(0,1,1)(2,1,0)₁₂ se aproximam melhor das observações reais do que o modelo SARIMA(0,1,1)(0,1,1)₁₂, embora a discrepância em relação ao dados reais ainda seja relevante. O que já era de se deduzir devido a questão das tendências opostas entre o período amostral e o de validação mencionados na análise descritiva.

Ajustou-se um terceiro modelo, utilizando o método de alisamento exponencial de Holt - Winters aditivo, procurou-se de forma iterativa as constantes de suavização que minimizassem a soma de quadrados dos erros. A equação do modelo ajustado é mostrada a seguir:

$$L_t = 0,33558(Y_t - S_t) + (1 - 0,3558)(L_t + T_{t-1})$$

$$T_t = 0,0001(L_t - L_{t-1}) + (1 - 0,0001)T_{t-1}$$

$$S_t = 0,0001(Y_t - L_t) + (1 - 0,0001)S_{t-12}$$

A FIG. 33, apresenta o resultado do ajuste do modelo 3 e analisando o gráfico, percebe-se que os valores ajustados não acompanham tão de perto as observações originais como ocorrido nos dois primeiros modelos.




FIGURA 33 - Série *CréditoCP* e valores ajustados pelo modelo Winters

A FIG. 34 e a TAB.15 revelam que, assim como nos modelos anteriores, a discrepância entre o valor observado e as previsões do modelo de Holt-Winters continuam relevantes, e as observações referentes a julho e agosto de 2019 estão situadas fora da estimativa intervalar.




FIGURA 34 - Previsões do modelo Holt-Winters Aditivo

TABELA 15 - Comparativo entre os valores da série *CréditoCP*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo Holt-Winters Aditivo

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 5.184,00	R\$ 4.162,38	19,71%
jul./19	R\$ 5.598,00	R\$ 3.406,67	39,14%
ago./19	R\$ 5.526,00	R\$ 3.256,58	41,07%
set./19	R\$ 5.017,00	R\$ 3.596,50	28,31%
out./19	R\$ 5.392,00	R\$ 3.884,80	27,95%
nov./19	R\$ 5.958,00	R\$ 4.144,23	30,44%

A seguir são apresentadas as estatísticas dos erros de previsão, tanto para o período amostral quanto no período de validação.

TABELA 16 - Medidas de Acurácia (Período amostral)

Estatísticas dos Erros no Período Amostral (n=99)

	Modelo 1: SARIMA(0,1,1) (0,1,1)	Modelo 2: SARIMA(0,1,1) (2,1,0)	Modelo 3: Holt-Winters Aditivo ($\alpha=0,3558, \gamma=0,0001, \delta=0,0001$)
MAPE	10,9131	11,4911	9,9158
MPE	-1,2053	-0,1782	-2,0898
RMSD	740,15	807,487	714,157
MAE	601,59	623,918	582,505

A TAB. 16, mostra que o modelo 3, estimado pelo método Holt-Winters foi o que melhor acompanhou a série no período de amostral, pois apresentou valores menores que os demais para as medidas de acurácia apresentadas.

Com relação as previsões, a TAB. 17 mostra os resultados obtidos e revelam que assim como no período amostral, o modelo 2 foi o que apresentou os menores valores para as medidas de acurácia e, por isso o melhor ajuste com relação as previsões.

TABELA 17 - Medidas de Acurácia (Período de validação)

Estatísticas dos Erros de Previsão no Período Validação			
	Modelo 1: SARIMA(0,1,1) (0,1,1)	Modelo 2: SARIMA(0,1,1) (2,1,0)	Modelo 3: Holt - Winters Aditivo ($\alpha=0,3558, \gamma=0,0001, \delta=0,0001$)
MAPE	33,2103	28,3346	31,1048
MPE	33,2103	28,3346	31,1048
RMSD	1879,44	1635,18	1759,50
MAE	1821,14	1553,34	1703,97

4.3. Concessões de crédito - Capital de giro Longo Prazo

Será apresentado a seguir uma análise exploratória da série de concessão de crédito para pessoas jurídicas, no período compreendido entre março de 2011 e novembro de 2019, cujas operações possuem prazo superior há 365 dias, doravante denominada *CréditoLP*. A FIG. 35 apresenta informações acerca da série em estudo.




FIGURA 35 - Análise exploratória *CréditoLP*

O volume médio de concessões da série *CréditoLP* foi de R\$ 104757 milhões com um desvio padrão de R\$ 2538 milhões. A hipótese de normalidade dos dados, segundo o teste de Anderson-Darling não deve ser rejeitada ao nível de significância de 5%. Os dados estão bem distribuídos em torno da média e possuem uma leve assimetria a esquerda ($\text{Assimetria} = 0,387652 > 0$). O indicador de Curtose indica que a distribuição dos dados acompanha bem de perto a curva normal. Contudo, ao se avaliar o Boxplot apresentado na figura anterior percebe-se a presença de um valor atípico.

A série *CréditoLP* é apresentada pela FIG. 36 e é possível notar que o volume das concessões foi diminuindo ao longo dos meses observados até fevereiro de 2018 onde ocorre a retomada dos empréstimos de longo prazo e uma consequente elevação no volume de crédito concedido. Faz-se necessário destacar a marcada variação sazonal ocorrida principalmente em dezembro.




FIGURA 36 - Série de valores do CréditoLP (período Março-2011 a Julho-2019)

Os Boxplot's por ano e por mês apresentados respectivamente nas FIG. 37 (a) e FIG. 37 (b) concordam com o exposto a respeito da tendência e da sazonalidade. Vale destacar que os anos de 2014 e 2015 apresentaram uma variabilidade maior que os demais e em 2011 observou-se a presença de um valor atípico. As últimas observações da série, referentes ao ano de 2019 revelam uma tendência oposta ao período imediatamente anterior. Isso pode ser problemático na estimação dos modelos já que o período utilizado para a estimação do modelo apresenta um comportamento oposto ao utilizado para a validação.

Analisando as observações no gráfico por mês, destaca-se a grande variabilidade no mês de agosto. As medianas desalinhadas, conforme já mencionado indicam a presença da componente sazonal.




FIGURA 37 - Boxplot por ano e por mês da série CréditoLP

As funções de auto correlação (FAC) e auto correlação(FACP) parcial apresentados na FIG. 38 dão conta de que a série não apresenta um decaimento exponencial, revelando, assim como percebido na análise exploratória não se tratar de um passeio aleatório.




FIGURA 38 - FAC e FACP da série *CréditoLP*

Ao identificar a presença de tendência e sazonalidade, diferenciou-se a série de modo que ela se tornasse estacionária. Apenas uma diferenciação em nível não sazonal foi necessária para que a tendência fosse eliminada conforme mostra a FIG. 39.




FIGURA 39 - Série *CréditoLP* diferenciada

Tomou-se uma diferença de 12 para eliminar a sazonalidade e verificou-se na função de auto correlação (FAC) e na função de auto correlação parcial (FACP) da série diferenciada (FIG. 40 e FIG.41) que existe “lags” múltiplos de 12 significativos, o que implica incluir no modelo componente sazonal estocástica, além da determinística.




FIGURA 40 - FAC da Série *CréditoLP* não sazonal ($d=1$ e $D=1$)




FIGURA 41 - FACP da Série *CréditoLP* não sazonal ($d=1$ e $D=1$)

A observação de FAC e FACP em nível não sazonal e sazonal auxiliam na identificação das ordens do modelo a serem estimados. Os correlogramas da função de auto correlação que a lag 1 é estatisticamente significativa, enquanto que a função de auto correlação parcial revela decaimento exponencial, isso tanto para a série diferenciada em nível quanto sazonal, com evidencias para se considerar um processo de média móvel simples. Coma relação a parte sazonal, FAC e FACP indicam tanto um processo auto regressivo sazonal de ordem 1, considerando os correlogramas da série diferenciada em nível, quanto um processo de média móvel sazonal, considerando a série diferenciada considerando a sazonalidade. Por isso, optou-se por estimar os dois modelos e comparar o ajuste dos modelos.

Os resultados do ajuste do modelo $SARIMA(0,1,1)(0,1,1)_{12}$ são apresentados na TAB. 18 e a sua equação está descrita a seguir:

$$(1 - B)(1 - B^{12}) Y_t = (1 - 0,7723B)(1 - 0,8283B^{12})a_t$$

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - 0,7723a_{t-1} - 0,8283a_{t-12} + 0,6397a_{t-13}$$

TABELA 18 - Resultados da estimação do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12

Modelo: SARIMA (0,1,1) (0,1,1)

Variável	Coefficiente	Erro Padrão	Estatística-t	Valor-p
MM(1)	0,7723	0,0707	10,21	0,0000
SMA(12)	0,8283	0,0797	10,40	0,0000
AIC	345,15	Estatística-Q de Ljung-Box dos resíduos		
AICc	345,44	Q(k)	Qui-Quadrado	Valor-p
BIC	352,51	Q(12)	12,4	0,262
N. Observ	99	Q(24)	23,3	0,383
		Q(36)	33,8	0,478
		Q(48)	44,2	0,546

Os coeficientes atendem as condições de estacionariedade e invertibilidade, pois estão compreendidos dentro do círculo unitário. Eles também são estatisticamente diferentes de zero, pois o valor-p de cada coeficiente é menor que $\alpha=0,05$. O valor-p das estatísticas de Ljung-Box revelam que a hipótese nula de que os erros são não correlacionados não deve ser rejeitada, considerando 5% de significância.

Conforme a FIG. 42, as funções de auto correlação e auto correlação parcial dos resíduos revelam se tratar de um ruído branco gaussiano.

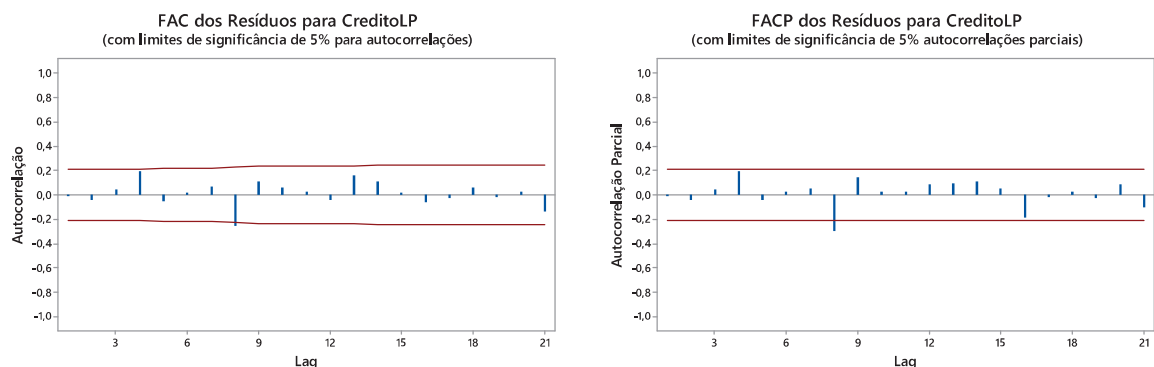


FIGURA 42 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1)(0,1,1) sazonalidade = 12

De acordo com o gráfico de probabilidade normal e o teste Anderson-Darling (Valor-p=0,290 > $\alpha=0,05$), apresentado na FIG. 43 os resíduos seguem uma distribuição normal e estão bem distribuídos em torno da média conforme mostra o histograma de resíduos.

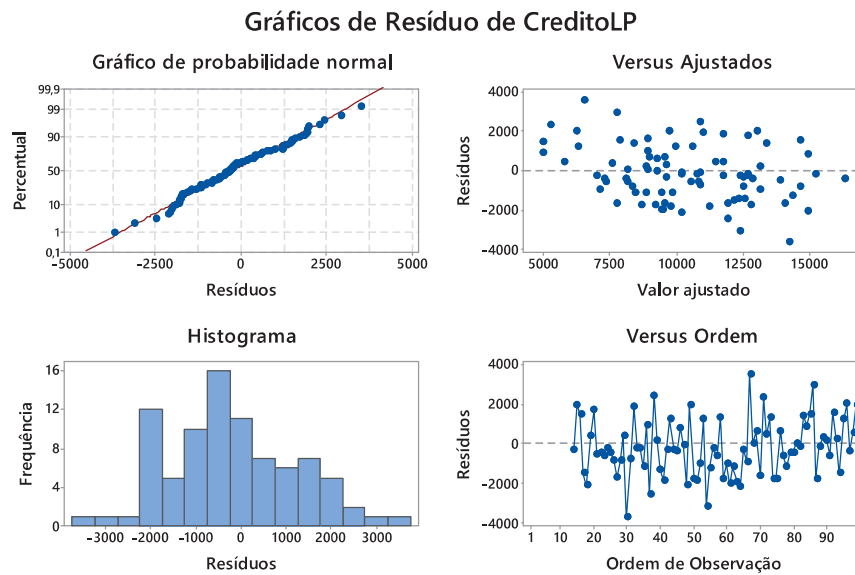


FIGURA 43 - Análise de resíduos do modelo SARIMA (0,1,1) (0,1,1)

Os valores ajustados acompanham bem a série original e a análise de resíduos foi satisfatória. Não é possível inferir graficamente qual dos dois modelos acompanhou mais de perto a série. Essa verificação será feita posteriormente analisando-se as medidas de acurácia de cada modelo.




FIGURA 44 - CréditoLP e ajustados do modelo SARIMA (0,1,1) (0,1,1) sazonalidade = 12

A FIG.45 e a TAB. 19 apresenta as previsões do modelo e revela que a os valores reais estão um pouco distantes das previsões do modelo, mas todos os valores se situam dentro da estimativa intervalar.




FIGURA 45 - Previsões do modelo SARIMA(0,1,1) (0,1,1) sazonalidade = 12

TABELA 19 - Comparativo entre os valores da série *CréditoLP*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (0,1,1) sazonalidade = 12

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 11.792,00	R\$ 11.593,06	1,69%
jul./19	R\$ 11.600,00	R\$ 9.114,75	21,42%
ago./19	R\$ 11.106,00	R\$ 10.293,07	7,32%
set./19	R\$ 10.964,00	R\$ 9.399,57	14,27%
out./19	R\$ 12.967,00	R\$ 10.668,11	17,73%
nov./19	R\$ 12.418,00	R\$ 10.768,45	13,28%

Conforme metodologia de Box-Jenkins ajustou-se um segundo modelo SARIMA(0,1,1)(1,1,0)₁₂ com intuito de se obter um ajuste que minimizasse os erros tanto no período amostral quanto no período de validação. A seguir são apresentados a equação do modelo e a TAB. 20 com os resultados do modelo estimado.

$$(1 + 0,6496B^{12})(1 - B)(1 - B^{12})Y_t = (1 - 0,7550B)a_t$$

$$Y_t = Y_{t-1} + 0,3504Y_{t-12} - 0,245 Y_{t-13} + 0,6496Y_{t-24} - 0,6496Y_{t-25} + a_t - 0,7750a_{t-1}$$

TABELA 20 - Resultados da estimação do modelo SARIMA(0,1,1) (1,1,0) sazonalidade = 12

Modelo: SARIMA(0,1,1)(1,1,0)₁₂

Variável	Coefficiente	Erro Padrão	Estatística-t	Valor-p
MM(1)	0,7550	0,0719	-7,45	0,0000
SAR(1)	-0,6496	0,0872	10,50	0,0000
AIC	1431,92	Estatística-Q de Ljung-Box dos resíduos		

AICc	1432,24	Q(k)	Qui-Quadrado	Valor-p
BIC	1439,07	Q(12)	9,8	0,457
N. Observ	93	Q(24)	15,2	0,854
		Q(36)	22,0	0,944
		Q(48)	30,6	0,960

Os coeficientes do modelo atendem as condições de estacionariedade e invertibilidade e são estatisticamente significativos, pois o valor-p de todos eles é menor que o nível de significância de 5%. Os resultados da estimação são apresentados na TAB. 20. As estatísticas de Ljung-Box revelam que os resíduos não são autocorrelacionados, a um nível superior ao nível de 5%. Tais evidências revelam que o ajuste do modelo é adequado e a FIG. 46 mostra que os valores ajustados acompanham bem de perto a série no período amostral.




FIGURA 46 - *CréditoLP* e ajustados pelo modelo SARIMA (0,1,1) (1,1,0) sazonalidade = 12

A FIG. 47 apresenta as funções FAC e FACP dos resíduos e indicam que eles representam um perfeito ruído branco gaussiano.

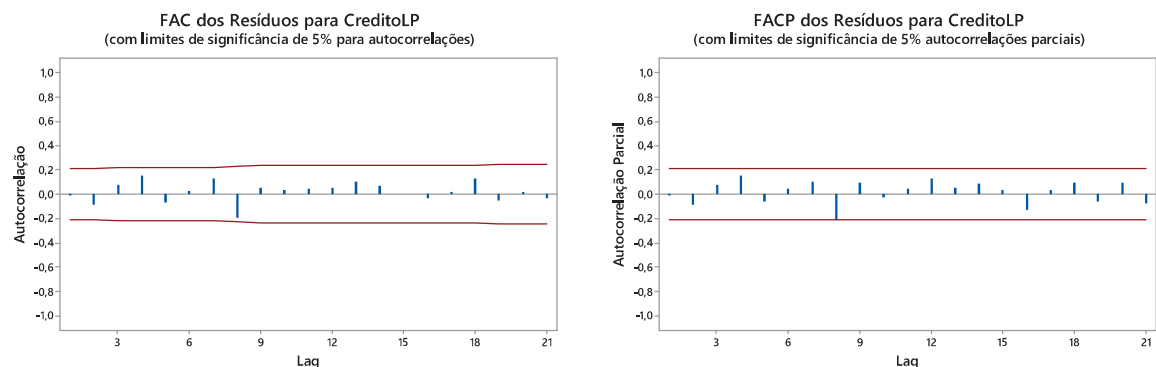


FIGURA 47 - FAC e FACP dos resíduos do modelo SARIMA (0,1,1) (1,1,0) sazonalidade =12

O histograma e o gráfico de probabilidade normal, apresentados na FIG. 48, revelam que os erros apresentam uma observação discrepante, contudo, o teste de

normalidade de Anderson-Darling não indica evidências que justifiquem a rejeição da hipótese nula de normalidade (valor - $p = 0,191 > \alpha = 0,05$).

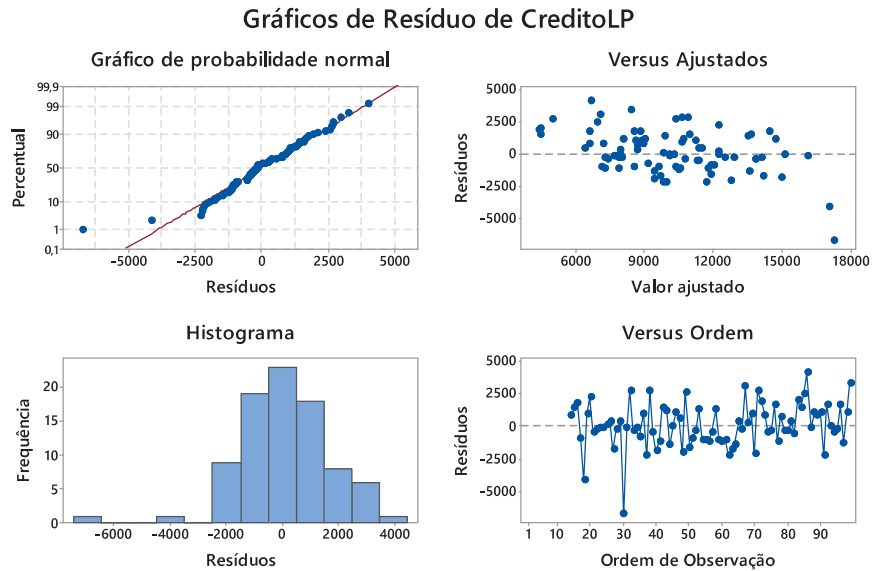


FIGURA 48 - Análise de resíduos do modelo SARIMA (0,1,1) (1,1,0) sazonalidade = 12

As previsões do modelo ajustado, apesar de um pouco distantes das observações originais se mantem dentro da estimativa intervalar, conforme observa-se na FIG. 49 e na TAB. 21.




FIGURA 49 - Previsões do modelo SARIMA(0,1,1) (1,1,0) sazonalidade = 12

TABELA 21 - Comparativo entre os valores da série *CréditoLP*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo SARIMA(0,1,1) (1,1,0) sazonalidade = 12

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 11.792,00	R\$ 11.769,50	0,19%
jul./19	R\$ 11.600,00	R\$ 8.783,68	24,28%
ago./19	R\$ 11.106,00	R\$ 9.560,41	13,92%
set./19	R\$ 10.964,00	R\$ 8.732,26	20,36%
out./19	R\$ 12.967,00	R\$ 10.278,73	20,73%
nov./19	R\$ 12.418,00	R\$ 10.423,76	16,06%

O terceiro modelo ajustado, seguiu o método de Holt - Winters aditivo, as constantes de suavização foram definidas iterativamente, e a equação do modelo é descrita

$$L_t = 0,2066(Y_t - S_t) + (1 - 0,2066)(L_t + T_{t-1})$$

$$T_t = 0,0207(L_t - L_{t-1}) + (1 - 0,0207)T_{t-1}$$

$$S_t = 0,0001(Y_t - L_t) + (1 - 0,0001)S_{t-12}$$

Os ajustes do modelo acompanharam bem a série e, de forma análoga a comparação entre o primeiro e o segundo modelo, o melhor ajuste será determinado a partir das medidas de acurácia.




FIGURA 50 - *CréditoLP* e ajustados pelo modelo Holt-Winters

As previsões do modelo, apresentadas na FIG. 51 e na TAB.22 revelam que as observações estão bem próximas da estimativa intervalar, sendo que a observação relativa ao mês de julho de 2019 está situada fora do intervalo de confiança de 95%.




FIGURA 51 - Previsões Holt-Winters Aditivo

TABELA 22- Comparativo entre os valores da série *CréditoLP*, no período de 06/2019 até 11/2019 e os valores(milhões) pelo modelo Holt-Winters

Período	Valores Observados	Previsões do modelo	Erro de previsão (proporção do valor realizado)
jun./19	R\$ 11.792,00	R\$ 10.953,70	7,11%
jul./19	R\$ 11.600,00	R\$ 8.547,67	26,31%
ago./19	R\$ 11.106,00	R\$ 10.055,14	9,46%
set./19	R\$ 10.964,00	R\$ 8.927,13	18,58%
out./19	R\$ 12.967,00	R\$ 10.255,62	20,91%
Nov./19	R\$ 12.418,00	R\$ 10.412,36	16,15%

As medidas de acurácia, apresentadas pela TAB. 23, revelam que, no período amostral, o modelo 1 foi o que melhor acompanhou a série e conforme já havia sido discutido na análise de resíduos dos modelos SARIMA.

TABELA 23 - Medidas de Acurácia (Período amostral)

Estatísticas dos Erros no Período Amostral (n=99)	Modelo 1:	Modelo 2:	Modelo 3: Holt-Winters Aditivo
	SARIMA (0,1,1) (0,1,1)	SARIMA (0,1,1) (1,1,0)	($\alpha=0,2066$, $\gamma=0,0207$, $\delta=0,0001$)
MAPE	10,9195	12,9005	16,4205
MPE	-2,9506	-0,2355	16,4205
RMSD	1418,41	1647,57	2107,40
MAE	1154,07	1253,94	1949,23

O modelo obtido através do método proposto por Holt-Winters foi o que apresentou a melhor capacidade preditiva, conforme TAB. 24, apesar de ter uma observação localizada fora da estimativa intervalar.

TABELA 24 -Medidas de Acurácia (Período de validação)

Estatísticas dos Erros no Período de Validação			
	Modelo 1: SARIMA (0,1,1) (0,1,1)	Modelo 2: SARIMA (0,1,1) (1,1,0)	Modelo 3: Holt-Winters Aditivo ($\alpha=0,2066$, $\gamma=0,0207$, $\delta=0,0001$)
MAPE	12,6188	15,9220	10,6820
MPE	12,6188	15,9220	-1,5466
RMSD	1699,52	2101,80	1412,72
MAE	1501,67	1883,11	1049,62

5. CONSIDERAÇÕES FINAIS

O desenvolvimento do presente estudo possibilitou uma reflexão de como a análise de séries temporais aplicada a previsão do volume de concessão de crédito pode contribuir para o aprimoramento da definição de objetivos estratégicos ligados as condições do mercado e da definição sobre a demanda relacionada ao crédito bancário.

De um modo geral, mesmo havendo diversos fatores macro e microeconômicos que interferem de alguma forma na concessão do crédito, fazendo com que o volume seja definido pela oferta, a possibilidade de modelar o ciclo de concessões traz inúmeras vantagens ao processo, contribuindo para que a atividade econômica se desenvolva por meio da expansão da demanda agregada.

Os resultados obtidos no presente estudo mostram que podem ser realizadas previsões relacionadas a concessão de crédito bancário a partir dos resultados anteriores do próprio volume de concessões. No entanto, deve-se considerar que como as previsões geradas se baseiam em valores relacionados a períodos anteriores, os modelos estimados possuem limitações quando for necessário obter previsões mais distantes, tornando-as menos confiáveis.

De forma geral, os modelos univariados construídos, tanto via modelos SARIMA quanto através da técnica de alisamento exponencial, apresentaram algumas deficiências relacionadas as previsões do modelo. Isso se justifica em função da divergência na tendência observada no período amostral e aquela obtida no período de validação do modelo. No entanto, como o período de validação é algo

arbitrário, resultados mais satisfatórios podem ser encontrados com a atualização das séries ao longo do tempo.

Para a série de concessão de crédito total o modelo SARIMA(2,1,0)(0,1,1)₁₂ apesar de não ser o que apresentou as melhores previsões foi o que melhor se ajustou a série original e apresentou boa performance para o ajuste dos erros. Com relação a série de concessão de crédito com prazo inferior a 365 dias, a divergência entre o comportamento dos dados de validação e os utilizados para estimação influenciaram no ajuste para os modelos SARIMAS e por isso o método de Holt-Winters, foi o que obteve a melhor performance com relação as estatísticas dos erros.

Na série de concessão de crédito com prazo superior a 365 dias, o modelo SARIMA(0,1,1)(0,1,1)₁₂, conseguiu acompanhar de perto série original, mas também apresentou o mesmo problema da série *CréditoCP* e, por isso, as previsões do modelo Holt-Winters apresentou melhor performance considerando as previsões, também nesse caso.

Dada a importância do tema, novos estudos podem ser desenvolvidos considerando variáveis macroeconômicas e a sua influência sobre o processo de concessão de crédito. A taxa de juros e o produto, são exemplos de variáveis que podem ter influência nesse processo e contribuir para a definição de estimativas mais assertivas.

Nesse sentido, a utilização de análise de séries temporais se mostrou efetiva e os objetivos propostos foram alcançados, na medida em que as previsões de concessão de crédito podem auxiliar na tomada de decisões estratégicas e na orientação para novos estudos.

REFERÊNCIAS

ABITANTE, K. G. Modelos de séries temporais aplicados à análise prospectiva de concessão de crédito bancário, Piracicaba, p. 251, 2007.

BANCO CENTRAL DO BRASIL. Portal de Dados Abertos. **Banco Central do Brasil – Departamento de Estatísticas**, 2019. Disponível em: <www.bcb.gov.br/estatisticas/estatisticasmonetariascredito>. Acesso em: 15 jan. 2019.

BOX, G. E. P.; JENKINS, G. M. **Times Series Analysis: Forecasting and Control**. 4. ed.: Willey, 2008.

BRUGNOLA, G. B. A expansão recente da oferta de crédito no Brasil: 2003 - 2008, Campinas, p. 53, Dezembro 2009. Disponível em: <<http://www.bibliotecadigital.unicamp.br/document/?code=000470594&opt=4>>. Acesso em: 10 mar. 2020.

DIEESE. Análise da evolução do crédito no período recente 2013-2017, 2018. Disponível em: <<https://www.dieese.org.br/notatecnica/2018/notaTecCredito2014a2017.pdf>>. Acesso em: 02 mar. 2020.

FABIANI, E. R. **Direito e Crédito Bancário no Brasil**. 1ª. ed. São Paulo: Saraiva, 2011.

FRANCO, D. C. **Modelagem Arima**. UFMG. Belo Horizonte, p. 104. 2011.

GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5ª. ed. Porto Alegre: AMGH Editora Ltda., 2011.

KOCHE, J. C. **Fundamentos de Metodologia Científica**. 1ª. ed. Petrópolis: Editora Vozes, 2002.

LANZANA, A. E. T. **Economia Brasileira: Fundamentos e Atualidade**. 5ª. ed. São Paulo: Atlas Ltda, 2017.

MORETTIN, P. A. **Econometria Financeira - Um curso em séries temporais financeiras**. 2ª. ed. São Paulo: Blucher , 2011.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 3ª. ed. São Paulo: Edgar Blucher Ltda, v. 1, 2018.

NETO, J. L. D. C.; SÉRGIO, R. S. G. **Análise de Risco de Crédito**. Curitiba: IESDE Brasil S.A., 2009.

NIELSON, F. A. G.; OLIVO, L. D. F.; MORILHAS, L. J. **Guia Prático Para Elaboração de Monografias, Dissertações e Teses em Administração**. 1ª. ed. São Paulo: Saraiva Uni, 2018.

PRODANOV, C. C.; FREITAS, E. C. D. **Metodologia do Trabalho Científico: Métodos e Técnicas do Trabalho Acadêmico**. 2ª. ed. Novo Hamburgo: Universidade Feevale, 2013.

SILVA, C. R. L. D.; LUIZ, S. **Economia e mercados: introdução à economia**. 20ª. ed. São Paulo: Saraiva, 2018.

SILVA, J. P. D. **gravada, Gestão e Análise de Risco de Crédito: 9a edição revista e atualizada**. 9ª. ed. São Paulo: Cengage Learning, 2016.

WOOLDRIDGE, J. M. **Introdução à Econometria: Uma Abordagem Moderna**. 3ª. ed. São Paulo: Cengage Learning, 2016.