

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO**

Junior Giacobbo

**PREVISÃO DE DEMANDA POR ARMAZENAGEM DE GRÃOS NO ESTADO
DO RIO GRANDE DO SUL**

Porto Alegre

2020

Junior Giacobbo

**PREVISÃO DE DEMANDA POR ARMAZENAGEM DE GRÃOS NO ESTADO
DO RIO GRANDE DO SUL**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do título de Mestre em Engenharia de Produção, modalidade profissional, área de concentração em Sistemas de Produção.

Orientador: Flávio Sanson Fogliatto,
Ph.D.

Porto Alegre

2020

Junior Giacobbo

Previsão de Demanda por Armazenagem de Grãos no Estado do Rio Grande do Sul

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Profissional e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação Mestrado Profissional em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

Prof. Orientador, PhD. Flávio Sanson Fogliatto
Orientador PMPEP/UFRGS

Profa. Christine Tessele Nodari
Coordenadora PMPEP/UFRGS

Banca Examinadora:

Professor Jonatas Ost Scherer, Dr. (PMPEP /UFRGS)

Professor Milad Yusefi, Dr. (PMPEP/UFRGS)

Professor Gilberto Tavares dos Santos, Dr. (PPGA/UFRGS)

AGRADECIMENTOS

Aos meus pais, Reni (*in memoriam*) e Nádia, por me ensinarem a valorizar o aprendizado contínuo e os estudos.

Aos meus irmãos, Irineu e Elaine, pelos estímulos da educação formal desde o meu nascimento.

Ao meu orientador, Flávio Sanson Fogliatto, pelas ideias e direcionamentos nas aulas presenciais e no decorrer da dissertação.

Especialmente, à minha esposa, Tatiana, pelo incentivo diário e apoio incondicional para o prosseguimento nos estudos, pelo estímulo à pesquisa, por abdicar de momentos no convívio em família para que essa etapa fosse concluída.

RESUMO

Essa dissertação tem por objeto a previsão de demanda por armazenagem de grãos no estado do Rio Grande do Sul. Para realizar o estudo, aplica métodos de previsão de demanda com o objetivo de verificar até quando os financiamentos bancários nessa área serão bons negócios para as agências de fomento em geral e, em especial, para o Badesul Desenvolvimento. Para realizar tal análise, parte-se da contextualização da importância do setor de grãos na economia brasileira e gaúcha, e sua evolução a partir de 1980. A seguir, elaborou-se uma estimativa de demanda por estocagem para o Rio Grande do Sul a partir de dados do Ministério da Agricultura, Pecuária e Abastecimento (Mapa) e da Companhia Nacional de Abastecimento (Conab). Fez-se uma previsão para seis períodos à frente; os resultados apontam que na safra de 2024/2025 a produção de grãos continuará sendo superior à capacidade de armazenamento no estado gaúcho. A safra 2024/2025, segundo a previsão de demanda mais ajustada, realizada através do modelo ARIMA, será de 42 milhões de toneladas para a produção de grãos e a capacidade estática de armazenamento será de cerca de 33,5 milhões de toneladas. Nesse cenário, a relação entre capacidade de armazenamento e produção de grãos é de 79,7%, inferior aos 120% recomendados pela Organização das Nações Unidas para a Alimentação e a Agricultura (FAO), o que demonstra que há oportunidade de realização de negócios na linha de fomento à armazenagem no Rio Grande do Sul.

Palavras-Chave: Previsão de demanda. Armazenagem de grãos no Rio Grande do Sul. Fomento ao desenvolvimento econômico.

ABSTRACT

This Master thesis aims to forecast the demand for grain storage in the state of Rio Grande do Sul. In order to carry out the analysis, the methods are applied to verify when bank financing in this area will be a good business for investment banks in general, and in particular for *Badesul Desenvolvimento*. The starting point in the analysis is to contextualize the grain sector's importance in the Brazilian economy and in the state of Rio Grande do Sul, and its evolution since 1980. Next, an estimate of demand for grain storage in Rio Grande do Sul is produced using data from Ministry of Agriculture, Livestock and Supply (Mapa) and the National Supply Company (Conab). A 6-year horizon forecast is made, with results indicating that in the 2024/2025 harvest grain production will continue to be higher than storage capacity in the state of Rio Grande do Sul. For the 2024/2025 harvest the forecast obtained through the ARIMA model is around 42 million tons of grain, but the storage capacity will be around 33.5 million tons. In this scenario, grain storage capacity will be 79.7% of the production, lower than the 120% recommended by FAO, which demonstrates that there is an opportunity to do business towards financing grain storage in Rio Grande do Sul.

Keywords: Grain demand forecast; Grain Storage in Rio Grande do Sul; ARIMA model; Investment for Economic Development.

LISTA DE FIGURAS

- Figura 1** - (a) Representação gráfica da série original da produção da safra de grãos no RS no período de 1980/81 a 2018/19 (b) Função de Autocorrelação (ACF) da série original (c) Representação gráfica do logaritmo da série original (d) Função de Autocorrelação (FAC) do logaritmo da série original..... 42
- Figura 2** - (a) Representação gráfica da primeira diferença da série do logaritmo série original (b) Função de Autocorrelação (FAC) do logaritmo da série original (c) Função de Autocorrelação Parcial (FACP) do logaritmo da série original.... 43
- Figura 3** - Previsão da produção de safra de grãos para os próximos seis anos-safra no estado do RS..... 45
- Figura 4** - (a) Representação gráfica da série original da capacidade estática de armazenamento de grãos no RS no período de 1980/81 a 2018/19. (b) Função de Autocorrelação (ACF) da série original. (c) Representação gráfica do logaritmo série original. (d) Função de Autocorrelação (FAC) do logaritmo da série original. 46
- Figura 5** - (a) Representação gráfica da segunda diferença da série do logaritmo série original. (b) Função de Autocorrelação (FAC) do logaritmo da série original. (c) Função de Autocorrelação Parcial (FACP) do logaritmo da série original.... 47
- Figura 6** - Previsão da capacidade estática de armazenamento dos grãos, para os próximos seis anos no estado do RS. 48
- Figura 7** - Projeção da produção agrícola de grãos e capacidade de armazenamento no Brasil para os próximos anos safra 50

LISTA DE TABELAS

Tabela 1– Produção de grãos no RS na safra 2018/2019	28
Tabela 2 - Seleção dos modelos para produção de safra	44
Tabela 3 - Seleção dos modelos para capacidade estática de armazenamento de grãos.	47
Tabela 4 - Valores preditos para a produção agrícola de grãos e capacidade de armazenamento no RS para os próximos seis anos-safra.....	50
Tabela 5 – Número de operações realizadas desde o início do programa PCA-Armazéns no RS	52

LISTA DE ABREVIATURAS E SIGLAS

- ACF – Coeficiente de Auto-Correlação
- ACFP – Coeficiente de Auto-Correlação Parcial
- AIC – Critério de Informação de Akaike
- ARIMA – Autoregressive Integrated Moving Average
- B-J – Box & Jenkins
- BM&F – Bolsa de Mercadorias e Futuro
- BNDES – Banco Nacional de Desenvolvimento Econômico e Social
- Conab – Companhia Nacional de Abastecimento
- Emater – Empresa de Assistência Técnica e Extensão Rural
- Embrapa – Empresa Brasileira de Pesquisas Agropecuárias
- FAO - Organização das Nações Unidas para a Alimentação e a Agricultura
- FEE – Fundação de Economia e Estatística
- GO - Goiás
- IBGE – Instituto Brasileiro de Economia e Estatística
- IGC – *International Grains Council*
- i.i.d – Independente e identicamente distribuído
- LI – Limite inferior
- LS – Limite Superior
- MAPE – Média Percentual Absoluta do Erro
- MT – Mato Grosso
- ONU – Organização das Nações Unidas
- PCA – Programa de Construção de Armazéns
- PR - Paraná
- RS – Rio Grande do Sul
- SICARM – Sistema de Cadastro Nacional de Unidades Armazenadoras

SUMÁRIO

1 INTRODUÇÃO	11
1.1 TEMA E OBJETIVOS	13
1.2 JUSTIFICATIVA DO TEMA E DOS OBJETIVOS	14
1.3 PROCEDIMENTOS METODOLÓGICOS	15
1.4 ESTRUTURA DA DISSERTAÇÃO	16
1.5 DELIMITAÇÕES DO ESTUDO	17
2 REFERENCIAL TEÓRICO	18
2.1 ARMAZENAGEM DE GRÃOS	18
2.2 O CONCEITO DE DEMANDA E SUA IMPORTÂNCIA	21
2.3 PREVISÃO DE DEMANDA E SUAS TÉCNICAS	22
2.4 ANÁLISE DE SÉRIES TEMPORAIS	24
3. MÉTODO	27
3.1 BASE DE DADOS	27
3.1.1 Obtenção dos Dados	29
3.2 MÉTODO DE ESTIMAÇÃO	29
3.2.1 Suavização Exponencial Biparamétrica de Holt	30
onde:	30
3.2.2 Metodologia Box-Jenkins	31
3.3 IDENTIFICAÇÃO DO MODELO	32
3.3.1 Estimativa dos Parâmetros do Modelo Identificado	33
3.3.2 Modelos autorregressivos	34
3.3.3 Modelo de Médias Móveis	34
3.3.4 Modelos Auto-Regressivos de Médias Móveis (ARMA)	35
3.3.5 Modelo Autoregressivo Integrado de Médias Móveis (ARIMA)	35
3.4 MEDIDAS DE ACURÁCIA	35
3.4.1 Erro Percentual Absoluto Médio de Previsão (MAPE)	36
3.4.2 Critério de Informação de Akaike (AIC)	36

4	DESCRIÇÃO DO ESTUDO, RESULTADOS E DISCUSSÃO	38
4.1	DEFINIÇÃO DO PROBLEMA	38
4.2	OBTENÇÃO DE DADOS	39
4.3	ESCOLHA DO MÉTODO DE PREVISÃO	39
4.4	ESTUDO DE CASO	40
4.4.1	Produção de Safra dos Grãos	41
4.4.2	Capacidade Estática de Armazenamento dos Grãos	45
4.4.3	Comparação Entre Produção e Capacidade Estática de Armazenamento dos Grãos	49
4.4.4	Panorama Financeiro Histórico do PCA Armazéns	51
5	CONSIDERAÇÕES FINAIS	53
	REFERÊNCIAS	56
	APÊNDICE 1 - SÉRIE HISTÓRICA DA PRODUÇÃO DE GRÃOS E DA CAPACIDADE DE ARMAZENAMENTO DO ESTADO DO RS	63
	APÊNDICE 2 – COMANDOS UTILIZADOS NO SOFTWARE R	64

1 INTRODUÇÃO

Estimar a demanda é fundamental para projetar o futuro de qualquer organização (MAKRIDAKIS *et al.*, 2018). Segundo Armstrong (2001), as previsões de demanda podem auxiliar nas principais tomadas de decisões, tanto em nível operacional como estratégico, por apresentarem uma visão mais clara do futuro. O agronegócio no país é caracterizado por atividades gerenciais complexas e movimentação volume físico e financeiro elevado. Tais fatores exigem ampla visão empresarial dos produtores, dos fornecedores de insumos, dos processadores da matéria prima e dos negociantes, com objetivo de manter e estender as vantagens competitivas de produção (MARTINS *et al.*, 2015).

O Brasil é destaque no comércio internacional como exportador de *commodities* agrícolas, sendo um dos países mais competitivos do mundo na produção de grãos (JANK *et al.*, 2005). A concorrência no mercado internacional requer, entretanto, que os produtos brasileiros exportados sejam de alta qualidade e com preços competitivos. Saliencia-se, porém, que o preço deve cobrir os custos de toda a cadeia produtiva do setor, o que não ocorre quando o produtor deseja escoar a produção rapidamente, por não ter local para estocá-la. Nesse contexto, a capacidade instalada de armazenamento nas zonas de produção de grãos é fundamental, devido às peculiaridades da produção agrícola, como sazonalidade e dependência de fatores climáticos. Opta-se, em muitos casos, pela comercialização da safra diretamente das propriedades agrícolas para os portos, mesmo sem a programação de navios, ou empresas de beneficiamento (MARTINS *et al.*, 2015).

Dentre os estados brasileiros que mais produzem grãos, segundo dados da Companhia Nacional de Abastecimento (CONAB, 2018), destacam-se Mato Grosso (MT), Goiás (GO), Rio Grande do Sul (RS) e Paraná (PR). No RS, objeto de estudo dessa dissertação, de acordo com a Fundação de Economia e Estatística (FEE, 2015), soja, arroz, milho e trigo constituem as principais culturas agrícolas praticadas em termos de área plantada e quantidade produzida. A produção de soja foi a que mais avançou no Estado nos últimos anos, incentivada pelo crescimento da demanda externa e pela alta nos preços

recebidos pelos agricultores. No período entre 2006 e 2014, a soja foi responsável por mais de 40% do crescimento do Valor Bruto da Produção agropecuária do RS (FEE,2015).

A produção de grãos vem crescendo historicamente no Brasil (CONAB, 2019), além de estar aumentando a área plantada, tendência que tem como consequência que a cada ano tem-se uma safra recorde no país. Em contrapartida, a capacidade instalada para estocagem, que já era aquém da necessária, embora esteja crescendo, permanece bastante inferior à necessidade do setor. A área plantada no RS, segundo o levantamento sistemático da produção agrícola, divulgado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) para 2019 é de 9.056.063 hectares, uma alta de 1,06% em relação a 2018. O estudo de Zanin (2011) afirma que o crescimento da produção de soja se concretiza nos âmbitos estadual e nacional. A soja, fortemente ligada ao mercado internacional, é o principal grão em volume de produção e, em função de preços atrativos, deve manter, e até mesmo aumentar, sua importância na economia agrícola nos próximos anos.

Segundo a Organização das Nações Unidas para a Alimentação e a Agricultura (FAO) e Mendes e Padilha Junior (2007), o ideal é que a capacidade estática de um país seja 1,2 vez a produção de grãos. Para atender a esse requisito, a capacidade estática de armazenagem brasileira deveria ser, em 2018, de 274 milhões de toneladas; porém, na safra 2017/2018, foi de 169 milhões de toneladas, correspondendo a uma relação de 0,74 vez a produção de grãos, 48,3% abaixo do patamar desejável. No RS, a safra 2018/2019 era de 35.160,3 milhões de toneladas, enquanto a capacidade de armazenamento de grãos era de 29.571,7 milhões de toneladas, que corresponde a aproximadamente 84% da produção de grãos e está aproximadamente 45% abaixo do patamar desejável.

Tendo em vista esse cenário, o governo federal, através do Banco Nacional de Desenvolvimento Econômico e Social (BNDES), lançou, em agosto de 2013, um programa de fomento específico ao setor de armazenagem de grãos, disponibilizando aos produtores financiamentos de longo prazo com taxas, na época, inferiores à taxa básica de juros (taxa Selic) para a aquisição de silos e

infraestrutura para a estocagem. No ano de 2019, tal programa de fomento à construção e ampliação de armazéns (PCA Armazéns) estava operando com taxas de juros entre 6% e 7% ao ano e prazo para amortização de até 15 anos para aquisição de silos.

O Badesul Desenvolvimento é a agência de fomento do estado do RS e sua principal missão é promover o desenvolvimento da economia gaúcha (BADESUL, 2019). Sua principal fonte de recursos são as linhas de crédito do BNDES, dentre as quais o programa PCA Armazéns. Diante desse contexto, o objetivo desse estudo é realizar previsões de demanda para a safra de grãos e para a capacidade de armazenamento de grãos no RS, bem como uma análise da linha de financiamento à armazenagem do BNDES – PCA Armazéns e sua continuidade como um possível gerador de negócios para a agência de fomento gaúcha, uma vez que quando o estado atingir o ponto de armazenamento ótimo, a política de fomento deve ser alterada.

Este trabalho pretende contribuir teoricamente e empiricamente para o estudo de demanda de grãos no RS. O argumento fundamental deste trabalho é o de que a armazenagem de grãos no RS chegará ao ponto de ótimo nos próximos anos, de maneira que a linha de crédito de agências de fomento, especialmente o Badesul Desenvolvimento para essa finalidade, não será mais um negócio viável. A hipótese principal que se busca investigar e testar é se as políticas de subsídio à construção de armazéns estão surtindo efeito e até quando será necessário investir em linhas de apoio para armazenagem de grãos, tendo como base a capacidade de armazenagem recomendada pela FAO.

1.1 TEMA E OBJETIVOS

O tema desta dissertação é a previsão de demanda através de métodos quantitativos. O objetivo geral do trabalho é analisar a viabilidade do Badesul Desenvolvimento continuar oferecendo a linha de financiamento PCA Armazéns no seu portfólio de negócios, através de modelos de previsão de demanda. Os objetivos específicos são (i) realizar uma revisão da literatura sobre previsão de

demanda com métodos adequados à modelagem de séries com tendência e ciclo em ambientes similares; (ii) aplicar modelos de previsão de demanda, usando dados de produção de grãos da Companhia Nacional de Abastecimento e do Instituto Brasileiro de Economia e Estatística (IBGE); (iii) desenvolver um modelo de previsão que permita estimar a demanda por armazenagem de grãos no estado do RS; e (iv) estimar se a armazenagem de grãos no estado do RS vai alcançar os níveis de armazenamento recomendados pela FAO nos próximos seis anos-safra.

1.2 JUSTIFICATIVA DO TEMA E DOS OBJETIVOS

A justificativa para o tema proposto é a necessidade de previsão da quantidade de silos, armazém com sacaria e armazém a granel para estocagem de grãos. Além da soja, principal produto agrícola do RS, há expectativa de elevação nos estoques mundiais de milho, arroz e trigo.

O Badesul Desenvolvimento atua nos segmentos de agronegócios, inovação, apoio a municípios e empresas, sendo que o agronegócio respondia por cerca de 40% da carteira ativa em agosto de 2019. Essa forte concentração no mercado primário faz com que o planejamento agrícola influencie diretamente na viabilidade dos negócios da agência de fomento gaúcha.

O Banco Nacional de Desenvolvimento Econômico e Social e o Badesul Desenvolvimento compõem o chamado Sistema Nacional de Fomento. Tal sistema é uma subseção do sistema financeiro nacional, que atua na concessão de crédito ou prestação de garantias para setores estratégicos ou para agentes e regiões que não possuem acesso a financiamento pelo setor privado (ABDE, 2015).

Desde a criação da linha de crédito PCA Armazéns, em 2013, o RS é o estado com o maior número de operações dentre os estados repassadores do programa no Brasil, respondendo por 673 operações das 2.335 ocorridas entre 2013 e junho de 2019, o que demonstra o quantitativo de operações realizadas no programa. Dada a significância dos números é necessário verificar a efetividade

do programa e até quando será uma linha rentável para a instituição e uma área da economia gaúcha que requer políticas de fomento.

1.3 PROCEDIMENTOS METODOLÓGICOS

De acordo com a classificação de Silva e Menezes (2001), essa dissertação pode ser classificada, com relação à natureza, abordagem, objetivos e procedimentos técnicos, como:

- Pesquisa aplicada, uma vez que visa a gerar conhecimentos para aplicação prática.
- Quantitativa, em que os números e dados do caso estudado serão analisados.
- Exploratória, dado que visa a maior familiaridade com o problema.
- Estudo de caso, ao verificar um caso específico e permitir um conhecimento detalhado do mesmo.

Referente à natureza, essa pesquisa é caracterizada como aplicada, pois propõe uma solução específica, de aplicação à empresa estudada. Em relação aos procedimentos adotados, trata-se de uma abordagem quantitativa, com a aplicação do estudo de séries temporais através do modelo ARIMA.

Quanto aos objetivos, a pesquisa caracteriza-se como exploratória, uma vez que visa a explorar ou fazer uma busca de um problema ou uma situação para a obtenção de conhecimento e maior compreensão sobre o assunto (MALHOTRA, 2001). A pesquisa caracteriza-se, ainda, como um estudo de caso, em que há a premissa de que um caso estudado em profundidade possa ser representativo para muitos outros (MARKONI; LAKATOS, 2003).

O método de trabalho a ser utilizado para atingir os objetivos propostos contempla as seguintes etapas:

- a) Revisão bibliográfica a respeito do tema armazenagem de grãos e estocagem de safras agrícolas;

- b) Realização de um diagnóstico da situação atual no estado do RS sobre a capacidade de armazenagem em relação à safra agrícola produzida;
- c) Realizar previsões de produção de grãos e capacidade de armazenagem, através do modelo ARIMA, segundo a metodologia de Box e Jenkins;
- d) Analisar os resultados do modelo, com vistas a prever se os programas de financiamento à armazenagem são bons negócios para a agência de fomento gaúcha; e
- e) Elaborar conclusões quanto à aplicação prática e quanto ao trabalho como um todo, gerando possíveis contribuições e sugestões para futuras pesquisas.

1.4 ESTRUTURA DA DISSERTAÇÃO

O trabalho está dividido em cinco capítulos. O primeiro capítulo introduz o tema, os objetivos, as justificativas e a metodologia aplicada nesta dissertação.

No segundo capítulo é apresentada uma revisão bibliográfica geral sobre as previsões de demanda, através da análise de trabalhos relevantes sobre o tema. Além disso, serão apresentados casos práticos de aplicações destas técnicas preditivas e como elas são utilizadas nas instituições públicas e privadas.

O terceiro capítulo apresentará o método utilizado, relacionando-o com a revisão bibliográfica do capítulo anterior. A partir dessa análise, consolida-se o modelo a ser utilizado e implementado no caso prático.

O quarto capítulo mostrará a evolução da estrutura de armazenagem de grãos no RS. Será proposto um modelo de previsão de quantidade de estocagem de grãos e um modelo de previsão de safra de grãos para os próximos 5 anos-safra. Dessa forma, deseja-se inferir a eficácia da política pública do programa de financiamento à armazenagem do BNDES – PCA Armazéns e sua efetividade enquanto política governamental de fomento ao setor primário.

Por fim, serão apresentadas as considerações finais, no capítulo 5, com base no que foi visto nos capítulos precedentes.

1.5 DELIMITAÇÕES DO ESTUDO

Este trabalho limita-se a desenvolver um modelo de previsão de demanda de armazenagem de grãos e de safra de grãos no RS. Os dados analisados compreendem o período de 1980 a 2019. Na pesquisa, o estudo é limitado aos trabalhos acadêmicos previamente publicados, que são em sua maioria aplicados a outros países e a outras regiões do Brasil.

No que tange aos dados, foram utilizados dados de fontes secundárias, contemplando somente os levantamentos feitos pela Companhia Nacional de Abastecimento sobre safras e pelo Banco Nacional de Desenvolvimento Econômico e Social e Badesul Desenvolvimento, sobre financiamentos.

Há peculiaridades de solo e logística de escoamento que alteram o ponto de ótimo de produção agrícola e que não serão abordados no estudo quantitativo, devido a impossibilidade de completude de informações. Por fim, este trabalho não tem a ambição de prever as vendas de todos os equipamentos de armazenagem e todos os tipos de grãos, mas de gerar informações que permitam avaliar a viabilidade da agência de fomento do estado do RS seguir operando sua linha de crédito PCA - Armazéns.

2 REFERENCIAL TEÓRICO

Este capítulo apresenta uma revisão da literatura acerca de conceitos e estudos sobre armazenagem de grãos, demanda, previsões de demanda e análise de séries temporais. Os tópicos aqui abordados e referenciados cientificamente são necessários para o correto desenvolvimento desse estudo.

2.1 ARMAZENAGEM DE GRÃOS

A armazenagem, segundo Elias (2003), é o processo de guardar o produto agrícola, associada a uma sequência de operações, tais como limpeza, secagem, tratamento fitossanitário, transporte e classificação, com o intuito de preservar as qualidades físicas e químicas da colheita, até o abastecimento. Após essas operações, os grãos devem obter uma série de qualidades desejáveis como baixo teor de umidade, alto peso específico, baixa degradação de componentes nutritivos, baixa susceptibilidade à quebra, baixa porcentagem de grãos danificados, alta viabilidade de sementes e ausência de pragas, fungos ou bactérias (ELIAS, 2003).

O armazenamento constitui uma rede indispensável no setor primário, já que é responsável por receber a produção, conservá-la em condições físicas, químicas e biológicas ideais para, então, redistribuí-la posteriormente ao consumidor. A produção de grãos é periódica; já a necessidade de alimentação e a demanda das agroindústrias são ininterruptas (PUZZI, 2000).

Segundo Elias (2003), a rede de armazéns é composta por unidades armazenadoras que possuem estrutura adequada às suas finalidades específicas e devem ser localizadas e dimensionadas de acordo com as características de operação, estabelecendo um fluxo lógico, tal qual sugere a logística, de atendimento ao escoamento da safra, com preservação da qualidade dos grãos, até que esses produtos cheguem ao consumidor final, controlando perdas e estocando o excedente que não foi comercializado.

Tendo em vista tais especificidades do setor primário, evidencia-se a indispensável necessidade da armazenagem para o mercado de grãos, pois ao cumprir os requisitos de qualidade, o valor do produto será majorado, aumentando lucro e receita da atividade. No mercado mundial, o Brasil tem vantagens comparativas na produção de soja em relação aos outros produtores, contudo perde em aspectos logísticos (PONTES *et al.*, 2009).

O armazenamento junto à plantação constitui prática de suma importância, tanto para o complemento da estrutura armazenadora urbana, quanto para minimizar perdas quantitativas e qualitativas a que estão sujeitos os produtos colhidos. Sabe-se que, no Brasil, dependendo da região, as perdas podem atingir 20% ou mais e são ocasionadas pelo ataque de pragas, devido à inadequação de instalações e à falta de conhecimentos técnicos adequados (WEBER, 2005). De acordo com Beskow e Dacker (2002), o armazenamento diretamente na fazenda, no Brasil, ainda é inexpressivo, diferentemente de países desenvolvidos, como é o caso do Canadá, em que o armazenamento próximo ao local de plantio alcança cerca de 80% da safra.

Conforme pesquisas antigas de Jenike e Johanson (1868), adaptadas por Gomes (2000), os primeiros grandes silos foram construídos em 1860 para o armazenamento de grãos. Desde então, milhares de grandes e pequenos silos foram instalados. Para Puzzi (2000), a implantação do manuseio e armazenamento de grãos a granel constitui uma tendência universal, sendo nos países desenvolvidos sua manipulação integrada desde a colheita.

No Brasil, a expansão do uso da estrutura de armazenamento dos grãos muitas vezes é caracterizada por inadequações e improvisações, que podem comprometer o desenvolvimento correto do sistema no país. É necessário o conhecimento científico e tecnológico dessas estruturas para sua correta implantação, que deve ser mais frequente no Brasil, cuja produção agrícola ainda não possui total eficiência no processo de armazenagem (PATURCA, 2014).

Souza *et al.* (2010) estudaram o complexo da soja para o mercado mundial, no período compreendido entre 1972 e 2008. Realizaram projeções futuras, através da representação markoviana, visando a obter previsões para o

período 2009 a 2018, e concluíram que o mercado brasileiro de soja em grão indicava grandes perspectivas de crescimento e fortalecimento no mercado mundial.

Borges (2002) já havia constatado que a soja é uma das principais atividades econômicas do RS, especialmente no noroeste do estado. O autor verificou que as perdas do produto ocasionadas na atividade de armazenagem inadequada são significativas. Além disso, constatou que a soja movimentava outros ramos econômicos, tais como indústria de sementes e fertilizantes, indústrias de silo e de secagem de grãos e cadeia de transportes.

De acordo com a Empresa Brasileira de Pesquisas Agropecuárias (Embrapa, 2013), os dados de perdas de grãos, especificamente na fase de armazenamento, variam muito, dependendo sobretudo do nível tecnológico que o produtor utiliza. Em países considerados desenvolvidos, tais dados também oscilam, mas indicam perdas inferiores a 10%. Nos Estados Unidos, o índice é em torno de 5%. Já em países em desenvolvimento, as perdas podem chegar a 50% (ou seja, metade da produção) na fase do armazenamento. Na década de 1990, foi feito levantamento no Brasil que apontou perdas quantitativas de até 20% na produção de grãos.

O estudo de Lorini (2015) demonstra que atualmente as perdas de grãos na etapa de armazenagem estão em cerca de 10% da produção. Se esse índice ocorrer na atual safra de grãos, seriam cerca de 22 milhões de toneladas perdidas apenas no armazenamento. Para o RS, a Empresa de Assistência Técnica e Extensão Rural do RS (Emater - RS) estima que a safra 2019/2020 será de cerca de 33,2 milhões de toneladas; neste caso, se as perdas em armazenamento fossem estimadas nesse percentual, seriam cerca de 3,32 milhões de toneladas perdidas, somente na etapa de armazenagem.

De acordo com dados do censo agropecuário de 2017, do IBGE, existem, no RS, 365.052 estabelecimentos agropecuários, perfazendo uma área de 21,7 milhões de hectares. Em torno de 42% da área dos estabelecimentos agropecuários do RS são ocupadas por pastagens e 36% por lavouras permanentes e temporárias. Desse modo, são cerca de 7,8 milhões de hectares

destinados a lavouras, sendo que os grãos representam a maior parte das culturas agrícolas produzidas no estado. Esses números demonstram a importância da previsão de armazenagem para o RS.

2.2 O CONCEITO DE DEMANDA E SUA IMPORTÂNCIA

A demanda pode ser definida como o desejo por produtos específicos, acompanhado pela habilidade e disposição para comprá-los (KOTLER; ARMSTRONG, 1991). Sandhusen (1998) definiu demanda de mercado como o volume total comprado em uma região específica por um determinado grupo de clientes em uma época particular sob um programa de *marketing* característico. Nesse sentido, Werner (2004) definiu demanda como a quantidade de bens ou serviços que um consumidor está disposto a adquirir por determinado preço, em determinado tempo em certo local geográfico. Por fim, segundo Iunes *et al.* (1995), a demanda por um bem ou serviço pode ser definida como a quantidade do bem ou serviço que as pessoas desejam consumir em um determinado período de tempo, dadas as suas restrições orçamentárias.

Kotler (1998) afirma que poucos produtos são de fácil previsão, como os serviços de utilidade pública ou os oligopólios puros. Na maior parte dos mercados, porém, a demanda por bens de uma empresa não é estável e uma boa previsão da demanda é imprescindível para a obtenção de êxito nos negócios. Quanto mais instável for a demanda, maior a importância da precisão da previsão e, por conseguinte, mais elaborados serão os procedimentos para obtê-la (WERNER, 2005).

A demanda que uma empresa pode mensurar varia em nível de produto, espaço e tempo. Em relação à variação de produto, há diferenciação conforme item e linhas do produto; em espaço, define-se o potencial consumidor e a região de atuação; em relação ao tempo, divide-se em curto, médio e longo prazos. Johnson e King (1988) afirmam que se a demanda estimada é solicitada para dois ou três períodos de tempo no futuro, o seu horizonte é considerado de curto prazo, enquanto um horizonte entre 3 e 20 anos é considerado de médio prazo.

Já se a demanda é estimada para um prazo superior a 20 anos, os autores consideram como de longo prazo.

Troster e Mochón (1999) dizem que dentre os vários fatores que podem influenciar a demanda, os mais importantes são a renda dos consumidores, o preço dos bens relacionados e as preferências dos consumidores. No caso do estudo de *commodities* agrícolas, que são muito utilizadas para alimentação, há outros fatores impactantes, como crescimento populacional e do estoque de animais. Já para a demanda por silos e armazéns através de um financiamento, taxa de juros e prazo de carência e amortização são fatores muito relevantes.

Apenas quando há a comprovação da existência da demanda por determinado bem ou serviço, haverá o interesse econômico pela sua produção e o conseqüente interesse das organizações em investir em determinado segmento. No estado do RS, o agronegócio respondeu por 58,2% das exportações totais, sendo que somente a soja, principal grão produzido no estado representou 30,3% das exportações gaúchas, em 2018 (FEIX E LEUSIN JÚNIOR, 2019). Para o setor produtivo do estado, portanto, evidencia-se a importância do estudo da demanda.

2.3 PREVISÃO DE DEMANDA E SUAS TÉCNICAS

Martins e Laugeni (2005) definem a previsão de demanda como um processo metodológico para determinação de dados futuros baseado em modelos estatísticos, matemáticos e econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida. Segundo Pellegrini e Fogliatto (2000), previsões de demanda desempenham um papel fundamental em diversas áreas da gestão das organizações.

Os métodos de previsão de demanda podem ser quantitativos ou qualitativos. Os métodos qualitativos usam o julgamento e a experiência humana, enquanto os métodos quantitativos usam modelos estatísticos e matemáticos para prever a demanda futura (CALSSING, 2015).

Segundo Mentzer e Cox (1984), os métodos qualitativos apresentam baixo grau de precisão, porém continuam sendo os mais utilizados nas empresas e organizações por não requererem especialistas em métodos mais sofisticados. Para Pellegrini (2006), os métodos qualitativos são vulneráveis a tendências que podem comprometer a confiabilidade dos resultados, uma vez que diferentes indivíduos têm preferências distintas. Além disso, as pessoas têm uma capacidade limitada de processamento de informações.

Os métodos quantitativos, por sua vez, ao utilizarem dados históricos para prever a demanda em períodos futuros, são mais confiáveis (PELLEGRINI, 2006). Padrões consistentes, que são os componentes estruturados da previsão, parecem ser melhor capturados pelas técnicas quantitativas formais (SANDERS e RITZMAN, 1990).

Modelos econométricos (causais), que integram os métodos quantitativos, são ferramentas valiosas para aumentar o entendimento da forma como um sistema econômico trabalha e para testar e avaliar políticas alternativas. Já os modelos de séries temporais limitam-se a analisar o comportamento da variável preditora (MAKRIDAKIS, 1989).

A previsão de demanda para armazenagem de grãos tem sido um assunto de interesse de estudos há décadas, visto que *commodities* devem ser armazenadas na proporção do excedente de produção e para atender a demanda para a mercadoria até a próxima colheita. Working (1953) propôs uma sistemática, referida pela literatura como estratégia base, que define que se deve armazenar os grãos apenas quando os retornos futuros obtidos pela venda excedem o custo de armazenamento.

Desde o artigo seminal de Working, vários estudos investigaram a estratégia base. Heifner (1966), Zulauf e Irwin (1998) e Siaplay *et al.* (2012) verificaram essa estratégia com a utilização de análises univariadas, através das quais examinam se os retornos líquidos reais do armazenamento podem ser explicados pelos retornos líquidos esperados previstos pela estratégia base.

Assad *et al.* (2007) previram a safra de soja no Brasil baseados em modelos empíricos regionalizados usando dados da Conab e do IBGE. A análise

comparativa indicou não haver diferença estatisticamente significativa entre as estimativas e os dados oficiais. Bons ajustes ($R^2 \geq 0,87$) foram obtidos para as produções regionalizadas; o RS, porém, foi um dos estados com desvios mais expressivos.

Bacci (2007) utilizou uma combinação de séries temporais para previsão da demanda de café no Brasil. O autor analisou dados de 1975 a 2005 e concluiu que a combinação dos modelos ARIMA, Suavização Exponencial Dupla e Análise Quadrática de Tendência (que utiliza o método dos mínimos quadráticos) apresentou o melhor resultado, uma vez que os erros foram inferiores a 4% para os anos validados pelo modelo de previsão (2006 e 2007).

Hamjah (2014) usou modelos ARIMA para prever a produção de arroz no Bangladesh e constatou que o modelo ARIMA é estatisticamente bem-comportado e fornece boa previsão para curto prazo com os dados logaritimizadas. Arthus *et al.* (2016) realizaram previsões de demanda para o rendimento da soja no oeste do Paraná usando modelos ARIMA e da suavização exponencial de Holt e concluíram que o modelo de Holt é uma alternativa eficaz, prática e economicamente viável para produtores de soja e cooperativas do oeste paranaense preverem rendimento da soja na região.

2.4 ANÁLISE DE SÉRIES TEMPORAIS

Uma série temporal é um conjunto de observações coletadas de forma sequencial, ao longo do tempo. A dependência entre as observações é o que caracteriza as aplicações das técnicas de séries temporais, já que as metodologias estatísticas clássicas, para serem aplicadas, exigem independência dos dados (MORETTIN, 2017).

Vale ressaltar que, além do tempo, uma série pode ser função de outra variável, como, por exemplo, espaço ou profundidade. A análise de uma série temporal pode ser feita no domínio do tempo ou no domínio da frequência, sendo os modelos propostos, respectivamente, paramétricos e não-paramétricos (EHLERS, 2007).

O objetivo da análise de séries temporais é a construção de modelos com propósitos determinados, tais como investigar o mecanismo gerador da série temporal, fazer previsões de valores futuros, descrever o comportamento da série e identificar periodicidades relevantes nos dados (MORETTIN; TOLOI, 2006).

Segundo Morettin e Toloí (2006), os modelos utilizados para descrever séries temporais são estocásticos. Um processo estocástico é definido como sendo uma coleção de variáveis aleatórias sequenciadas no tempo e definidas em um conjunto de pontos T , que pode ser contínuo ou discreto. A variável aleatória no tempo t é designada por Z_t , em que $t = 0, 1, \dots, T$.

Uma das suposições mais frequentes na análise de uma série temporal é a de que ela seja estacionária, ou seja, ela se desenvolve no tempo de forma aleatória em torno de uma média constante, repetindo alguma forma de equilíbrio estável. Existem, tecnicamente, duas formas de estacionaridade: fraca (ou ampla, ou de segunda ordem) e estrita (ou forte). A estacionaridade forte é uma propriedade de difícil verificação. Assim, faz sentido definir um conceito de estacionaridade baseado nos momentos de uma série temporal, mais precisamente nos momentos de primeira e segunda ordens. Isso é dado pela estacionaridade fraca (MORETTIN; TOLOI, 2006).

Bressan (2004) aplicou modelos de previsão de séries temporais como ferramenta de decisão de compra e venda de contratos futuros de boi gordo, café e soja na Bolsa de Mercadorias e Futuro (BM&F), em datas próximas ao vencimento. Os modelos estudados foram ARIMA, Redes Neurais Artificiais e Modelos Lineares Dinâmicos. Os dados compreenderam o período entre 1996 e 1999. O objetivo do estudo foi calcular os retornos médios dos modelos em operações no mercado futuro, de modo a indicar o potencial ou limitação dos modelos. Os resultados das previsões obtidos pelos diferentes métodos são divergentes.

Pinto *et al.* (2008) utilizaram uma previsão para os preços das *commodities* cacau, café, cana de açúcar, laranja e soja a partir da metodologia ARIMA. Os autores se propuseram a analisar o comportamento dos preços

recebidos pelo produtor das principais *commodities* agrícolas brasileiras e obtiveram uma previsão bem ajustada através da metodologia aplicada. Salientaram que as previsões são de extrema importância para que os produtores e investidores formem suas expectativas sobre o comportamento dos preços futuros das *commodities*.

Felipe (2012) realizou um estudo aplicando modelos ARIMA com o objetivo de analisar a série diária de preços da soja do Norte do Paraná. O período estudado compreendeu os anos de 2000 (a partir de janeiro) a 2011 (até outubro). O autor encontrou um modelo com boa capacidade preditiva.

Tibulo e Carlo (2014) utilizaram séries temporais para realizar uma análise do preço médio mensal do milho no RS. O trabalho abordou uma comparação entre os modelos ARIMA e de Suavização Exponencial de Holt-Winters, no período de março de 2004 a fevereiro de 2014, aplicados a série histórica do preço médio mensal do milho no RS.

3. MÉTODO

Este capítulo se divide em três seções. Na primeira, apresenta-se a base de dados utilizada no estudo de caso. A segunda seção está destinada a apresentar os métodos de previsão selecionados para o estudo. Na terceira seção serão demonstrados os detalhamentos dos modelos de previsão a serem utilizados.

3.1 BASE DE DADOS

Esse estudo desenvolverá dois modelos de previsão: um para capacidade estática de armazenagem de grãos no RS e outro para a safra de grãos do estado. A base de dados utilizada nesse trabalho é composta por séries históricas de safras de grãos e capacidades de armazenagem, relativas ao estado do RS, para o período de 1980 a 2019. Os dados de safra de grãos foram extraídos da Conab¹, enquanto a capacidade de armazenagem foi verificada segundo os dados cadastrados no Sistema Nacional de Unidades Armazenadoras (SICARM²), também mantido pela Conab.

Para o levantamento da base de dados sobre safra de grãos, a Conab realiza o acompanhamento constante das safras, monitorando as condições de desenvolvimento das principais culturas do país, abrangendo os seguintes produtos agrícolas: algodão, amendoim, arroz, aveia, canola, centeio, cevada, feijão, girassol, mamona, milho, soja, sorgo, trigo e tritcale (CONAB, 2019). Conforme a Tabela 1, soja, arroz, trigo e milho são os principais grãos produzidos no estado do RS. Somados, alcançaram a marca de aproximadamente 32,79 milhões de toneladas em 2018, respondendo por cerca de 92% da produção gaúcha de grãos.

¹ Os dados utilizados foram obtidos através da base de dados da Conab disponível através do sítio eletrônico: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras> .

² Os dados de capacidade estática de armazenamento foram obtidos através da base de dados do SICARM disponível através do sítio eletrônico: <https://www.conab.gov.br/armazenagem/serie-historica-da-armazenagem> .

Tabela 1– Produção de grãos no RS na safra 2018/2019

Cultura	Produção na Safra 2018/2019 (milhares de toneladas)	Representatividade do grão sobre o total da produção agrícola
Soja	17.538,60	49,21%
Arroz	8.401,80	23,57%
Milho	4.565,60	12,81%
Trigo	2.281,20	6,40%
Outros Grãos	2.853,10	8,01%
Total	35.640,30	100%

Fonte: IBGE (2019).

A partir do levantamento da produção agrícola a Conab disponibiliza, mensalmente, o Boletim de Acompanhamento da Safra Brasileira de Grãos e o Boletim de Monitoramento Agrícola, que fornecem informações e conhecimentos relevantes aos agentes envolvidos nos desafios da agricultura, da segurança alimentar e nutricional e do abastecimento do país. As publicações referidas auxiliam a compreender os resultados da safra e têm como objetivo produzir subsídios para o monitoramento e a formulação das políticas agrícola e de abastecimento. Suas informações também auxiliam a tomada de decisão dos produtores rurais.

O SICARM cadastra, acompanha e credencia todas as unidades armazenadoras do país, amparado pelas Leis 8.171/1991 e 9.973/2000, que estabelecem o cadastro obrigatório de todas as unidades armazenadoras de produtos agrícolas do Brasil, tanto para pessoas físicas quanto para pessoas jurídicas. A origem dos dados parte do levantamento sistemático de todas as unidades armazenadoras quanto à localização, às características operacionais e à capacidade de armazenagem.

3.1.1 Obtenção dos Dados

A escolha de um método de previsão envolve a obtenção das variáveis dependente e independentes (preditoras), a fim de solucionar o problema formulado. O processo de obtenção das variáveis engloba: (i) discriminação dos níveis de previsão; (ii) definição dos fatores temporais; (iii) priorização dos itens a serem previstos; (iv) análise do ciclo de vida dos itens a serem previstos; (v) definição dos dados de entrada e saída; e (vi) coleta e preparação de dados. Os dados para essa dissertação foram obtidos no Mapa e na Conab, de maneira regionalizada, para o estado do RS, tendo em vista que o Badesul Desenvolvimento possui atuação regional. O período analisado foi desde 1980 até 2019, com frequência anual.

3.2 MÉTODO DE ESTIMAÇÃO

Os modelos utilizados serão a suavização exponencial biparamétrica de Holt e o ARIMA, que segue a metodologia de Box e Jenkins. A suavização exponencial biparamétrica de Holt é um modelo que se baseia no fato de que as observações passadas contêm informações sobre o padrão da série temporal. O modelo proposto por Holt consiste em uma dupla suavização com constantes diferentes, sendo uma para ponderar o componente de nível da série e outra para a tendência.

De acordo com Mueller (1996), o modelo de George Box e Gwilyn Jenkins, conhecido como Box-Jenkins, possui capacidade de manipular, a princípio, séries temporais de qualquer natureza, razão pela qual foi utilizada para previsão das séries temporais deste estudo. A metodologia consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA (p, d, q), a um conjunto de dados. Tais modelos se caracterizam, ainda, por serem simples e parcimoniosos; as previsões costumam resultar precisas, comparando-se favoravelmente aos demais modelos de previsão. O modelo ARIMA permite capturar a existência de sazonalidade em séries de dados, o que não se aplicaria a este trabalho, que trata com dados anuais. Entretanto, devido à extensão do período coberto, a série de dados pode apresentar ciclos, que poderiam ser

capturados pelo modelo, o que torna sua utilização adequada. A seguir serão apresentados detalhadamente os dois modelos que serão aplicados: Suavização Exponencial Biparamétrica de Holt e ARIMA.

3.2.1 Suavização Exponencial Biparamétrica de Holt

O modelo da suavização exponencial biparamétrica de Holt também é conhecido como suavização exponencial dupla. É usado para dados que apresentam tendência linear sem apresentar sazonalidade e emprega duas constantes α e β , com valores entre 0 e 1 (e independentes), sendo representado pelas seguintes equações (MAKRIDAKIS *ET AL.*,1998 MORETTIN E TOLOI, 2006; LEMOS, 2006):

$$L_t = \alpha Z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3.1)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3.2)$$

$$\hat{P}_{t+h} = L_t + T_t h \quad (3.3)$$

onde:

h = horizonte de tempo para o qual se deseja a previsão;

L_t = estimativa do nível da série no tempo t ;

T_t = estimativa da tendência da série no tempo t ;

α = constante de suavização de nível;

β = constante de suavização de tendência ;

\hat{P}_{t+h} = previsão da série para o tempo $t + h$.

Os valores iniciais dos parâmetros podem ser estimados pelas seguintes equações:

$$L_1 = y_1 \quad (3.4)$$

$$T_1 = y_2 - y_1 \quad (3.5)$$

O modelo faz previsões a partir de série temporal não-sazonal com tendência linear, constituída localmente pela soma de nível, tendência e resíduo

aleatório, com média zero e variância constante. Além disso, estima o nível e a tendência da série aplicando constantes de suavização para o nível e para a tendência.

3.2.2 Metodologia Box-Jenkins

O modelo Box-Jenkins (BJ) utiliza um algoritmo matemático com termos auto regressivos e de média móvel, para identificar a forma de um modelo matemático para séries temporais com N observações (ARCHER, 1980). De acordo com Pellegrini (2000), o modelo permite, através de análises estatísticas, determinar o modelo mais apropriado para cada situação, modelando uma função de autocorrelação de uma série temporal com o mínimo de parâmetros necessários. O modelo utiliza uma combinação de termos de auto regressão (AR), integração (I) e média móvel (MA), que resulta no modelo designado por ARIMA.

O modelo de Box-Jenkins é constituído basicamente de três fases (KURRLE, 2004): identificação do Modelo ARIMA que melhor se ajusta aos dados históricos, estimativa dos parâmetros do modelo identificado e verificação da adequação do modelo para fins de previsão.

Box *et al.* (1994) afirmam que o modelo BJ captura as correlações históricas entre os dados e extrapola essas correlações para o futuro. Caso existam correlações fortes, homogêneas e estáveis nos dados analisados, as previsões resultam precisas; no entanto, com correlações que mudam ao decorrer do tempo, o modelo perde a acurácia. Segundo os mesmos autores, a aplicação do modelo depende da série ser estacionária ou não.

No caso de série não-estacionária, é necessário primeiro estabilizá-la através da diferenciação. Para a determinação da estacionariedade, analisam-se gráfica e analiticamente os coeficientes de autocorrelação (FAP) e de autocorrelação parcial (FACP).

O coeficiente de autocorrelação da série temporal é determinado pela equação (3.6):

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - Y_m)(Y_{t-k} - Y_m)}{\sum_{t=1}^n (Y_t - Y_m)^2} \quad (3.6)$$

onde r_k é o coeficiente de correlação da observação Y_t com a observação Y_{t-k} , k é a ordem do coeficiente da correlação, Y_t é a demanda observada no período t e Y_m é a média das observações da série temporal.

A notação do modelo geral é ARIMA (p, d, q) (P, D, Q) [S]. Walker e McClelland (1991) e Businger e Read (1999) assim definiram as partes do modelo ARIMA:

- AR – parcela auto-regressiva que modela a dependência de um valor atual sobre valores passados;
- I – parcela de integração que remove a tendência da série temporal, tornando a série estacionária;
- MA – parcela de média móvel, a qual assume que valores atuais são dependentes de erros de previsão de períodos passados;
- p – ordem máxima dos parâmetros de auto-regressão simples;
- d – número de diferenciações não-sazonais aplicadas para tornar a série temporal estacionária;
- q – ordem máxima dos parâmetros de média móvel simples;
- P – ordem máxima dos parâmetros de auto-regressão sazonal;
- D – número de diferenciações sazonais aplicadas para tornar a série temporal estacionária;
- Q – ordem máxima dos parâmetros de média móvel sazonal;
- S – número de períodos por ciclo sazonal.

3.3 IDENTIFICAÇÃO DO MODELO

De acordo com Pellegrini (2000), a identificação de um modelo ARIMA é feita através da análise dos dados que compõem a série temporal. As principais

ferramentas usadas para identificação são a função de autocorrelação (FAP) e a função de autocorrelação parcial (FACP). Para Velasco (2008), a primeira ação para identificar um modelo é montar um gráfico, para identificar padrões ou situações não usuais; após, os gráficos de FAP e FACP são construídos.

Na fase de identificação, os dados são transformados para estabilizar a variância e diferenciados, se for caso, para obter uma série estacionária. De acordo com Fava (2000), se a série é estacionária, d assumirá o valor zero; se não for, a série terá de ser diferenciada até n vezes para que se torne estacionária tanto na média quanto na variância.

A FAP, de acordo com Makridakis *et al.* (1998), mensura o grau de associação entre Y_t e Y_{t-k} excluindo-se os efeitos de observações de outros períodos. Os coeficientes de autocorrelação parcial (a_k) são as estimativas dos coeficientes (b_k) do modelo de regressão da equação (3.7).

$$Y_t = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_k Y_{t-k} \quad (3.7)$$

Makridakis *et al.* (1998) explicam a correlação como uma medida da extensão do relacionamento linear entre duas variáveis. Como exemplo de utilização da correlação, pode ser citada a verificação de como um valor observado no período Y_t está relacionado com o valor observado no período anterior (Y_{t-1}). Neste caso, a observação Y_{t-1} é conhecida como uma observação defasada (*lagged*). De acordo com Volkan *et al.* (2007), o número máximo de *lags* é determinado dividindo o número de observações na amostra por 4. Ressalta-se que o modelo ARIMA é parcimonioso, o que implica que, em geral, $d = 0, 1$ ou 2 será suficiente para a identificação do modelo adequado (MORETTIN E TOLOI., 2006).

3.3.1 Estimativa dos Parâmetros do Modelo Identificado

Segundo Bacci (2007), após a definição da ordem de integração d , passa-se a trabalhar com a série estacionária Y_t quando $d = 0$ e W_t quando $d > 0$. Inicia-se, em seguida, a fase de identificação dos filtros AR e MA, ou seja, os

valores das ordens p e q do modelo ARIMA. Pellegrini (2006) afirma que, para os componentes MA, não existe uma fórmula simples para determinação das estimativas dos parâmetros.

Pindyck e Rubinfeld (2004) afirmam que para se identificar a ordem p e se construir modelos auto-regressivos, é importante observar o momento em que as autocorrelações parciais (FAP) deixam de ser próximas de zero ou estatisticamente não significativas. Para Fava (2000), se o modelo for MA (1), a FACP deverá estar truncada em $k = 1$, e depois decrescer exponencialmente com condição de invertibilidade no ponto onde o módulo de θ for menor que 1.

3.3.2 Modelos autorregressivos

De acordo com Cardoso e Cruz (2016), a aproximação de uma série temporal pelo modelo AR é realizada quando os valores futuros possuem uma relação linear com as componentes passadas da série temporal. Um modelo autorregressivo de ordem p , $AR(p)$, é escrito em função dos seus valores passados e do ruído branco conforme a equação (3.8),

$$AR(p): Z(t) = \varphi_0 + \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + \alpha_t, \quad (3.8)$$

onde $\varphi_0, \varphi_1 \dots \varphi_p$ são parâmetros a serem estimados a partir da amostra.

3.3.3 Modelo de Médias Móveis

O modelo de Médias Móveis (MA) vem do fato que Y_t é uma regressão, com os erros passados (e_{t-q}) apresentados na equação (3.7), ou em sua forma polinomial, na equação (3.8) (BOX; JEKINS; REINSELL, 1994; MORETTIN e TOLOI, 2006).

$$Y_t = c - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} + e_t \quad (3.9)$$

$$Y_t = \theta(B)e_t \quad (3.10)$$

onde θ_i é o coeficiente de média móvel no período i e o $\theta(B)$ é um polinômio de média móvel de ordem q .

3.3.4 Modelos Auto-Regressivos de Médias Móveis (ARMA)

De acordo com Morettin e Tolloi (2006), os modelos autorregressivos e de médias móveis são uma combinação dos modelos AR e MA. Denota-se por ARMA (p, q) um processo autorregressivo e de médias móveis de ordem (p, q) , que pode ser representado pela equação (3.11), com termos definidos em seções anteriores.

$$ARMA(p, q) = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q} \quad (3.11)$$

3.3.5 Modelo Autoregressivo Integrado de Médias Móveis (ARIMA)

O ARIMA é definido como um modelo em que a série temporal é submetida a um processo de diferenciação, cuja ordem é representada por d . Como apresentado anteriormente, o processo de diferenciação tem como objetivo remover as tendências e estabilizar a variância, antes da aplicação dos modelos anteriormente descritos. O modelo geral ARIMA é dado pela seguinte equação (Box, Jenkins e Reinsel, 1994):

$$\varphi(B)(1 - B)^d Y_t = \theta(B) e_t, \quad (3.12)$$

onde $\varphi(B)$ é um polinômio regressivo de ordem p , $\theta(B)$ é um polinômio de média móvel de ordem q e $(1 - B)^d Y_t$ são as sucessivas diferenciações.

3.4 MEDIDAS DE ACURÁCIA

Segundo Makridakis *et al.* (1998), fazer previsões é um processo que envolve incerteza. Assim, para a obtenção da previsão mais acertada, torna-se

necessário analisar uma gama variada de técnicas e verificar qual fornece a melhor medida de acurácia (MARTINS E WERNER, 2014).

De acordo com Lemos (2006), as medidas de acurácia traduzem numericamente a precisão de um determinado modelo. Nesse trabalho serão usadas duas medidas comparativas para selecionar o modelo que melhor se ajustará aos dados para previsão de demanda: o erro percentual absoluto médio (MAPE) e o Critério de Akaike (AIC).

3.4.1 Erro Percentual Absoluto Médio de Previsão (MAPE)

O MAPE é calculado utilizando as previsões um passo à frente obtidas pelo modelo cujo ajuste se deseja verificar (RUSSO *et al.*, 2002), conforme a equação (3.13).

$$MAPE (\%) = \frac{1}{n} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (3.13)$$

onde y_t designa o valor observado da série temporal no tempo t , \hat{y}_t designa o valor estimado pelo modelo e T é o número de observações da série temporal.

Em estudo empírico sobre medidas de acurácia, Armstrong e Collopy (1992) identificaram o MAPE como uma das medidas mais populares para verificar o ajuste de modelos de previsão a dados empíricos.

3.4.2 Critério de Informação de Akaike (AIC)

O critério de Akaike foi desenvolvido em 1973, com o objetivo de identificar a semelhança entre um modelo empírico e um modelo teórico ideal. De acordo com Floriano *et al.* (2006), o teste pode ser utilizado para comparar qualquer tipo de modelo: linear, não-linear, aninhado e não-aninhado. É uma medida relativa da qualidade de ajuste de um modelo estatístico estimado (EMILIANO, 2009), sendo descrito pela equação:

$$AIC = -2 \ln(L) + 2k \quad (3.14)$$

onde L é o modelo candidato e k é o número de parâmetros estimados.

Para escolher a equação do AIC a ser utilizada, deve-se seguir uma sequência de seis passos, conforme exposto por Motulsky e Christopoulos (2003):

- 1 - Ajustar as equações;
- 2 - Anotar a soma do quadrado dos erros de cada equação: no caso de fatores ponderados, usar a soma ponderada do quadrado dos erros;
- 3 - Determinar o número de observações (n): se foi usada uma variável de frequência, ela deve ser considerada como multiplicador, e o valor total de n deve ser aquele determinado pela soma das frequências de cada classe de valor;
- 4 - Determinar o valor de k para cada equação: nas equações não-lineares sem um intercepto, deve-se adicionar 1 ao valor do número de parâmetros da equação, já que a regressão não-linear estima o valor da soma de quadrados;
- 5 - Calcular o AIC;
- 6 – Selecionar o modelo com menor AIC como o mais adequado.

4 DESCRIÇÃO DO ESTUDO, RESULTADOS E DISCUSSÃO

Este capítulo reporta a aplicação da metodologia proposta para a previsão de safra de grãos agrícolas e capacidade de armazenamento estática para o horizonte de seis anos. As previsões elaboradas visam verificar se o estado do RS alcançará o índice de capacidade estática recomendada nos próximos anos, bem como a auxiliar o Badesul Desenvolvimento a adequar a carteira de negócios e verificar se o PCA Armazéns continuará a ser um bom negócio.

4.1 DEFINIÇÃO DO PROBLEMA

A definição do problema a ser resolvido é o primeiro passo no processo de escolha de um método de previsão de demanda. O propósito da previsão é fornecer informações para a tomada de decisão, como, por exemplo, para desenvolvimento de produtos, estratégias de marketing, planejamento de capacidade de produção, alocação de recursos e planejamento financeiro (LEMOS, 2006).

Assim, o propósito desse trabalho é verificar empiricamente a viabilidade e continuidade da linha de financiamento à armazenagem de grãos – PCA Armazéns – para a agência de fomento gaúcha, através da análise dos valores previstos de demanda para os níveis de produção de grãos no RS e crescimento da capacidade de estocagem. Deseja-se verificar se nos próximos seis anos o estado alcançará os níveis de armazenamento recomendados pela FAO. Conforme já mencionado na parte introdutória desse trabalho, o ideal é que a capacidade estática de armazenagem seja 1,2 vez a produção de grãos.

Tendo em vista o descompasso entre oferta e demanda de grãos, que gera um sistema de escoamento fortemente centrado em caminhões, o Governo Federal criou, em 2013, um programa de incentivo ao setor. O PCA Armazéns é um programa de financiamento do Banco Nacional de Desenvolvimento Econômico e Social, operado regionalmente pelo Badesul, com a finalidade de fomentar investimentos individuais ou coletivos, referentes exclusivamente a

projetos para ampliação, modernização, reforma e construção de armazéns destinados à guarda de safra agrícola.

Segundo Souza e Veríssimo (2013), a década de 2000 foi caracterizada por um desempenho expressivo das exportações brasileiras de *commodities*, fato que configurou um ambiente favorável a um processo de especialização no manejo e cultivo de grãos. Dessa forma, se a capacidade de armazenagem de grãos crescer no RS, a tendência é que melhore ainda mais o desempenho das exportações de *commodities*, uma vez que é possível armazenar grãos e negociar melhores preços de venda e organização da cadeia logística, sem a necessidade de escoar a produção imediatamente.

4.2 OBTENÇÃO DE DADOS

Os dados para essa dissertação foram obtidos no Mapa e na Conab, de maneira regionalizada, para o estado do RS, tendo em vista que o Badesul Desenvolvimento possui atuação regional. O intervalo analisado foi desde 1980 até 2019, em períodos anuais.

4.3 ESCOLHA DO MÉTODO DE PREVISÃO

Segundo Armstrong (2001), para a escolha de um método de previsão de demanda a preferência deve ser por métodos de previsão estruturados que possam ser sistematizados e replicados, privilegiando-se técnicas quantitativas, com poucas variáveis, pois ajudam no entendimento e reduzem erros e custos.

Alguns estudos apontam a acurácia como o critério mais importante na utilização de determinado método (CARBONE; ARMSTRONG, 1982; KAHN; MENTZER, 1995). Por isso, optou-se por utilizar os modelos de suavização exponencial biparamétrica de Holt e o modelo Box-Jenkins de estimação de séries temporais ARIMA neste estudo, conforme já descrito detalhadamente no Capítulo 3.

A escolha pelo modelo ARIMA é motivada pelo seu amplo espectro de aplicações nas diversas áreas, inclusive na agricultura, tornando-se, assim, um modelo aplicável ao contexto deste trabalho (HUBER; GOSSMANN; STUCKENSCHMIDT, 2017). Já a escolha da suavização exponencial de Holt foi motivada pela aplicabilidade do modelo para séries temporais que apresentam tendência e não possuem sazonalidade. A suavização exponencial biparamétrica de Holt costuma, de acordo com Makridakis *et al.* (1998), apresentar baixo custo para implantação e razoável precisão. Armstrong (2001) verificou que modelos simples, como é caso do método da suavização exponencial de Holt, devem ser priorizados em relação a modelos complexos. O software utilizado para modelagem dos dados foi o *R Project for Statistical Computing* com o apoio do pacote *forecast* (R CORE TEAM, 2015).

4.4 ESTUDO DE CASO

O estudo de caso para a aplicação dos modelos propostos utilizará técnicas estatísticas de séries temporais. De acordo com Armstrong (2001), ao se utilizar as técnicas estatísticas de séries temporais para se obter previsões, faz-se uma extrapolação, a qual é baseada na premissa de que os padrões da série continuarão a se comportar como no passado. Essa suposição é mais apropriada para previsões de curto prazo.

Nesse sentido, Slack *et al.* (2009) afirmam que a análise de séries temporais é geralmente utilizada para cenários de curto prazo, tal que a ocorrência de alterações no ambiente externo não afete a precisão da previsão. Dessa forma, o horizonte de previsão definido para esse trabalho foi de seis períodos subsequentes, tendo em vista que qualquer método de previsão se torna menos confiável para muitos períodos posteriores.

Alves *et al.* (2008) destacam que no campo da política agrícola há 3 fatores que impulsionam o crescimento: crédito subsidiado, avanço da ciência e tecnologia e extensão rural pública e privada. Segundo os mesmos autores, o crescimento é, portanto, lento ao longo do horizonte de muitas décadas. Tendo em vista esse argumento, o presente trabalho considerou o horizonte de seis

anos-safra como um horizonte curto na área de agricultura. A tabela de dados utilizada no trabalho está disponível no Apêndice.

4.4.1 Produção de Safra dos Grãos

As Figuras 1(a) e 1(c) apresentam a série temporal para o período entre 1980/81 a 2018/19, totalizando 39 observações para produção da safra de grãos no Estado do RS. No período analisado, a série possui ponto de máximo em 2018/19, com produção de 35,6 milhões de toneladas e ponto de mínimo na safra de 1990/91, com 10,1 milhões de toneladas. A função de autocorrelação (FAC) da série está apresentada nas Figuras 1(b) e 1(d). Pela análise do correlograma, observa-se que a série não decai rapidamente para zero, indicando a sua não-estacionariedade.

Os correlogramas também evidenciam, através da análise gráfica, autocorrelações com decréscimo exponencial lento, o que sinaliza a presença de tendência nas séries. Embora as safras tenham alguns períodos de quedas, o que é esperado, dado que a natureza da atividade é afetada pelos fatores climáticos, a tendência geral é de crescimento.

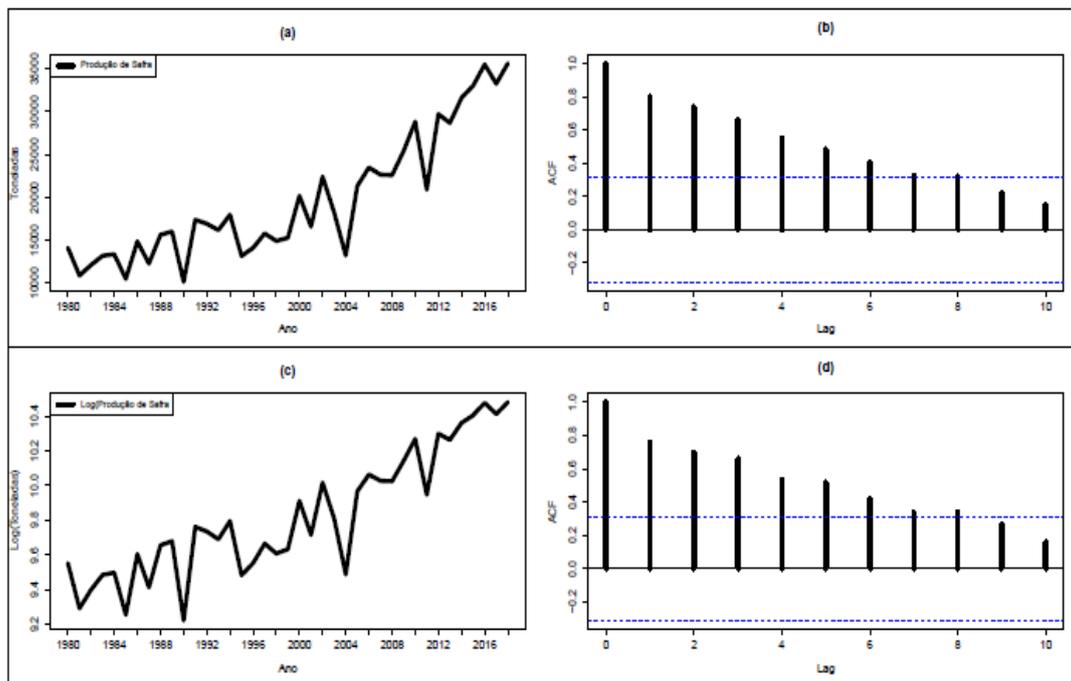


Figura 1 - (a) Representação gráfica da série original da produção da safra de grãos no RS no período de 1980/81 a 2018/19 (b) Função de Autocorrelação (ACF) da série original (c) Representação gráfica do logaritmo da série original (d) Função de Autocorrelação (FAC) do logaritmo da série original

Fonte: Elaborado pelo autor (2020)

De acordo com Lúcio *et al.* (2010), a análise estatística de séries temporais adota transformações para corrigir problemas devidos à variabilidade dos dados. Dessa forma, a série original foi logaritmizada. Como a maioria dos procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias, é necessário a adoção de transformações, principalmente para retificar problemas decorrentes da variabilidade dos dados, ou seja, estabilizar a variância e melhorar as estimativas dos parâmetros do modelo.

Haja vista a não-estacionariedade das séries, o procedimento adotado foi de aplicar diferenciações na série logaritmizada visando à estacionariedade. Por meio de uma única diferenciação, obteve-se um comportamento estacionário, conforme evidenciado pela Figura 2(a).

Como essa série temporal possui uma amostra com 39 observações, os limites que delimitam a significância de FAC e FACP são iguais a $\frac{1,96}{\sqrt{39}} = 0,314$. (Makridakis *et al.*, 1998).

Após a primeira diferenciação é possível observar que as funções de autocorrelação (FAC) da Figura 2 (b) e de Autocorrelação Parcial (FACP) da Figura 2(c) posicionam-se dentro dos limites recomendados, ou seja, dentro dos limites que delimitam a significância de FAC e FACP após o segundo *lag*.

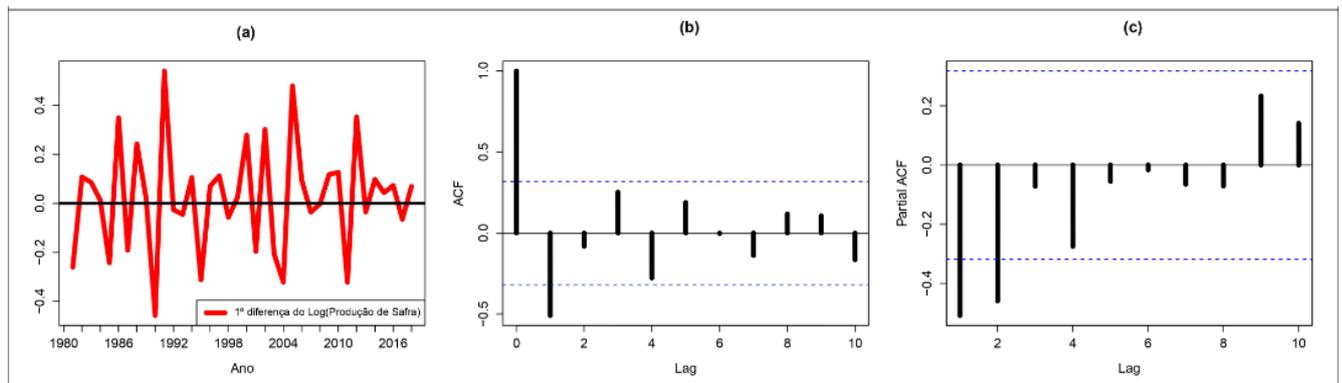


Figura 2 - (a) Representação gráfica da primeira diferença da série do logaritmo série original (b) Função de Autocorrelação (FAC) do logaritmo da série original (c) Função de Autocorrelação Parcial (FACP) do logaritmo da série original

Fonte: Elaborado pelo autor (2020)

Uma vez diferenciadas as séries, inicia-se o processo de modelagem dos dados. A primeira série analisada foi a de produção de safra de grãos.

Para a modelagem através do modelo biparamétrico de Holt, utilizou-se como valor inicial de L_1 o valor inicial da série e como T_1 a diferença entre os dois primeiros valores da série, conforme equações (3.4) e (3.5). Utilizando-se as equações (3.1) a (3.3) chega-se às expressões (4.1) a (4.3), que descrevem o modelo para previsão de h passos à frente.

$$L_t = 0,0397Z_t + (1 - 0,0397)(L_{t-1} + T_{t-1}) \quad (4.1)$$

$$T_t = 0,0397(L_t - L_{t-1}) + (1 - 0,0397)T_{t-1} \quad (4.2)$$

$$\hat{P}_{t+h} = L_t + hT_t \quad (4.3)$$

A Tabela 2 traz o comparativo de acurácia entre o modelo ARIMA e o modelo de suavização exponencial de Holt e seus parâmetros. Como regra principal de decisão para optar pelo melhor modelo, utilizou-se o Critério de Informação de Akaike (AIC), que direciona a escolha a modelos parcimoniosos. Dessa forma, foi escolhida a série com o menor valor de AIC.

Como critério complementar, utilizou-se o erro percentual absoluto médio de Previsão (MAPE). Assim como no AIC, valores de MAPE próximos a zero evidenciam um bom ajuste do modelo à série. Levando em conta os critérios acima, o modelo que melhor se ajustou à série foi o Modelo 2 (M_2): ARIMA (2,1,1).

Tabela 2 - Seleção dos modelos para produção de safra

Série	Modelo	Parâmetros	AIC	MAPE
Log(Produção de Safra)	M ₁ HOLT (α , β)	$\alpha = 0,0397$, $\beta = 0,0397$	7,34	1,34
Log(Produção de Safra)	M ₂ ARIMA (2,1,1)	-	6,18	1,22

Fonte: Elaborada pelo autor (2020)

A Figura 3 permite verificar a tendência crescente da produção de grãos no estado do RS, no entanto, em alguns anos a tendência observada não é linear. Nas safras dos anos 1981/82, 1985/86, 1987/88, 1990/91, 1993/94, 2001/02, 2003/04, 2004/05, 2011/12 e 2017/18 observaram-se quedas em relação ao ano-safra anterior, que são explicadas pelas relações entre chuva e sol inadequadas para os grãos, que preferem maior quantidade de chuva em período de plantio e germinação e de sol em período de colheita.

A tendência crescente das safras é explicada pelo aumento da área cultivada. De acordo com dados do IBGE, em 2009 a área plantada era de cerca de 7,9 milhões de hectares e, em 2018, foi de 8,9 milhões de hectares. Para a safra 2024/2025 está previsto um volume de aproximadamente 42 milhões de toneladas, que corresponde a um aumento de cerca de 18% em relação à última safra concluída até a elaboração desse trabalho (2018/2019).

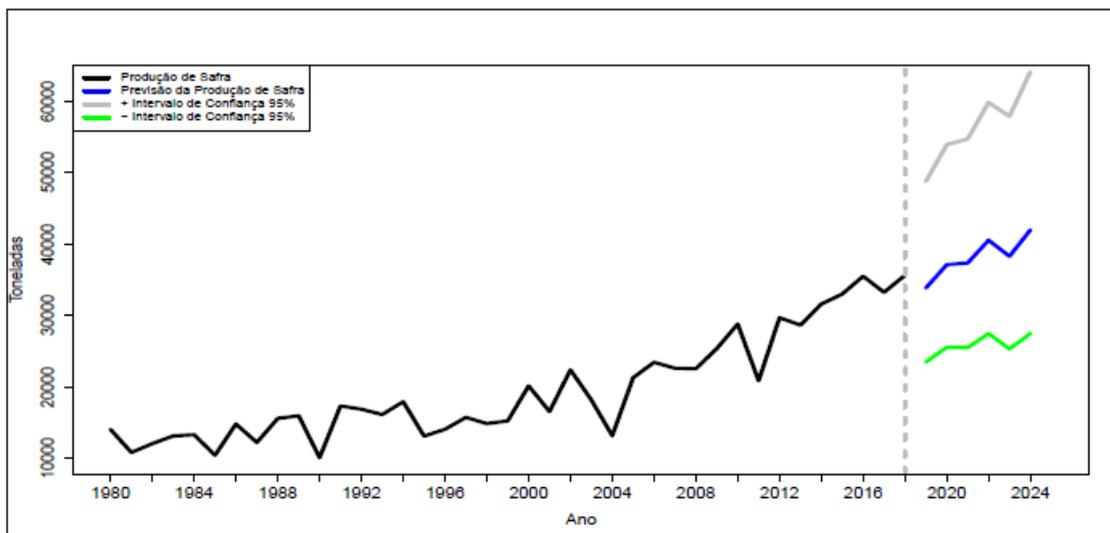


Figura 3 - Previsão da produção de safra de grãos para os próximos seis anos-safra no estado do RS

Fonte: Elaborado pelo autor (2020)

4.4.2 Capacidade Estática de Armazenamento dos Grãos

As Figuras 4(a) e 4(c) apresentam as séries temporais (original e logaritmizada) para o período entre 1980 e 2018, totalizando 39 observações para capacidade estática de armazenamento de grãos no estado do RS. No período analisado a série possui ponto de máximo em 2018, com capacidade de armazenamento de 29,57 milhões de toneladas e ponto de mínimo no ano de 1980, com 10,13 milhões de toneladas. As funções de autocorrelação (FAC) das séries estão apresentadas nas Figuras 4(b) e 4(d). Além disso, pode-se observar que as autocorrelações têm um decréscimo exponencial lento, indicando a presença de tendência nas séries.

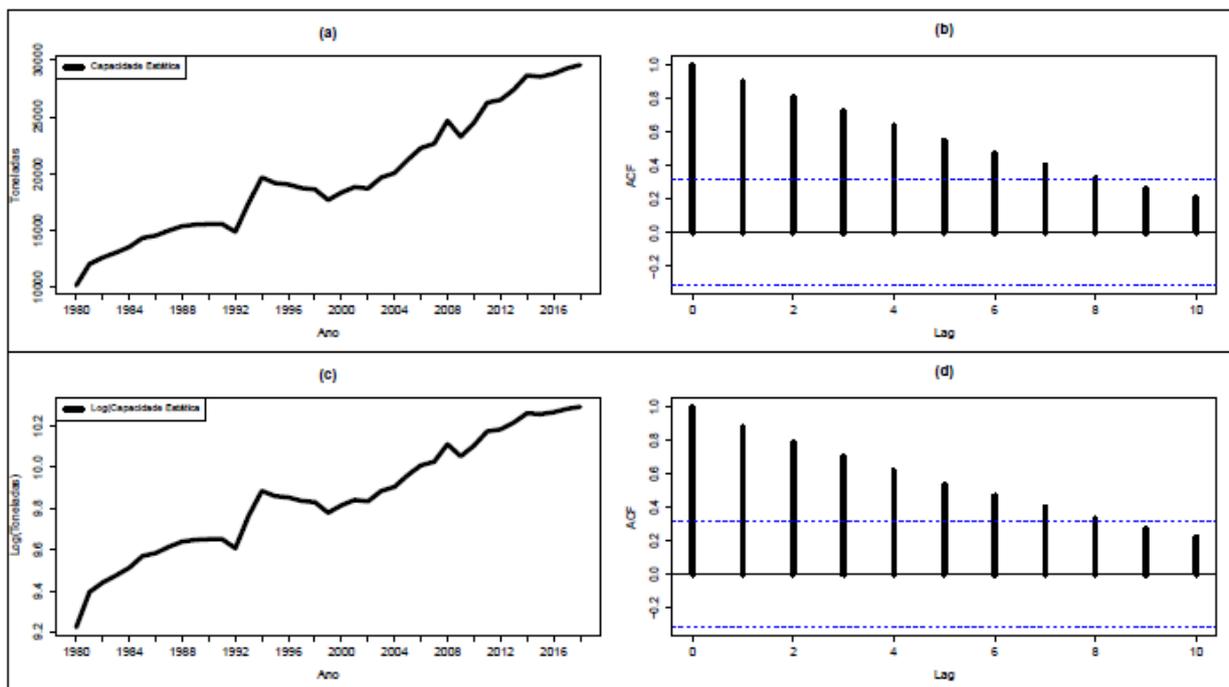


Figura 4 - (a) Representação gráfica da série original da capacidade estática de armazenamento de grãos no RS no período de 1980/81 a 2018/19. (b) Função de Autocorrelação (ACF) da série original. (c) Representação gráfica do logaritmo série original. (d) Função de Autocorrelação (FAC) do logaritmo da série original.

Fonte: Elaborado pelo autor (2020).

Haja vista a não-estacionariedade das séries, foram aplicadas diferenciações na série logaritmizada, até a obtenção da estacionariedade. Por meio da segunda diferença, é possível observar que a série logaritmizada diferenciada [Figura 5 (a)] apresentou comportamento estacionário, não sendo necessárias mais diferenciações. As funções de autocorrelação (FAC), representada na Figura 6(b), e autocorrelação Parcial (FACP), na Figura 6(c), encontraram-se dentro dos limites que delimitam a significância para FAC e FACP após o segundo *lag*.

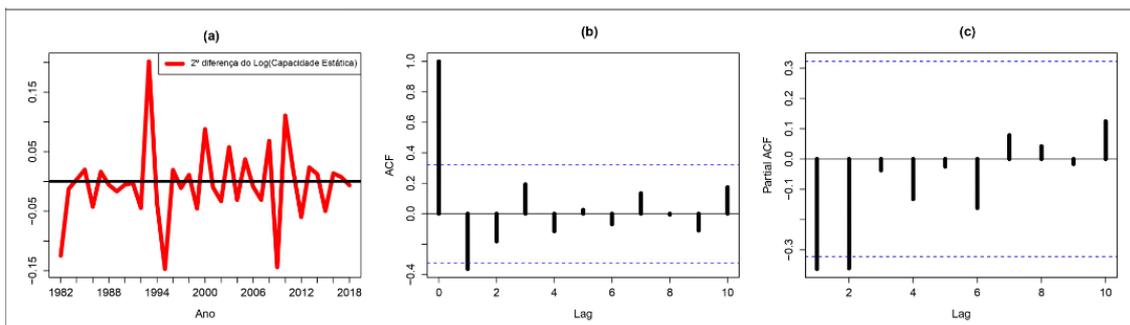


Figura 5 - (a) Representação gráfica da segunda diferença da série do logaritmo da série original. (b) Função de Autocorrelação (FAC) do logaritmo da série original. (c) Função de Autocorrelação Parcial (FACP) do logaritmo da série original

Fonte: Elaborado pelo autor (2020)

Para a modelagem através do modelo biparamétrico de Holt, utilizou-se como valor inicial de L_1 o valor inicial da série e como T_1 a diferença entre os dois primeiros valores da série. Utilizando-se as equações (3.1) a (3.3) encontram-se as equações (4.4) a (4.6), que descrevem o modelo para previsão da capacidade estática h passos à frente.

$$L_t = 0,9976 x Z_t + (1 - 0,9976)(L_{t-1} + T_{t-1}) \quad (4.4)$$

$$T_t = 1e - 04((L_t L_{t-1}) + (1 - (1e - 04))T_{t-1}) \quad (4.5)$$

$$\hat{P}_{t+h} = L_t + kT_t h \quad (4.6)$$

Através da análise da Tabela 3, observam-se os melhores modelos ARIMA e Holt, bem como seus parâmetros. O modelo que melhor se ajustou à série foi o Modelo 1: Holt ($\alpha = 0,9976$, $\beta = 1 e -04$).

Tabela 3 - Seleção dos modelos para capacidade estática de armazenamento de grãos.

Série	Modelo	Parâmetros	AIC	MAPE
Log(Capacidade Estática)	M ₁ HOLT (α , β)	$\alpha = 0,9976$, $\beta = 1e-04$	70,84	0,3515
Log(Capacidade Estática)	M ₂ ARIMA (2,1,1)	-	84,81	0,3964

Fonte: Elaborado pelo autor (2020)

A Figura 6 apresenta uma tendência de crescimento para a capacidade de armazenamento de grãos no estado do RS. Pela previsão do modelo de suavização exponencial biparamétrico de Holt selecionado, em 2024 a capacidade estática de armazenamento de grãos será de cerca de 33,5 milhões de toneladas.

Através da análise gráfica da Figura 6 evidencia-se, ainda, que há períodos de queda na década de 1990, os quais podem ser explicados pelas diretrizes governamentais de menor intervenção nos processos produtivos. Tais diretrizes ocasionaram redução nos investimentos e subsídios ao setor primário para unidades armazenadoras na época.

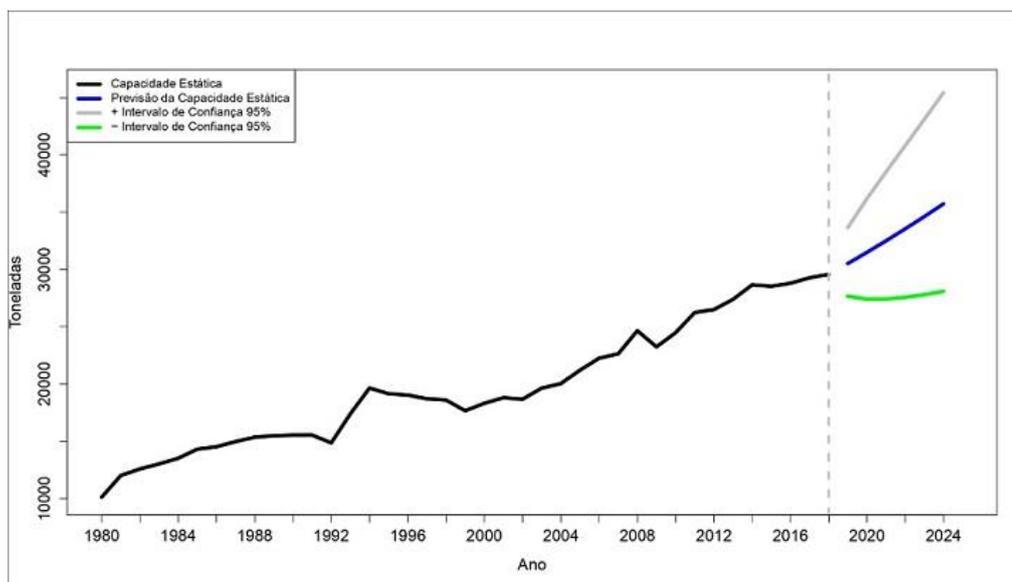


Figura 6 - Previsão da capacidade estática de armazenamento dos grãos, para os próximos seis anos no estado do RS.

Fonte: Elaborado pelo autor (2020)

A previsão para a capacidade estática para o ano de 2024 representa um crescimento de cerca de 26,5% desde o início do programa PCA Armazéns, em 2013, o que demonstra que a política de subsídios a programas de armazenagens está efetivamente aumentando a capacidade estática do RS.

4.4.3 Comparação Entre Produção e Capacidade Estática de Armazenamento dos Grãos

Os dados de armazenagem possuem como data base o dia 31 de dezembro de cada ano. Já os dados de safra têm como referência o mês de julho, isto é, a Conab divulga dados da safra anual percorrendo o período de julho de um ano a junho do ano subsequente. Como o estudo tem por objetivo analisar a relação entre capacidade de armazenagem e safra de grãos, foi necessário prever tanto a capacidade estática de armazenamento quanto a safra de grãos para o Estado.

A produção de grãos no RS cresceu cerca de 153% entre as safras 1980/1981 e 2018/2019, que passou de 14,1 milhões de toneladas para 35,6 milhões de toneladas. A capacidade de armazenamento, por sua vez, cresceu 193% no mesmo período, saltando de 10,1 milhões de toneladas para 29,6 milhões de toneladas.

A partir da análise da Figura 6, verifica-se que entre os anos de 2013 e 2019, a capacidade estática de armazenagem cresceu cerca de 8%, enquanto a produção de grãos avançou aproximadamente 24% entre as safras 2013/14 e 2018/19. Constata-se que partir de 2013 a produção de safra teve crescimento superior à capacidade de armazenagem. No período compreendido desde o início do programa PCA Armazéns e o momento atual, a capacidade de armazenamento gaúcha teve crescimento inferior ao aumento das safras de grãos no Estado.

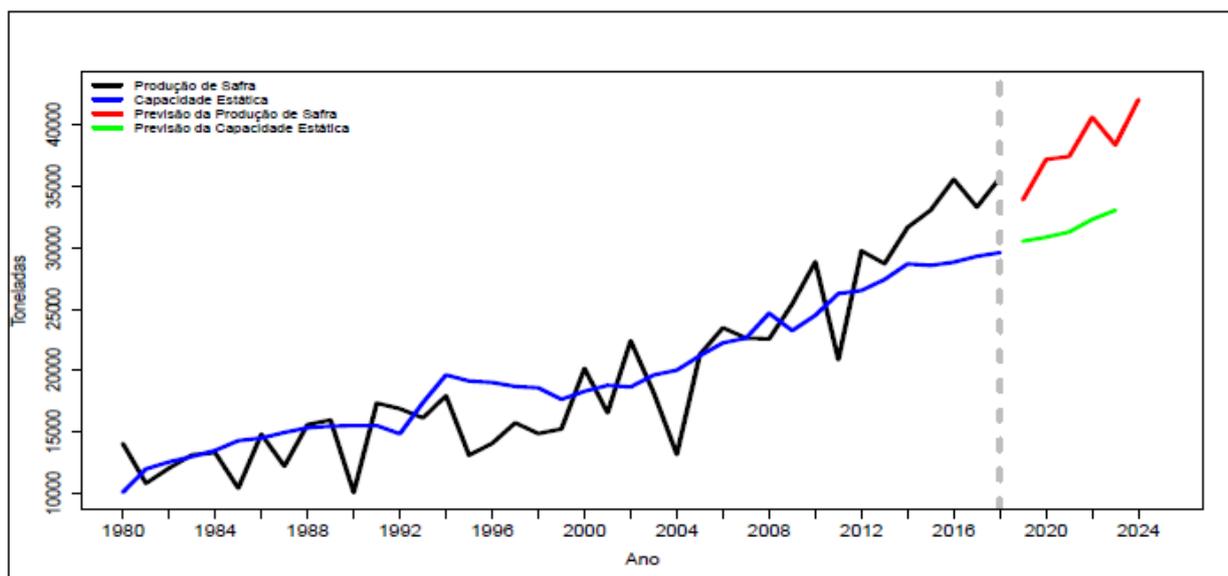


Figura 7 - Projeção da produção agrícola de grãos e capacidade de armazenamento no Brasil para os próximos anos safra

Fonte: Elaborado pelo autor

Observa-se na Tabela 4 o quantitativo projetado para produção de grãos e capacidade estática até a safra de 2024/2025. Na tabela, LI representa o limite inferior da projeção e LS representa o limite superior da projeção, para um intervalo de confiança de 95%.

Tabela 4 - Valores preditos para a produção agrícola de grãos e capacidade de armazenamento no RS para os próximos seis anos-safra

Ano	Produção de Safra	Produção		Capacidade Estática	Capacidade	
		LI 95%	LS 95%		LI 95%	LS 95%
2019/20	33.862,90	23.505,38	48.784,41	30.500,39	26.212,53	35.484,24
2020/21	37.129,82	25.562,58	53.931,41	30.824,09	24.443,43	38.870,35
2021/22	37.375,73	25.531,02	54.715,61	31.248,37	22.977,34	42.496,69
2022/23	40.556,13	27.491,62	59.829,14	32.267,76	22.018,02	47.288,92
2023/24	38.305,59	25.343,67	59.896,84	33.011,65	19.582,27	55.650,79
2024/25	42.001,12	27.508,44	64.129,18	33.523,16	17.398,53	64.591,78

Fonte: Elaborado pelo autor (2020)

As projeções populacionais indicam crescimento acelerado e contínuo nas próximas décadas, o que deve elevar a demanda de alimentos em geral (SAATH e

FACHINELLO, 2018). Tal elevação impactará, por conseguinte, na demanda por grãos.

De acordo com estimativas da ONU (2019), a população mundial em 2050 será de 9,7 bilhões de pessoas, o que representa um crescimento de 26% em relação à população de 2019. Segundo estimativas do *International Grains Council* (IGC, 2019), a produção de grãos no mundo da safra 2019/2020 será de 2.148 milhões de toneladas, enquanto o consumo mundial estimado é 2.184 milhões de toneladas de grãos, demonstrando que ainda não se atingiu a produção necessária para suprir a demanda.

4.4.4 Panorama Financeiro Histórico do PCA Armazéns

Com o objetivo de reduzir o déficit de armazenagem no Brasil, o Governo Federal criou, em julho de 2013, o PCA Armazéns. Desde a data da criação da linha de crédito até março de 2019 foram realizadas 2.335 operações no programa de fomento no país, dentre as quais 673 contratadas no RS. As taxas de juros no período de vigência variaram entre 3,5% a.a. e 8% a.a.. A Tabela 5 demonstra o número de operações realizadas, os valores desembolsados e as taxas de juros aplicadas a cada ano no RS.

Ano	Número de operações realizadas no RS	Valores Desembolsados	Taxa de Juros
2013 ³	27	R\$ 5.294.405,54	3,5%
2014	116	R\$ 52.493.757,27	3,5% - 4,0%
2015	115	R\$ 40.901.936,00	4,0% - 7,5%
2016	111	R\$ 31.941.781,28	7,5% - 8,5%
2017	98	R\$ 32.438.674,46	8,5% - 6,5%
2018	137	R\$ 43.810.339,72	6,5% - 5,25% ou 6% ⁴
2019 ⁵	69	R\$ 13.747.684,25	5,25% ou 6% ⁶

Tabela 5 – Número de operações realizadas desde o início do programa PCA-Armazéns no RS

Fonte: Elaborado pelo autor (2020)

Através da análise dos números demonstrados na Tabela 5, percebe-se que no ano de 2014, período em que as taxas de juros estiveram mais baixas, com variação entre 3,5% e 4% os valores desembolsados foram os mais elevados (R\$ 52.493.757,27). No período em que as taxas de juros do programa estiveram mais elevadas, por sua vez, no ano de 2016, foi o ano completo em que houve menor valor desembolsado ao longo do programa (R\$31.941.781,28).

Assim, nota-se que taxas mais baixas estimulam os agricultores a investirem valores maiores na armazenagem de grãos e infere-se que além da política de fomento do programa PCA Armazéns, a taxa de juros praticada impacta diretamente na decisão do investidor do setor primário. Tal aspecto financeiro, que afeta diretamente a empresa estudada, não é definido pela mesma e sim pelo gestor do programa, que é o BNDES, de forma que embora seja um fator muito relevante e determinante, foge do escopo desse estudo.

³ O programa iniciou no mês de julho de 2013, portanto há apenas 6 meses contemplados no somatório.

⁴ A taxa de juros até julho de 2018 era de 6,5% a.a. e a partir de julho de 2018 era de 5,25% a.a. para unidades armazenadoras com capacidade de até 6.000 toneladas e de 6% a.a. para unidades armazenadoras a partir de 6.000 toneladas.

⁵ Dados até março de 2019.

⁶ A taxa de juros 2018 era de 5,25% a.a. para unidades armazenadoras com capacidade de até 6.000 toneladas e de 6% a.a. para unidades armazenadoras a partir de 6.000 toneladas e possibilidade de taxa pós-fixada.

5 CONSIDERAÇÕES FINAIS

Esta dissertação teve como objetivo principal utilizar modelos de previsão de demanda para analisar a viabilidade de manutenção da linha de financiamento PCA Armazéns em agências de fomento, tendo como caso específico o do Badesul Desenvolvimento, no estado do RS. Para atingir o objetivo foi necessário realizar uma revisão bibliográfica a respeito do tema armazenagem de grãos e estocagem de safras agrícolas, bem como analisar a situação atual do Estado com relação à safra agrícola produzida. Obtiveram-se modelos, através do modelo ARIMA de previsão de demanda, segundo a metodologia de Box e Jenkins, e da suavização exponencial biparamétrica de Holt, para um horizonte de seis períodos à frente, que correspondem aos próximos seis anos-safra.

O setor agrícola é parte de uma área estratégica para o RS, tendo em vista que o Estado é o terceiro maior produtor de grãos do país. Os principais grãos produzidos no RS são: soja, arroz, milho e trigo, que representaram, na safra 2018/2019, cerca de 92% da produção gaúcha de grãos. A soja, principal grão produzido no Estado, foi responsável, em valor, por cerca de 30,2% das exportações gaúchas em 2018.

O estudo de caso utilizou dados de produção agrícola e da capacidade de armazenamento para o Estado do RS no período compreendido entre 1980 e 2019. Através das previsões de demanda realizadas, verificou-se que a produção de grãos nos próximos seis anos-safra aumentará, anualmente, em termos relativos, mais do que a capacidade de armazenamento. A partir dos dados disponibilizados pelo BNDES e analisados nesse trabalho, inferiu-se que fatores financeiros, como a taxa de juros praticada, impacta diretamente na decisão do investidor do setor primário, tendo em vista que no período com a menor taxa de juros, os valores desembolsados pelo programa foram cerca de 64% superiores ao período em que a taxa praticada foi a mais elevada.

Na safra 2024/2025, último período previsto, a produção de grãos foi estimada em cerca de 42 milhões de toneladas. A capacidade de armazenamento, por sua vez, segundo a previsão realizada, será de aproximadamente 33,5 milhões de toneladas. Dessa forma, evidencia-se que a capacidade estática de

armazenamento de grãos no RS corresponderá a 79,81% da safra, valor aquém dos 120% recomendados pela FAO. O déficit previsto para 2024/2025 é percentualmente superior ao existente hoje, em que a capacidade estática de armazenamento corresponde a 86,5% da produção de grãos.

O modelo que melhor se adaptou à previsão de safra foi o ARIMA (2,1,1), enquanto o modelo que melhor se adaptou à previsão da capacidade de armazenamento foi o modelo biparamétrico de Holt. O método da análise de séries temporais mostrou-se eficiente na obtenção de previsões, uma vez que o MAPE encontrado foi de 1,34% para a produção de safra de grãos e de 0,35% para a capacidade estática de armazenamento.

O estudo de caso permitiu uma interação entre universidade e empresa, ao modelar uma situação real de previsão de demanda. Os modelos identificaram que, apesar dos desembolsos efetuados pelo programa PCA Armazéns, a situação da armazenagem no RS não tende a alcançar os índices recomendados pela FAO. Pelo contrário, tendo em vista que a safra de grãos apresenta tendência de crescimento superior à capacidade de armazenamento, o programa PCA Armazéns continuará sendo uma boa opção a ser oferecida no portfólio de negócios da agência de fomento para os próximos seis anos-safra, ao contrário do pressuposto no argumento fundamental desta dissertação.

O crescimento projetado para a safra de grãos no RS no período analisado é de cerca de 11,7% e o crescimento da capacidade estática de armazenamento é de cerca de 8,7%. Uma vez que a agricultura, segundo dados do IBGE (2016), é a principal atividade econômica de 252 dos 497 municípios gaúchos e que as perdas por insuficiência ou inadequação na armazenagem podem chegar a 20% da safra, o investimento nessa área é fundamental para melhorar a produção de grãos no RS.

Assim, conclui-se que a hipótese principal investigada está surtindo efeito, uma vez que a política de fomento ao armazenamento de grãos no Estado do RS será necessária, no mínimo, para os próximos seis anos-safra. Para futuros trabalhos outros enfoques podem ser adotados. Sugere-se uma previsão de demanda para armazenagem a nível nacional, a fim de testar a efetividade do

programa PCA Armazéns como política pública adotada pelo BNDES em sua integralidade.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDE (Rio de Janeiro) (org.). **Sistema Nacional de Fomento**: Financiando o Desenvolvimento. 2015. Disponível em: <http://abde.org.br/wp-content/uploads/2018/06/SNF.pdf>. Acesso em: 20 dez. 2019.

ARCHER, B.H. Forecasting Demand: Quantitative and Intuitive Techniques – **International Journal of Tourism Management** – v. 1, n. 1, p. 5-12, 1980.

ARMSTRONG, J. S.; COLLOPY, F. Error measures for generalizing about forecasting methods: Empirical comparisons. **International journal of forecasting**, v. 8, n. 1, p. 69-80, 1992.

ARMSTRONG, J. S. **Principles of Forecasting**: A handbook for Researchers and Practitioners. Boston: Kluwer Academic Publishers, 2001.

ARTHUS, M. G.; CAMATTI, J.A.; BORTOLETTO, W.;Ferrari. O.;IGNÁCIO. P.S.A.; Planejamento da safra de soja no Oeste do Paraná. **Produto & Produção**, v. 17, n. 4, 2016.

ASSAD, E. D.; MARIN, F.R.; EVANGELISTA, S.R.; PILAU, F.G.; FARIAS, J.R.B.; PINTO, H.S.; ZULLO JUNIOR, J. Sistema de previsão da safra de soja para o Brasil. **Pesquisa Agropecuária Brasileira**, v. 42, n. 5, p. 615-625, 2007.

BACCI, L. A. **Combinação de métodos de séries temporais para previsão da demanda de café no Brasil**. 2007. 145 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Universidade Federal de Itajubá, Itajubá, 2007.

BESKOW, P.; DECKERS, D. Legislação brasileira de armazenamento de grãos. **Armazenagem de grãos. Geneziz, Campinas, Brasil**, p. 27-53, 2002.

BORGES, Pedro Augusto Pereira. **Modelagem dos Processos Envolvidos nos Sistemas de Secagem e Armazenamento de Grãos**. 2002. 112 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2002.

BOX, G. E.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time series analysis: forecasting and control**. 3rd ed. Englewood Cliffs. Prentice Hall, c1994. 598p.

BRESSAN, Aureliano Angel. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE-eletrônica**, v. 3, n. 1, p. 1-20, 2004.

BUSINGER, Mark P.; READ, Robert R.. Identification of demand patterns for selective processing: a case study. **Omega**, [s.l.], v. 27, n. 2, p.189-200, 02 abr. 1999. Elsevier BV. [http://dx.doi.org/10.1016/s0305-0483\(98\)00039-5](http://dx.doi.org/10.1016/s0305-0483(98)00039-5).

CALSING, L.C. **Previsão de Demanda Combinada a Partir de Métodos Quantitativos e Opinião de Especialistas**. 2015. 66 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.

CARDOSO, C. A. V.; CRUZ, G. L. Forecasting natural gas consumption using ARIMA models and artificial neural networks. **IEEE Latin America Transactions**, v. 14, n. 5, p. 2233-2238, 2016.

CONAB, C.d.A. Safra série histórica. 2019.

EHLERS, R. S.. **Análise de Séries Temporais**. 5. ed. Curitiba: Universidade Federal do Paraná, 2009.

ELIAS, M. Armazenamento e conservação de grãos. **Texto didático. Pólo de Inovação Tecnológica em Alimentos da Região Sul, Conselho Regional de Desenvolvimento da Região Sul (COREDE-SUL), UFPel. Pelotas: UFPel**, 2003.

EMATER. **Safra de verão é anunciada enquanto a de inverno se desenvolve no RS**. 2019. Disponível em: <
<https://www.noticiasagricolas.com.br/noticias/agronegocio/241625-safra-de-verao-e-anunciada-enquanto-a-de-inverno-se-desenvolve-no-rs.html#>>. Acesso em: 25 out. 2019.

EMBRAPA. **Perdas na produção de grãos ainda assustam**. 2013. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/1473675/perdas-na-producao-de-graos-ainda-assustam>>. Acesso em: 20 out. 2019.

EMILIANO, P. C. Fundamentos e aplicações dos critérios de informação: Akaike e Bayesiano. **Universidade Federal de Lavras**, 2009.

FAVA, V. L. Metodologia de Box-Jenkins para modelos univariados. **Manual de econometria: nível intermediário**, 2000.

FEIX, R. D. Perspectivas para a Agricultura Gaúcha em 2017. **Carta de Conjuntura FEE**. Porto Alegre, disponível em: <<https://estado.rs.gov.br/upload/arquivos//painel-do-agronegocio-no-rs-2019.pdf>>. Acesso em 29.dez.2019.

FELIPE, I. J. S. Aplicação de modelos Arima em séries de preços de soja no Norte do Paraná. **Tekhne e Logos**, v. 3, n. 3, 2012.

FILDES, R; HIBON, M; MAKRIDAKIS, S; MEADE, N. Generalising about univariate forecasting methods: further empirical evidence. **International Journal Of Forecasting**, [s.l.], v. 14, n. 3, p.339-358, set. 1998. Elsevier BV. Disponível em <[http://dx.doi.org/10.1016/s0169-2070\(98\)00009-0](http://dx.doi.org/10.1016/s0169-2070(98)00009-0)>. Acesso em 03.nov.2019.

FUNDAÇÃO DE ECONOMIA E ESTATÍSTICA. **Características da agropecuária do RS**. 2015. Disponível em: <<https://www.fee.rs.gov.br/sinteseilustrada/caracteristicas-da-agropecuaria-do-rs/>>. Acesso em: 01 set. 2015.

GOMES, F. C. Os modelos Arima e a abordagem de Box-Jenkins uma aplicação na previsão do IBOVESPA a curtíssimo prazo. **Revista de Administração de Empresas**, v. 29, n. 2, p. 63-70, 1989.

HEIFNER, R. G. The Gains from Basing Grain Storage Decisions on Cash-Future Spreads. **Journal of Farm Economics**, v. 48, n. 5, p. 1490-1495, 1966.

HAMJAH, M.A. Rice production forecasting in Bangladesh: An application of Box-Jenkins ARIMA model. **Mathematical theory and modeling**, v. 4, n. 4, p. 1-11, 2014.

INTERNATIONAL GRAINS COUNCIL. **Grain Market Report**. 2019. Disponível em: <<https://www.igc.int/en/default.aspx>>. Acesso em: 02 ago. 2019.

IUNES, R. F. *et al.* Demanda e demanda em saúde. **Economia da Saúde: conceito e contribuição para a gestão da saúde**. Brasília: IPEA, p. 99-140, 1995.

JANK, M. S.; NASSAR, A. M.; TACHINARDI, M. H. Agronegócio e comércio exterior brasileiro. **Revista USP**, n. 64, p. 14–27, 2005.

JOHNSON, D.; KING, M. **Basic forecasting techniques**. Butterworth. London, 1988.

KOTLER, P; ARMSTRONG, G. **Fundamentos de mercadotecnia**. Prentice Hall Hispanoamericana,, 1991.

KOTLER, P. Administração de marketing: análise. **Planejamento, implementação e controle**. V.5, 1998.

KURRLE, M.A.. **Métodos para Previsão de Demanda de Veículos Novos: estudo de caso em uma concessionária de automóveis**. Estudo de Caso em uma Concessionária de Automóveis. 2004. 114 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

LEMOS, F. O. **Metodologia para Seleção de Métodos de Previsão de Demanda**. 2006. 183 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. **Forecasting methods and applications**. John Wiley & Sons, 2008.

MARTINS, P.G; LAUGENI, F.P. **Administração da produção**. 2.ed. rev., aum. e atual. São Paulo: Saraiva, 2005.

MARTINS, R.S. REBECHI, D.; PRATI, C.A. *et al.* Decisões estratégicas na logística do agronegócio: compensação de custos transporte-armazenagem para a soja no estado do Paraná. **Revista de administração contemporânea**, v. 9, n. 1, p. 53-78, 2005.

MARTINS, V. L. M.; WERNER, L. Comparação de previsões individuais e suas combinações: um estudo com séries industriais. **Production**, v. 24, n. 3, p. 618-627, 2014.

MENDES, Judas Tadeu Grassi; PADILHA JÚNIOR, João Batista. **Agronegócio: uma abordagem econômica**. Pearson Prentice Hall, 2007.

MENTZER, J. T.; COX JR, J. E. Familiarity, application, and performance of sales forecasting techniques. **Journal of Forecasting**, v. 3, n. 1, p. 27-36, 1984.

MORETTIN, P.A. **Econometria financeira: um curso em séries temporais financeiras**. Editora Blucher, 2017.

MORETTIN, P.A. E TOLLOI C.M.C. **Métodos para Previsão Temporal**, Rio de Janeiro, 1981.

MOTULSKY, H; CHRISTOPOULOS, A. **Fitting models to biological data using linear e nonlinear regression : a practical guide to curve fitting**. San Diego : GraphPad Software, 2003. 351p.

MUELLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. 1996. 103 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 1996.

PATURCA, E. Y. Caracterização das estruturas de armazenagem de grãos: um estudo de caso no mato grosso. **Grupo de Pesquisa e Extensão em Logística Agroindustrial– ESALQ-LOG**. Piracicaba, 2014.

PELLEGRINI, Fernando R. **Metodologia para Implementação de Sistemas de Previsão de Demanda**. 2000. Dissertação (Pós-Graduação em Engenharia de Produção) - Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

PELLEGRINI, F. R.; FOGLIATTO, F. Estudo comparativo entre modelos de winters e de box-jenkins para a previsão de demanda sazonal. **Revista Produto & Produção**, v. 4, p. 72–85, 2000.

PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: modelos & previsões**. Elsevier, 2004.

PINTO, P. L. A.; PEREIRA, E.S.; Santos, J.M.D; MAIA, S.F. **Aplicação do modelo ARIMA à previsão do preço das commodities agrícolas brasileiras**. 2008.

PONTES, H. L. J.; CARMO, B. B. T. D.; PORTO, A. J. V. Problemas logísticos na exportação brasileira da soja em grão. **Sistemas & Gestão**, v. 4, n. 2, p. 155–181, 2009.

PUZZI, D. Abastecimento e Armazenagem de Grãos. **ICEA, Campinas, Brasil** 2000.

RUSSO, S.L. **GRÁFICOS DE CONTROLE PARA VARIÁVEIS NÃO-CONFORMES AUTOCORRELACIONADAS**. 2002. 166 f. Tese (Doutorado) - Curso de Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 2002.

SANDERS, N.; RITZMAN, L. Improving short-term forecasts. **Omega**, Elsevier, v. 18, n. 4, p. 365–373, 1990.

SAATH, K.C.O; FACHINELLO, A.L. Crescimento da demanda mundial de alimentos e restrições do fator terra no Brasil. **Revista de Economia e Sociologia Rural**, [s.l.], v. 56, n. 2, p.195-212, jun. 2018. FapUNIFESP (SciELO).

SANDHUSEN, R. L. **Marketing Básico**. Editora Saraiva. São Paulo, 1998.

SIAPLAY, Mounir *et al.* Using basis, futures price, and futures price spread as barometers for storage decisions. **International Journal of Economics and Finance**, v. 4, n. 5, p. 15-24, 2012.

SIAPLAY, M.; Adam, B. D., Brorsen, B. W., & Anderson, K. B. Using basis, futures price, and futures price spread as barometers for storage decisions. **International Journal of Economics and Finance**, v. 4, n. 5, p. 15-24, 2012.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. Administração da produção. 3. ed. São Paulo (SP): Atlas, 2009.

SOUZA, M. O.; MARQUES, V.D.; SOUZA, G.S.; MARRA, R.de *et al.* **O complexo de soja: aspectos descritivos e previsões**. 2010.

TIBULO, C; TIBULO, V. C. Previsão do preço do milho, através de séries temporais. **Scientia Plena**, v. 10, n. 10, 2014.

VELASCO, L.H. **Previsão de demanda de acessos móveis no sistema de telefonia brasileiro**. Dissertação (Pós-Graduação em Engenharia de Produção) - Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

WEBER, E. A. **Exelência em beneficiamento e armazenagem de grãos**. Salles, 2005.

WORKING, H. Futures trading and hedging. **The American Economic Review**, v. 43, n. 3, p. 314-343, 1953.

ZANIN, V. **Análise setorial As produções nacional e estadual de grãos**, 2011,

ZULAUF, C.R.; IRWIN, S.H. Market efficiency and marketing to enhance income of crop producers. **Review of Agricultural Economics**, v. 20, n. 2, p. 308-331, 1998.

APÊNDICE 1 - SÉRIE HISTÓRICA DA PRODUÇÃO DE GRÃOS E DA CAPACIDADE DE ARMAZENAMENTO DO ESTADO DO RS

ANO	Série da Produção de Grãos do RS	Série da Capacidade Estática
1980/81	14.083,50	10.126,00
1981/82	10.853,80	12.017,00
1982/83	12.086,50	12.589,00
1983/84	13.166,60	13.026,00
1984/85	13.335,10	13.521,00
1985/86	10.461,50	14.315,00
1986/87	14.837,30	14.525,00
1987/88	12.250,30	14.979,00
1988/89	15.614,10	15.360,00
1989/90	15.991,50	15.490,00
1990/91	10.115,40	15.537,00
1991/92	17.360,40	15.541,00
1992/93	16.908,90	14.867,4
1993/94	16.160,60	17.400,4
1994/95	17.958,40	19.649,7
1995/96	13.137,70	19.154,8
1996/97	14.094,40	19.037,2
1997/98	15.763,60	18.714,8
1998/99	14.890,70	18.601,3
1999/00	15.266,00	17.667,1
2000/01	20.171,50	18.319,4
2001/02	16.576,70	18.804,7
2002/03	22.413,40	18.674,8
2003/04	18.205,40	19.644,7
2004/05	13.201,90	20.035,3
2005/06	21.313,23	21.207,6
2006/07	23.471,90	22.252,8
2007/08	22.640,70	22.637,9
2008/09	22.578,00	24.654,7
2009/10	25.398,40	23.247,37
2010/11	28.825,00	24.487,1
2011/12	20.888,80	26.247,5
2012/13	29.711,98	26.500
2013/14	28.677,90	27.391,57
2014/15	31.620,50	28.659,79
2015/16	33.023,10	28.535
2016/17	35.516,64	28.798,56
2017/18	33.267,85	29.275,62
2018/19	35.640,28	29.571,72

APÊNDICE 2 – COMANDOS UTILIZADOS NO SOFTWARE R

```
setwd("C:/Users/JUNIORGIACOBBO/seriedissertacao)

require(forecast)

require(tseries)

require(stats)

require(GeneCycle)

library(Kendall)

require(adehabitatLT)

require(MASS)

library(readxl)

library(grid)

library(seasonal)

library(lmtest)

library(nortest)

library(dplyr)

library(ggplot2)

library(fGarch)

library(urca) # Testes de Co-integração e de raízes unitárias

library(randtests)

library(caret)

library(nortest)

dados_producao_safra <- read_excel("dados_capacidade_safra.xlsx")

#deixando os dados prontos para serem tracados de forma temporal

prod_safra=ts((dados_producao_safra$prod_safra),start = 1980, freq=1)# Produção de
Safra

log_prod_safra=ts(log(dados_producao_safra$prod_safra),start = 1980, freq=1)#
Produção de Safra
```

```

periodo<-as.factor(dados_producao_safra$periodo)

pdf("Producaodesafra_log-FAC-PACF.pdf", height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

m<-t(matrix(c(1,2, 1,2, 3,4, 3,4),

nrow = 2,

ncol = 4))

layout(m)

plot.ts(ts(dados_producao_safra$prod_safra,start = 1980, freq=1),main='(a)',
xlab="Ano",ylab= "Toneladas", col="black",lwd=5,xaxt="n")

axis(1, at = seq(1980,2018,2))

# par(new=TRUE)

legend("topleft", c(expression(paste('Produção de Safra'))),

lty=c(1), col=c('black'), lwd=c(5))

#Função de producaocorrelação da série de produção de safra

acf(prod_safra,lag=10,xlab="Lag",lwd=5,main="(b)")

#Função de producaocorrelação Parcial a série de produção de safra

# pacf(prod_safra,lag=1,xlab="Lag",main="(c)",lwd=5)

plot.ts(log_prod_safra,main='(c)',xlab="Ano",ylab= " Log(Toneladas)",
col="black",lwd=5,xaxt="n" )

axis(1, at = seq(1980,2018,2))

legend("topleft", c(expression(paste('Log(Produção de Safra)')),

lty=c(1), col=c('black'), lwd=c(5))

#Função de producaocorrelação da série de Capacidade Estática

acf(log_prod_safra,lag=10,xlab="Lag",lwd=5,main="(d)")

#Função de producaocorrelação Parcial a série de Capacidade Estática

# pacf(log_prod_safra,lag=10,xlab="Lag",main="(f)",lwd=5)

box()

pushViewport(viewport())

```

```
grid.lines(y = 0.5, x = c(1,0) ,
gp = gpar(col = "black"))
popViewport()
box(lty = 1, col = 'black', which = 'outer')
dev.off()

####TESTE DE HIPOTESE ####

####TESTE DE TENDENCIA#####

#Teste de Mann-Kendall para verificar tendência na série Produção de Safra, sob a
#hipótese:
#H0:"Ho: Não possui a componente tendência"
#H1:"H1: possui tendência"
MannKendall(prod_safra)

#Pelo teste de Mann-Kendall e Cox Stuart test, a série logaritimizada de produção de
safra possui tendência.

MannKendall(log_prod_safra)

#teste de kruskal-Wallis para verificar sazonalidade na série Capacidade Estática, sob a
#hipótese:
#H0:"Ho: Não possui sazonalidade"
#H1:"H1: possui sazonalidade"
tempo=seq(1:39)
kruskal.test(prod_safra ~ tempo)

#Pelo teste de kruskal-Wallis, a série produção de safra não possui sazonalidade.

tempo=seq(1:39)
kruskal.test(log_prod_safra ~ tempo)

#Pelo teste de kruskal-Wallis, a série logaritimizada da produção de safra não possui
sazonalidade.

#Testes para não-estacionariedade: ##

##Dickey-Fuller para a série de produção de safra
```

```

#hipótese:

#H0:"A série é não-estacionária"

#H1:"A série é estacionária"

adf.test(prod_safra)

#Pelo teste de Dickey-Fuller, não rejeita-se a não hipótese nula, ou seja, a série de
produção de safra é não-estacionária.

adf.test(log_prod_safra)

#Pelo teste de Dickey-Fuller, não rejeita-se a não hipótese nula, ou seja, a série
logaritimizada de produção de safra é não-estacionária.

#TESTE PARA AS DIFERENÇAS DEIXA A SÈRIE ESTACIONARIA

adf.test(diff(prod_safra,dif=1))

#Pelo teste de Dickey-Fuller, rejeita-se a não hipótese nula, ou seja, a primeira
diferença da série de produção de safra é não-estacionária.

adf.test(diff(log_prod_safra,dif=1))

#Pelo teste de Dickey-Fuller, rejeita-se a não hipótese nula, ou seja, a primeira
diferença da série logaritimizada de produção de safra é não-estacionária.

# jpeg("diff1-PF-log-FAC-PACF.jpeg", res = 1080, type = "windows", width = 20000,
height = 13000)

pdf("diff1-PF-log-FAC-PACF.pdf", height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

m<-t(matrix(c(1,2, 3, 1,2,3, 1,2,3,4,5,6,4,5,6,4,5,6), nrow = 3, ncol = 6))

layout(m)

plot(diff(log_prod_safra,lag=1,differences=1),xlab="Ano",ylab=
"",xaxt="n",col='red',lwd=5,main='(a)')

abline(h=0, lwd=c(3))

axis(1, at = seq(1980,2018,2))

legend("bottomright", c(expression(paste('1ª diferença da Produção de Safra'))),
lty=c(1), col=c('red'), lwd=c(5))

#Função de producaocorrelação da série de produção de safra

acf(diff(prod_safra,dif=1),lag=10,xlab="Lag",lwd=5,main="(b)")

```

```

#Função de producaocorrelação Parcial a série de produção de safra
pacf(diff(prod_safra,dif=1),lag=10,xlab="Lag",main="(c)",lwd=5)

plot.ts(diff(log_prod_safra,lag=1,differences=1),xlab="Ano",ylab=
"",xaxt="n",col='red',lwd=5,main='(d)')

abline(h=0, lwd=c(3))

axis(1, at = seq(1980,2018,2))

legend("bottomright", c(expression(paste('1º diferença do Log(Produção de Safra)'))),
      lty=c(1), col=c('red'), lwd=c(5))

#Função de produção correlação da série de Capacidade Estática
acf(diff(log_prod_safra,dif=1),lag=10,xlab="Lag",lwd=5,main="(e)")

#Função de producaocorrelação Parcial a série de Capacidade Estática
pacf(diff(log_prod_safra,dif=1),lag=10,xlab="Lag",main="(f)",lwd=5)

box()

pushViewport(viewport())

grid.lines(y =0.5, x = c(1,0) ,
          gp = gpar(col = "black"))

popViewport()

box(lty = 1, col = 'black', which = 'outer')

dev.off()

#Construindo os modelos Produção de safra
modelo1_prod_safra <- holt(prod_safra,h=6)

modelo3_prod_safra <- Arima(prod_safra,order=c(0,1,2))

modelo<-AR(prod_safra)

#TESTE DO MODELO 1

summary(modelo1_prod_safra)

coefest(modelo1_prod_safra)

```

```

tsdiag(modelo1_prod_safra,lwd=3)

Box.test(modelo1_prod_safra$residuals, lag = 1, type = c("Box-Pierce", "Ljung-Box"),
fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo1_prod_safra=forecast(modelo1_prod_safra, h=5)

plot(fit_modelo1_prod_safra,main="", xlab="Ano",ylab= "Produção",col=1,lwd=3)

#TESTE DO MODELO 3

summary(modelo3_prod_safra)

coeftest(modelo3_prod_safra)

tsdiag(modelo3_prod_safra,lwd=3)

Box.test(modelo3_prod_safra$residuals, lag = 1, type = c("Box-Pierce", "Ljung-Box"),
fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo3_prod_safra=forecast(modelo3_prod_safra, h=5)

plot(fit_modelo3_prod_safra,main="", xlab="Ano",ylab= "Produção",col=1,lwd=3)

#Construindo os modelos para log Produção de safra

modelo1_log_prod_safra <- holt(log_prod_safra,h=6)

modelo2_log_prod_safra <-Arima(log_prod_safra,order=c(2,1,1),
seasonal=list(order=c(0,1,1)))

#TESTE DO MODELO 1

summary(modelo1_log_prod_safra)

coeftest(modelo1_log_prod_safra)

tsdiag(modelo1_log_prod_safra,lwd=3)

Box.test(modelo1_log_prod_safra$residuals, lag = 1, type = c("Box-Pierce", "Ljung-
Box"), fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo1_log_prod_safra=forecast(modelo1_log_prod_safra, h=5)

plot(fit_modelo1_log_prod_safra,main="", xlab="Ano",ylab= "Produção",col=1,lwd=3)

#TESTE DO MODELO 2

summary(modelo2_log_prod_safra)

coeftest(modelo2_log_prod_safra)

tsdiag(modelo2_log_prod_safra,lwd=3)

```

```

Box.test(modelo2_log_prod_safra$residuals, lag = 1, type = c("Box-Pierce", "Ljung-
Box"), fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo2_log_prod_safra=forecast(modelo2_log_prod_safra, h=6)

plot(fit_modelo2_log_prod_safra,main="", xlab="Ano",ylab= "Produção",col=1,lwd=3)

hist(modelo2_log_prod_safra$residuals)

# Testes NORMALIDADE DOS RESIDUOS

ks.test(modelo2_log_prod_safra$residuals, "pnorm",
mean(modelo2_log_prod_safra$residuals),
      sd(modelo2_log_prod_safra$residuals)) # KS

lillie.test(modelo2_log_prod_safra$residuals) # Lilliefors

cvm.test(modelo2_log_prod_safra$residuals) # Cramér-von Mises

shapiro.test(modelo2_log_prod_safra$residuals) # Shapiro-Wilk

sf.test(modelo2_log_prod_safra$residuals) # Shapiro-Francia

ad.test(modelo2_log_prod_safra$residuals) # Anderson-Darling

pdf('tsdag_producaosafra.pdf', height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

tsdiag(modelo2_log_prod_safra,lwd=5)

box(lty = 1, col = 'black', which = 'outer')

dev.off()

fit_modelo2_log_prod_safra=forecast(modelo2_log_prod_safra, h=6)

plot(fit_modelo2_log_prod_safra,main="", xlab="Ano",ylab= "Produção",col=1,lwd=3)

fit_m2_log_prod_safra<-exp(fit_modelo2_log_prod_safra[["mean"]][c(1:6)])

int95_lower_fit_m2_safra<-exp(fit_modelo2_log_prod_safra[["lower"]][7:12])

int95_lower_fit_m2_safra<-c(as.vector(rep(NA,39)),as.vector(
int95_lower_fit_m2_safra))

int95_upper_fit_m2_safra<-exp(fit_modelo2_log_prod_safra[["upper"]][7:12])

```

```

int95_upper_fit_m2_safra<-c(as.vector(rep(NA,39)),as.vector(
int95_upper_fit_m2_safra))

prod_safra_fit<-
c(as.vector(dados_producao_safra$prod_safra),as.vector(fit_m2_log_prod_safra))

pdf('previsao_prod_safra.pdf', height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

plot.ts(ts(prod_safra_fit[1:39],start = 1980, freq=1),main="",
        xlab="Ano",ylab= "Toneladas",
col="black",lwd=5,xaxt="n",xlim=c(1980,2025),ylim=c(10000,63000))

lines(ts(prod_safra_fit[40:45],start = 2019, freq=1),lwd=5,col="blue")

lines(ts(int95_upper_fit_m2_safra[40:45],start = 2019, freq=1),lwd=5,col="gray")

lines(ts(int95_lower_fit_m2_safra[40:45],start = 2019, freq=1),lwd=5,col="green")

legend("topleft", c(expression(paste('Produção de Safra')),
        expression(paste('Previsão da Produção de Safra')),
        expression(paste('+ Intervalo de Confiança 95%')),
        expression(paste('- Intervalo de Confiança 95%')) ),
        lty=c(1,1,1,1), col=c('black','blue','gray','green'),lwd=c(5,5,5,5))

abline(v=2018, col="gray", lwd=3, lty=2)

axis(1, at = seq(1980,2024,2))

box(lty = 1, col = 'black', which = 'outer')

dev.off()

##### CAPACIDADE ESTÁTICA#####

dados_capa_estatica <- read_excel("dados_capacidade_safra.xlsx",
        col_types = c("numeric", "numeric","text"))

#deixando os dados prontos para serem traçados de forma temporal

capa_estatica=ts((dados_capa_estatica$capa_estatica),start = 1980, freq=1)#
Capacidade Estática

log_capa_estatica=ts(log(dados_capa_estatica$capa_estatica),start = 1980, freq=1)#
Capacidade Estática

```

```

periodo<-
as.factor(c('1980/1981','1986/1987','1992/1993','1998/1999','2004/2005','2010/2011','2016/2
017','2022/2023'))

pdf("capacidadeestatica_log-FAC-PACF.pdf", height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

m<-t(matrix(c(1,2,
              1,2,
              3,4,
              3,4),
            nrow = 2,
            ncol = 4))

layout(m)

#plotando a série de Capacidade Estática
plot.ts(capa_estatica,main='(a)',
        xlab="Ano",ylab= "Toneladas", col="black",lwd=5,xaxt="n")
axis(1, at = seq(1980,2018,2))
legend("topleft", c(expression(paste('Capacidade Estática'))),
      lty=c(1), col=c('black'), lwd=c(5))

#Função de producaocorrelação da série de Capacidade Estática
acf(capa_estatica,lag=10,xlab="Lag",lwd=5,main="(b)")

#Função de producaocorrelação Parcial a série de Capacidade Estática
# pacf(capa_estatica,lag=10,xlab="Lag",main="(c)",lwd=5)

#plotando a série de log(Capacidade Estática)
plot.ts(log_capa_estatica,main='(c)',xlab="Ano",ylab= " Log(Toneladas)",
col="black",lwd=5,xaxt="n" )
axis(1, at = seq(1980,2018,2))

# par(new=TRUE)

legend("topleft", c(expression(paste('Log(Capacidade Estática')))),

```

```

lty=c(1), col=c('black'), lwd=c(5))

#Função de producaocorrelação da série de Capacidade Estática
acf(log_capa_estatica,lag=10,xlab="Lag",lwd=5,main="(d)")

#Função de producaocorrelação Parcial a série de Capacidade Estática
# pacf(log_capa_estatica,lag=10,xlab="Lag",main="(f)",lwd=5)

box()

pushViewport(viewport())

grid.lines(y =0.5, x = c(1,0) ,
           gp = gpar(col = "black"))

popViewport()

box(lty = 1, col = 'black', which = 'outer')

dev.off()

####TESTE DE HIPOTESE #####

####TESTE DE TENDENCIA#####

#Teste de Mann-Kendall para verificar tendência na série Capacidade Estática, sob a
#hipótese:

#H0:"Ho: Não possui a componente tendência"

#H1:"H1: possui tendência"

MannKendall(capa_estatica)

#Pelo teste de Mann-Kendall e Cox Stuart test, a série logaritimizada de Capacidade
Estática possui tendência.

MannKendall(log_capa_estatica

#teste de kruskal-Wallis para verificar sazonalidade na série Capacidade Estática, sob a
#hipótese:

#H0:"Ho: Não possui sazonalidade"

#H1:"H1: possui sazonalidade"

tempo=seq(1:39)

kruskal.test(capa_estatica ~ tempo)

```

#Pelo teste de kruskal-Wallis, a série producao de safra Não possui sazonalidade.

```
tempo=seq(1:39)
```

```
kruskal.test(log_capa_estatica ~ tempo)
```

#Pelo teste de kruskal-Wallis, a série logaritimizada da produção de safra Não possui sazonalidade.

```
#Testes para não-estacionariedade: ##
```

```
##Dickey-Fuller para a série de Capacidade Estática
```

```
#hipótese:
```

```
#H0:"A série é não-estacionária"
```

```
#H1:"A série é estacionária"
```

```
adf.test(capa_estatica)
```

#Pelo teste de Dickey-Fuller, não rejeita-se a não hipótese nula, ou seja, a série de Capacidade Estática é não-estacionária.

```
adf.test(log_capa_estatica)
```

#Pelo teste de Dickey-Fuller, não rejeita-se a não hipótese nula, ou seja, a série logaritimizada de Capacidade Estática é não-estacionária.

```
#TESTE PARA AS DIFERENÇAS DEIXA A SÈRIE ESTACIONARIA
```

```
adf.test(diff(capa_estatica,dif=1))
```

#Pelo teste de Dickey-Fuller, rejeita-se a não hipótese nula, ou seja, a primeira diferença da série de Capacidade Estática é não-estacionária.

```
adf.test(diff(log_capa_estatica,dif=1))
```

#Pelo teste de Dickey-Fuller, rejeita-se a não hipótese nula, ou seja, a primeira diferença da série logaritimizada de Capacidade Estática é não-estacionária.

```
pdf("diff2-CAP-Esta-log-FAC-PACF.pdf", height = 8, width = 14)
```

```
par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)
```

```
m<-t(matrix(c(1,2, 3, 1,2,3, 1,2,3,4,5,6,4,5,6,4,5,6), nrow = 3, ncol = 6))
```

```
layout(m)
```

```
plot(diff(log_capa_estatica,lag=1,differences=2),xlab="Ano",ylab=
"",xaxt="n",col='red',lwd=5,main='(a)')
```

```
axis(1, at = seq(1980,2018,2))
```

```

legend("topright", c(expression(paste('2º diferença da Capacidade Estática'))),
lty=c(1), col=c('red'), lwd=c(5))

abline(h=0, lwd=c(3))

#Função de producaocorrelação da série de Capacidade Estática
acf(diff(capa_estatica,dif=2),lag=10,xlab="Lag",lwd=5,main="(b)")

#Função de producaocorrelação Parcial a série de Capacidade Estática
pacf(diff(capa_estatica,dif=2),lag=10,xlab="Lag",main="(c)",lwd=5)

plot.ts(diff(log_capa_estatica,lag=1,differences=2),xlab="Ano",ylab=
"",xaxt="n",col='red',lwd=5,main='(d)')

axis(1, at = seq(1980,2018,2))

abline(h=0, lwd=c(3))

legend("topright", c(expression(paste('2º diferença do Log(Capacidade Estática)'))),
lty=c(1), col=c('red'), lwd=c(5))

#Função de produção correlação da série de Capacidade Estática
acf(diff(log_capa_estatica,dif=2),lag=10,xlab="Lag",lwd=5,main="(e)")

#Função de produção correlação Parcial a série de Capacidade Estática
pacf(diff(log_capa_estatica,dif=2),lag=10,xlab="Lag",main="(f)",lwd=5)

box()

pushViewport(viewport())

grid.lines(y =0.5, x = c(1,0) ,

gp = gpar(col = "black"))

popViewport()

box(lty = 1, col = 'black', which = 'outer')

dev.off()

#Construindo os modelos Capacidade Estática

modelo1_capa_estatica <- holt(capa_estatica,h=6)

modelo2_capa_estatica <- Arima(capa_estatica,order=c(1,2,1),
seasonal=list(order=c(0,2,1),period=4)

```

```

#TESTE DO MODELO 1

summary(modelo1_capa_estatica)

coefptest(modelo1_capa_estatica)

tsdiag(modelo1_capa_estatica,lwd=3)

Box.test(modelo1_capa_estatica$residuals, lag = 1, type = c("Box-Pierce", "Ljung-
Box"), fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo1_capa_estatica=forecast(modelo1_capa_estatica, h=5)

plot(fit_modelo1_capa_estatica,main="", xlab="Ano",ylab= "Produção",col=1,lwd=3)

#TESTE DO MODELO 2

summary(modelo2_capa_estatica)

coefptest(modelo2_capa_estatica)

tsdiag(modelo2_capa_estatica,lwd=3)

Box.test(modelo2_capa_estatica$residuals, lag = 1, type = c("Box-Pierce", "Ljung-
Box"), fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo2_capa_estatica=forecast(modelo2_capa_estatica, h=5)

plot(fit_modelo2_capa_estatica,main="", xlab="Ano",ylab= "Produção",col=1,lwd=3)

#Construindo os modelos para log Capacidade Estática

modelo1_log_capa_estatica <- holt(log_capa_estatica,h=6)

modelo2_log_capa_estatica <- Arima(log_capa_estatica,order=c(0,2,1),
seasonal=list(order=c(1,2,1)))

#TESTE DO MODELO 1

summary(modelo1_log_capa_estatica)

coefptest(modelo1_log_capa_estatica)

tsdiag(modelo1_log_capa_estatica,lwd=3)

Box.test(modelo1_log_capa_estatica$residuals, lag = 1, type = c("Box-Pierce", "Ljung-
Box"), fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo1_log_capa_estatica=forecast(modelo1_log_capa_estatica, h=5)

plot(fit_modelo1_log_capa_estatica,main="", xlab="Ano",ylab=
"Produção",col=1,lwd=3)

```

```

ks.test(modelo1_log_capa_estatica$residuals, "pnorm",
mean(modelo1_log_capa_estatica$residuals),
      sd(modelo1_log_capa_estatica$residuals)) # KS

#TESTE DO MODELO 2

summary(modelo2_log_capa_estatica)

coefstest(modelo2_log_capa_estatica)

tsdiag(modelo2_log_capa_estatica,lwd=3)

Box.test(modelo2_log_capa_estatica$residuals, lag = 1, type = c("Box-Pierce", "Ljung-
Box"), fitdf = 0)#AQUI é o TESTE de Ljung-Box

fit_modelo2_log_capa_estatica=forecast(modelo2_log_capa_estatica, h=5)

plot(fit_modelo2_log_capa_estatica,main="", xlab="Ano",ylab=
"Produção",col=1,lwd=3)

# Testes NORMALIDADE DOS RESIDUOS

ks.test(modelo1_log_capa_estatica$residuals, "pnorm",
mean(modelo1_log_capa_estatica$residuals),
      sd(modelo1_log_capa_estatica$residuals)) # KS

pdf('tsdag_capesta.pdf', height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

tsdiag(modelo2_log_capa_estatica,lwd=5)

box(lty = 1, col = 'black', which = 'outer')

dev.off()

fit_modelo1_log_capa_estatica=forecast(modelo1_log_capa_estatica, h=6)

plot(fit_modelo1_log_capa_estatica,main="", xlab="Ano",ylab=
"Produção",col=1,lwd=3)

fit_m1_log_capa_estatica<-exp(fit_modelo1_log_capa_estatica[["mean"]][c(1:6)])

int95_lower_fit_m1_safra<-exp(fit_modelo1_log_capa_estatica[["lower"]][7:12])

int95_lower_fit_m1_safra<-c(as.vector(rep(NA,39)),as.vector(
int95_lower_fit_m1_safra))

int95_upper_fit_m1_safra<-exp(fit_modelo1_log_capa_estatica[["upper"]][7:12])

```

```

int95_upper_fit_m1_safra<-c(as.vector(rep(NA,39)),as.vector(
int95_upper_fit_m1_safra))

cap_estatica_fit<-
c(as.vector(dados_producao_safra$capa_estatica),as.vector(fit_m1_log_capa_estatica
))

pdf('previsao_capa_estatica.pdf', height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

plot.ts(ts(capa_estatica_fit[1:39],start = 1980, freq=1),main="",

xlab="Ano",ylab= "Toneladas",
col="black",lwd=5,xaxt="n",xlim=c(1980,2025),ylim=c(10000,46000))

lines(ts(capa_estatica_fit[40:45],start = 2019, freq=1),lwd=5,col="blue")

lines(ts(int95_upper_fit_m1_safra[40:45],start = 2019, freq=1),lwd=5,col="gray")

lines(ts(int95_lower_fit_m1_safra[40:45],start = 2019, freq=1),lwd=5,col="green")

legend("topleft", c(expression(paste('Capacidade Estática')),
expression(paste('Previsão da Capacidade Estática')),
expression(paste('+ Intervalo de Confiança 95%')),
expression(paste('- Intervalo de Confiança 95%')) ),

lty=c(1,1,1,1), col=c('black','blue','gray','green'),lwd=c(5,5,5,5))

abline(v=2018, col="gray", lwd=3, lty=2)

axis(1, at = seq(1980,2024,2))

box(lty = 1, col = 'black', which = 'outer')

dev.off()

pdf('Plote_comasprevisoes.pdf', height = 8, width = 14)

par(cex.axis=1.3,cex.lab=1.3,cex.main=1.5)

plot.ts(ts(prod_safra_fit[1:39],start = 1980, freq=1),main="",

xlab="Ano",ylab= "Toneladas",
col="black",lwd=5,xaxt="n",xlim=c(1980,2025),ylim=c(10000,46000))

lines(ts(prod_safra_fit[40:45],start = 2019, freq=1),lwd=5,col="red")

lines(ts(capa_estatica_fit[1:39],start = 1980, freq=1),main="",

```

```
xlab="Ano",ylab= "Toneladas",
col="blue",lwd=5,xaxt="n",xlim=c(1980,2025),ylim=c(10000,60000))

lines(ts(capa_estatica_fit[40:45],start = 2019, freq=1),lwd=5,col="green")

abline(v=2018, col="gray", lwd=5, lty=2)

axis(1, at = seq(1980,2024,2))

legend("topleft",c("Produção de Safra", "Capacidade Estática",'Previsão da Produção
de Safra', 'Previsão da Capacidade Estática' ) ,col=c ('black','blue','red','green'), bty="n",
lwd=c(5,5,5,5) )

box(lty = 1, col = 'black', which = 'outer')

dev.off()
```