

**UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CONTABILIDADE**

ANDRÉ LUIZ BARROS LUCHESI

Simulação computacional para avaliação de cenários econômicos de cultivo agrícola

CASCADEL

2020

André Luiz Barros Luchesi

Simulação computacional para avaliação de cenários econômicos de cultivo agrícola

Dissertação apresentada ao Programa De Pós-Graduação Em Contabilidade (PPGC) da Universidade Estadual do Oeste do Paraná, como requisito parcial para obtenção do grau de Mestre em Contabilidade.

Área de Concentração: Contabilidade
Financeira e Finanças

Orientador: Dr. Jerry Adriani Johann.

Cascavel

2020



Universidade Estadual do Oeste do Paraná

Campus de Cascavel CNPJ 78680337/0002-65
Rua Universitária, 2069 - Jardim Universitário - Cx. P. 000711 - CEP 85819-110
Fone:(45) 3220-3000 - Fax:(45) 3324-4566 - Cascavel - Paraná



PARANÁ
GOVERNO DO ESTADO

ANDRÉ LUIZ BARROS LUCHESI

Simulação computacional para avaliação de cenários econômicos de cultivo agrícola

Dissertação apresentada ao Programa de Pós-Graduação em Contabilidade em cumprimento parcial aos requisitos para obtenção do título de Mestre em Contabilidade, área de concentração Controladoria, linha de pesquisa Contabilidade Financeira e Finanças, APROVADO(A) pela seguinte banca examinadora:

Orientador(a) - Jerry Adriani Johann

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Maria Piedade Araújo

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Darlón Vasata

Instituto Federal do Paraná - Cascavel (IFPR)

Cascavel, 6 de fevereiro de 2020

AGRADECIMENTOS

À minha família, que perante todas as dificuldades estiveram ao meu lado me incentivando a não desistir desta etapa acadêmica.

Ao Professor Doutor Jerry Adriani Johann, meu orientador, pela paciência e sabedoria na condução das orientações para o desenvolvimento desta pesquisa.

Ao Professor Doutor André Luiz Brun, pelos ricos apontamentos na banca de qualificação, dedicando ao trabalho uma perspectiva construtiva.

À Professora Doutora Maria da Piedade Araújo, pelo carinho concedido à pesquisa, tanto na banca de qualificação quanto na banca de defesa, aos vários ensinamentos em econometria e demais áreas afins, cujos os direcionamentos nos permitiram a enxergar melhor o percurso a ser trilhado neste estudo.

Ao Professor Doutor Darlon Vasata, por ter aceitado participar na banca de defesa, foi uma honra tê-lo em minha banca.

Aos Professores do Programa de Pós-Graduação em Contabilidade – PPGC, da Universidade Estadual do Oeste do Paraná – UNIOESTE e aos meus colegas e alunos do Mestrado, pela parceria e o compartilhamento de novos conhecimentos ao longo dessa caminhada.

Enfim, agradeço a todos aqueles que contribuíram de alguma forma para a realização deste trabalho, meus sinceros agradecimentos.

RESUMO

Luchesi, A. L. B. (2020). *Simulação computacional para avaliação de cenários econômicos de cultivo agrícola*. Dissertação de Mestrado, Universidade Estadual do Oeste do Paraná, Cascavel, PR, Brasil.

O Brasil é um dos grandes produtores e exportadores de *commodities*, em especial a soja e o milho. Esse segmento, tem grande influência na economia internacional e nacional, por serem as principais *commodities* agrícolas comercializadas no mundo. No entanto, devido à globalização e outros aspectos inerentes ao agronegócio, a agricultura se tornou uma atividade que apresenta vários riscos e incertezas, influenciando diretamente na rentabilidade do empreendimento. Diante disso, torna-se fundamental a utilização de ferramentas para avaliar e minimizar os riscos. Nessa perspectiva, a presente pesquisa teve como objetivo desenvolver uma ferramenta computacional para simular cenários econômicos para o cultivo da soja e do milho, a fim de auxiliar o produtor na tomada de decisão. Para isso, foram desenvolvidos modelos de previsão de preços por meio de duas técnicas distintas, ARIMA e redes neurais artificiais. As previsões e outras informações coletadas foram consolidadas em um único sistema no qual realizou várias simulações de cenários econômicos que foram analisados por meio de indicadores econômico-financeiros e de risco. Verificou-se que os modelos de previsão de preços com uso de redes neurais artificiais foram mais precisos e apresentaram um bom desempenho preditivo com MAPE entre 1,5% a 4% e índice de concordância Willmott entre 95% a 99%. Quanto aos cenários simulados, concluiu-se que o cultivo da soja possui uma lucratividade maior, com menor chance de obter prejuízos, se comparado ao cultivo do milho. Além disso, observou-se que as estratégias de gerenciamento de risco se demonstraram eficientes, reduzindo os riscos, sem comprometer a lucratividade do empreendimento. O diferencial e a principal contribuição desta pesquisa foi o desenvolvimento de um sistema computacional para simulação de cenários econômicos do cultivo da soja e do milho, ferramenta que demonstrou ser de grande relevância, pois permite ao gestor estimar os lucros de cada cultivo e mensurar os riscos financeiros envolvidos, além de avaliar o impacto da utilização de estratégias de gerenciamento de risco. Todo esse conjunto de informações auxilia, de forma significativa, os gestores na tomada de decisão.

Palavras-chave: Simulação de cenários econômicos; Modelos de previsão de preços; Redes neurais artificiais.

ABSTRACT

Luchesi, A. L. B. (2020). *Computer simulation for the evaluation of agricultural cultivation economic scenarios*. Dissertation (Master's in Accounting), Western Paraná State University, Cascavel, PR, Brazil.

Brazil is one of the biggest commodities' producers and exporters, especially, regarding soybeans and corn. This segment has great influence on the international and national economy, as they are the main agricultural commodities traded in the world. However, due to globalization and other aspects inherent to agrobusiness, the agriculture has become an activity which presents several risks and uncertainties, influencing directly in the profitability of the enterprise. Facing that, the usage of tools to assess and minimize the risks is fundamental. In this view, this research aimed to develop a computational tool to simulate economic scenarios for the cultivation of soybeans and corn, in order to assist the producer in the decision-making task. For this, price forecasting models were developed using two different techniques, ARIMA and artificial neural networks. The forecasts and other information collected were consolidated into a single system which performed several simulations of economic scenarios which were analyzed using economic-financial and risk indicators. We found out that the models of price forecast using artificial neural networks were more accurate and presented a good predictive performance with MAPE between 1.5% and 4% and Willmott agreement index between 95% and 99%. Regarding the simulated scenarios, we concluded that the cultivation of soybeans has larger profitability with fewer chances of obtaining losses, when compared to the cultivation of corn. Besides that, it was observed that the risk management strategies proved themselves efficient, reducing the risks without compromising the profitability of the enterprise. The differential and the main contribution of this research was the development of a computer system for simulating economic scenarios of soybeans and corn cultivation, such tool showed great value as it allows the manager to estimate the profits of each cultivation and also to measure the financial risks involved, beyond assessing the impact of the usage of risk management strategies. All this group of information meaningfully supports the managers in the decision-making task.

Keywords: Economic scenarios simulation; Price forecast models; Artificial neural networks.

LISTA DE FIGURAS

Figura 1 – Série histórica produção/consumo mundial de soja e milho.....	26
Figura 2 – Série histórica do preço da tonelada de soja e milho na bolsa de Chicago	26
Figura 3 – Modelo não linear de um neurônio artificial	48
Figura 4 – Exemplo de arquitetura de uma rede neural artificial	49
Figura 5 – Diagrama de etapas do trabalho.....	58
Figura 6 – Geração dos cenários pessimista, realista e otimista	66
Figura 7 - Cenários econômicos da soja sem Gerenciamento de Risco	79
Figura 8 - Cenários econômicos da soja com seguro ProAgro e Barter	79
Figura 9 - Cenários econômicos da soja com seguro ProAgro e venda antecipada PreFixada	80
Figura 10 - Cenários econômicos do milho sem Gerenciamento de Risco	83
Figura 11 - Cenários econômicos do milho com seguro ProAgro e Barter	83
Figura 12 - Cenários econômicos do milho com seguro ProAgro e venda antecipada PreFixada	84
Figura 13 - Tela inicial do sistema	86
Figura 14 - Cadastro de custos de Produção.....	87
Figura 15 - Série Histórica.....	88
Figura 16 – Previsões.....	89
Figura 17- Configuração da simulação de cenários econômicos.....	90
Figura 18 - Resultados simulação de cenários econômicos.....	91
Figura 19 Análise Ljung-Box Arima (4,1,2) Soja Mensal.....	101
Figura 20 Análise Ljung-Box Arima (5,2,3) Soja Bimestral	101
Figura 21 Análise Ljung-Box Arima (3,2,1) Soja Trimestral.....	102
Figura 22 Análise Ljung-Box Arima (2,1,2) Milho Mensal	102
Figura 23 Análise Ljung-Box Arima (4,2,3) Milho Bimestral.....	103
Figura 24 Análise Ljung-Box Arima (3,2,4) Milho Bimestral.....	103

LISTA DE TABELAS

Tabela 1 – Indicadores econômicos, financeiros e de risco.....	37
Tabela 2 – Dados de entrada para os modelos RNAs	63
Tabela 3 – Estratégias de gerenciamento de riscos	68
Tabela 4 – Modelos selecionados de acordo com os valores de AIC e BIC.....	71
Tabela 5 – Estatísticas de erro dos modelos ARIMA	73
Tabela 6 – Topologia dos modelos RNAs	74
Tabela 7 – Resultados modelos RNA validação cruzada	75
Tabela 8 – Resultados modelos RNAs com validação dois-passos-a-frente	76
Tabela 9 – Operações de gerenciamento de risco para o cultivo da soja	81
Tabela 10 – Operações de gerenciamento de risco para o cultivo do milho	85
Tabela 11 – Cenários Econômicos para a soja entre 2015 a 2019	106
Tabela 12 – Cenários Econômicos para o milho entre 2015 a 2019	109

SUMÁRIO

1	INTRODUÇÃO	11
1.1	PROBLEMA DE PESQUISA	13
1.2	OBJETIVOS	14
1.2.1	Geral	14
1.2.2	Específicos.....	14
1.3	JUSTIFICATIVA E CONTRIBUIÇÃO DO ESTUDO	15
1.4	DELIMITAÇÃO DA PESQUISA.....	15
1.5	ESTRUTURA DO TRABALHO	16
2	REFERENCIAL TEÓRICO	18
2.1	MERCADO DE COMMODITIES	18
2.1.1	Bolsa.....	20
2.1.2	Tipos de Mercado de <i>Commodities</i>	21
2.1.3	Participante do Mercado	23
2.1.4	Mercado da Soja e Milho.....	24
2.2	GESTÃO DE RISCOS NO AGRONEGÓCIO	27
2.2.1	Operações no Mercado para o Gerenciamento de Riscos	30
2.3	PLANEJAMENTO ESTRATÉGICO.....	34
2.3.1	Planejamento Orçamentário	35
2.3.2	Análise de Investimentos.....	36
2.4	SIMULAÇÃO DE CENÁRIOS	39
2.4.1	Método de Monte Carlo.....	41
2.5	MODELO DE PREVISÃO DE PREÇOS	42
2.5.1	Modelo Autorregressivo Integrado e de Médias Móveis - ARIMA.....	43
2.5.2	Redes Neurais Artificiais - RNA	46
2.5.3	Critérios de Seleção e Validação de Modelos	53
3	METODOLOGIA.....	57
3.1	DELINEAMENTO DA PESQUISA	57
3.2	ETAPAS DE DESENVOLVIMENTO DO TRABALHO.....	57
3.3	COLETA DE DADOS.....	60
3.4	MODELAGEM DE DADOS	61

3.4.1	Modelagem ARIMA.....	61
3.4.2	Modelagem RNA.....	62
3.5	SIMULAÇÃO DE CENÁRIOS	65
3.6	ESPECIFICAÇÃO DO SISTEMA COMPUTACIONAL	68
4	ANÁLISE E DISCUSSÃO DOS RESULTADOS	70
4.1	MODELOS DE PREVISÃO DE PREÇOS	70
4.1.1	ARIMA.....	71
4.1.2	REDES NEURAIS ARTIFICIAIS	74
4.2	CENÁRIOS ECONÔMICOS	77
4.2.1	Soja.....	78
4.2.2	Milho	82
4.3	SISTEMA COMPUTACIONAL.....	85
5	Conclusão	92
	REFERÊNCIAS	94
	APÊNDICE 1 – ANÁLISE DE RESÍDUOS MODELOS ARIMA	101
	APÊNDICE 2 – CENÁRIOS ECONÔMICOS	104

1 INTRODUÇÃO

O agronegócio brasileiro cumpre um importante papel na economia nacional. Segundo pesquisa realizada pela Confederação Nacional da Agricultura e Pecuária (CNA), em 2018, o setor foi responsável por 21,1% do PIB do país, sendo o principal setor nas exportações contabilizando mais de 100 bilhões de dólares, o que representa 42% do total do valor exportado em mercadorias.

O Brasil é um dos grandes produtores e exportadores de *commodities*, em especial o milho e a soja. Esse segmento tem grande influência na economia internacional, por serem as principais *commodities* agrícolas comercializadas no mundo, devido a vasta utilização desses cereais nos mais variados fins, que vão desde a alimentação (animal e humana) até a indústria que a utiliza como matéria prima (Menezes, 2015).

Segundo dados da Companhia Nacional de Abastecimento (CONAB), em 2018, o Brasil foi o segundo maior produtor mundial de soja, produzindo cerca de 115 milhões de toneladas, enquanto os Estados Unidos, maior produtor, obteve 123 milhões de toneladas de soja. Na produção de milho o país ocupa a terceira posição com produção de 100 milhões toneladas, precedido apenas dos Estados Unidos e China os quais produziram aproximadamente 366 e 220 milhões de toneladas, respectivamente.

No entanto, devido à globalização e outros aspectos inerentes ao agronegócio, a agricultura se tornou uma atividade que apresenta vários riscos e incertezas, principalmente associados a fatores climáticos, mercadológicos e conjunturais. Tais riscos influenciam diretamente na rentabilidade e causam incertezas aos agricultores e aos demais participantes dessa cadeia de produção (Martins & Martinelli, 2010). Devido à complexidade e os riscos envolvidos, torna-se fundamental o desenvolvimento de ferramentas para minimizar os riscos e subsidiar a tomada de decisão.

O avanço tecnológico das últimas décadas proporcionou o desenvolvimento de várias técnicas para otimizar ou auxiliar as atividades agrícolas. Dentre elas, destacam-se, os

equipamentos e maquinários agrícolas, agrotóxicos, fertilizantes químicos, melhoramento genético e a moto-mecanização (Teixeira, 2005).

Existe um conjunto de técnicas matemáticas que podem ser empregadas com o objetivo de auxiliar o planejamento e subsidiar a tomada de decisão no contexto agrícola, dentre elas, destacam-se os modelos matemáticos de previsão de preços de *commodities*, os modelos de simulação de crescimento e desenvolvimento das culturas, modelos de simulação de cenários.

Segundo Bressan e de Lima (2009), os modelos de previsão de séries temporais univariadas podem ser utilizados para reduzir a incerteza no processo de tomada de decisões econômicas. A possibilidade de “prever” o preço de *commodities* é de grande relevância para os participantes do mercado agrícola, sejam eles compradores, vendedores ou especuladores, pois eles baseiam suas decisões em expectativas de preços (Ribeiro, Sosnoski, & Oliveira, 2010).

Os estudos de Lima, Góis e Ulises (2007), Ceretta, Righi e Schlender (2010), Ribeiro et al. (2010) e Ferreira, de Moura, Borenstein e Fischmann (2011) utilizaram modelos de séries temporais para a previsão de preços no contexto agrícola, concluindo que esta técnica fornece resultados relevantes, contribuindo no processo de tomada de decisão dos gestores rurais.

Além disso, a elaboração de cenários futuros tem sido cada vez mais utilizada no planejamento estratégico das empresas e empreendimentos agrícolas. Através da análise dos cenários futuros é possível avaliar riscos e viabilidades, desenvolver planos de ação a fim de aproveitar um ambiente favorável ou se precaver em projeções de cenários negativos. Uma das formas de projetar e analisar cenários futuros é por meio de modelos de simulação.

A simulação é o processo de projetar um modelo computacional de um sistema real e conduzir experimentos com este modelo com o propósito de entender seu comportamento e/ou avaliar estratégias para sua operação (Pegden, Shannon, & Sadowski, 1990).

A utilização da técnica de simulação de cenários permite um planejamento mais eficiente e de menor risco, considerando simultaneamente um conjunto de decisões alternativas e informações comportamentais dos eventos que compõem as operações em questão.

Ferramentas analíticas de planejamento com simulação estão cada vez mais presentes nos processos de tomada de decisão.

No entanto, especialmente nos países em desenvolvimento, a aplicação desta tecnologia no meio agrícola ainda é insipiente, seja por falta de informação e orientação técnica, ou pela dificuldade de acesso a ferramentas que ofereçam esses recursos tecnológicos de forma simplificada (BUAINAIN, VIEIRA, & CURY, 2011).

Porém, acredita-se que a utilização desses recursos tecnológicos no contexto agrícola irá auxiliar o gestor no processo de tomada de decisão, otimizando processos e obtendo maior retorno econômico com menor risco (BUAINAIN et al., 2011).

1.1 PROBLEMA DE PESQUISA

O atual cenário agrícola caracteriza-se pela globalização dos mercados, o crescente uso de novas tecnologias e pela democratização da informação e conhecimento, aumentando a competitividade do setor. Diante deste cenário, fatores como produtividade, custos de produção e lucratividade devem ser analisados e controlados. Este entendimento está em consonância com a necessidade de incorporar práticas que maximizem o uso da tecnologia e otimizem os processos agrícolas, visando obter maior produtividade por unidade de área ao menor custo e, conseqüente, maior retorno econômico advindo da produção.

Além disso, uma das características marcantes do agronegócio é a magnitude e natureza dos riscos. Os riscos mais significativos estão relacionados a variações na produtividade em função de fatores climáticos ou biológicos e as oscilações de preços das *commodities* agrícolas. Diante disso, torna-se necessário uma gestão de riscos eficiente.

No entanto, o produtor rural encontra dificuldades para prever e analisar a viabilidade, a rentabilidade e os riscos envolvidos nos diferentes cultivos de grãos, pois, na maioria das vezes, o produtor não possui informações pertinentes à atividade agrícola como, por exemplo, estimativas de safra, preço, rentabilidade e riscos de uma determinada cultura. A ausência dessas informações dificulta a seleção da cultura de melhor custo-benefício ao menor risco.

Além disso, dificulta a elaboração de estratégias para minimizar os riscos como, por exemplo, definir a data de semeadura que apresente a menor probabilidade de escassez ou excesso de precipitação, ou ainda o acesso a procedimentos de proteção a oscilações de produtividade de safra e preços como a contratação de seguros agrícolas, venda antecipada da safra, entre outros.

Neste sentido, torna-se relevante o desenvolvimento de ferramentas que forneçam essas estimativas e possibilitem ao produtor, analisar a projeção de diferentes cenários econômicos dos principais grãos cultivados no Brasil, subsidiando as decisões no planejamento das atividades agrícolas, a fim de obter maior rentabilidade ao menor risco.

1.2 OBJETIVOS

1.2.1 Geral

O objetivo geral do trabalho foi desenvolver cenários econômicos para o cultivo da soja e do milho por meio de uma ferramenta computacional, a fim de auxiliar o produtor na tomada de decisão.

1.2.2 Específicos

- Desenvolver modelos de previsão de preços para as *commodities* de soja e milho utilizando as técnicas de Modelos Autorregressivos Integrados e de Médias Móveis (ARIMA) e Redes Neurais Artificiais (RNA);
- Analisar e comparar o desempenho preditivo dos modelos testados e selecionar o melhor para integrá-lo ao sistema computacional;
- Desenvolver uma ferramenta computacional para consolidar as informações referentes às estimativas de produtividade, previsões de preços e custo de produção das culturas de soja e milho, para gerar simulações de cenários econômicos.

1.3 JUSTIFICATIVA E CONTRIBUIÇÃO DO ESTUDO

O setor agrícola é de fundamental importância para a economia do Brasil, sendo a soja e o milho os grãos mais cultivados no país. No entanto, ainda há poucas ferramentas que auxiliem os gestores no processo de tomada de decisão possibilitando a otimização de recursos, aumentando a rentabilidade e minimizando os riscos.

Uma ferramenta computacional que faça simulações de cenários econômicos para os cultivos de soja e milho permite aos gestores realizar um planejamento mais eficiente como, por exemplo, elaborar ações para evitar ou minimizar os riscos nos cenários pessimistas e ações para maximização dos resultados em cenários otimistas, além de prover estimativas de lucratividade e risco. Desta forma, a simulação de cenários para o planejamento subsequente configura vantagem competitiva e aproxima gestores da fronteira da eficiência.

Outro fato relevante é que não há estudos presentes na literatura que utilizem modelos de previsão de preços de *commodities* de forma integrada a uma ferramenta computacional para simulação de cenários econômicos na produção agrícola.

1.4 DELIMITAÇÃO DA PESQUISA

Este trabalho restringe-se ao estudo de duas *commodities*, a soja e milho, devido à grande importância que esses dois grãos exercem na economia brasileira e mundial.

Devido as diferenças de produtividade, custos de produção, valor do prêmio de exportação entre as diversas regiões do Brasil, as simulações de cenários econômicos para o plantio de soja e milho foram desenvolvidas apenas para a região oeste do Paraná - referência nacional na produção e produtividade desses grãos.

Quanto aos modelos de previsão de preços, a presente pesquisa apenas utilizou-se de duas técnicas: a modelagem ARIMA e a RNA. Não são utilizados quaisquer outros tipos de modelos como modelos ARFIMA-GARCH, EWMA ou de volatilidade estocástica, nem mesmo modelos multivariados.

Além disso, vale frisar que a pesquisa desenvolveu apenas modelos de previsão de preços da soja e do milho para a bolsa de Chicago (CBOT). As demais estimativas e previsões utilizadas (dólar, produtividade e prêmio de exportação) foram obtidas de terceiros como o Banco Central do Brasil (BACEN) ou geradas por uma média histórica.

1.5 ESTRUTURA DO TRABALHO

O capítulo introdutório do presente trabalho compreende a contextualização do tema, os argumentos que sustentam o problema de pesquisa, os objetivos gerais e específicos do estudo, bem como a justificativa da realização e as contribuições esperadas.

No segundo capítulo, aborda-se o referencial bibliográfico, o qual dá base à realização do estudo. Inicialmente são apresentados aspectos referentes ao mercado de *commodities* em especial o mercado da soja e milho, os riscos envolvidos neste tipo de empreendimento e a gestão dos mesmos. Em seguida, apresentam-se os conceitos de planejamento estratégico e orçamentário, análise de investimentos e simulação de cenários na tomada de decisão. Posteriormente, aborda-se a fundamentação teórica da modelagem matemática utilizada na pesquisa, detalhando conceitos de modelo de séries temporais para a previsão de preços de *commodities* agrícolas, bem como o modelo ARIMA e redes neurais artificiais.

O terceiro capítulo, por sua vez, traz os aspectos metodológicos do trabalho, envolvendo a apresentação das variáveis do estudo, o modelo teórico, a fonte e o tratamento dos dados, os procedimentos de análises, como as técnicas estatísticas definidas e os modelos matemáticos utilizados. O processo de integração de informações e a especificação do sistema computacional proposto, além de apresentar o conjunto de etapas a serem seguidas para alcançar os objetivos propostos neste trabalho.

No quarto capítulo são analisados e discutidos os resultados obtidos por meio da modelagem matemática proposta na pesquisa. Além disso, são discutidos os resultados gerados das simulações dos cenários econômicos para o cultivo da soja e milho nos últimos cinco anos.

Por fim, no quinto capítulo, são apresentadas as considerações finais da pesquisa.

2 REFERENCIAL TEÓRICO

O referencial teórico apresenta temas relacionados ao mercado de *commodities*, em especial as agrícolas, a gestão de risco no agronegócio, o planejamento estratégico, bem como, planejamento orçamentário e análise de investimentos.

Além disso, aborda métodos estatísticos para simulação de cenários econômicos e para a previsão de preços, por meio das técnicas de redes neurais artificiais e modelos econométricos.

2.1 MERCADO DE COMMODITIES

O termo *commodity* vem do inglês e expressa “um artigo em comércio” (Williamson, 1989). O Novo Dicionário de Economia define como sendo um tipo particular de mercadoria em estado bruto ou produto primário de importância comercial (Sandroni, 1994). Desta forma, define-se uma *commodity*, como uma mercadoria padronizada, de baixo valor agregado, produzida por diferentes produtores e comercializada em nível mundial, no qual, os preços são definidos pelo mercado (Matias, Silva, & Vieira, 2005).

Além disso, grande parte das *commodities* são mercadorias que podem ser estocadas por um determinado período de tempo sem que haja perda de qualidade. Essas características fazem do mercado de *commodities* um mercado extremamente competitivo. Devido à sua padronização, não importa de qual vendedor irá comprar, já que os produtos não apresentam diferenciação; desta forma, a decisão de compra se dá em função do preço. Vale ressaltar, que esse tipo de mercadoria é utilizada como matéria prima para vários produtos, sendo de fundamental importância para os países no mundo (Castro, 2002).

Existem vários tipos de *commodities* e podem ser classificadas em quatro tipos básicos. As *commodities* financeiras: moedas (dólar, euro, libra, etc.), títulos públicos de governos federais, ações de empresas e etc. *Commodities* minerais: minério de ferro, alumínio, petróleo, ouro, níquel, prata e etc. *Commodities* agrícolas: incluem os produtos provenientes do agronegócio, por exemplo, soja, milho, café, trigo, açúcar, etc. *Commodities* ambientais:

englobam diversos recursos naturais como a madeira, créditos de carbono, energia, etc. (I. Ferreira, 2016).

Os mercados de *commodities*, assim como os mercados de capital, ações, estão sujeitos às leis econômicas de oferta e demanda quando o assunto é a precificação dos produtos negociados. Tal relação é um dos principais fatores que norteia a precificação das *commodities*. A teoria neoclássica da oferta e demanda, criada por Alfred Marshall (1890), em sua obra *Principles of Economics*, afirma que o preço de um bem é determinado pela relação de oferta e demanda deste.

Este mercado possui natureza cíclica, o que significa que a produção é estimulada ou desestimulada de acordo com o preço. Se o preço de algum produto estiver alto, diversos produtores se sentirão “estimulados” a produzi-lo. No entanto, se há um grande volume em estoque ou ocorre uma alta produção, haverá uma diminuição no preço devido ao aumento na oferta, desestimulando a sua produção, conseqüentemente, reduzindo os estoques que por sua vez, fará com que o preço volte a subir. Vale ressaltar que não há uma tendência eterna de alta ou baixa, mas sim, ciclos. Por este motivo as *commodities* são consideradas cíclicas (Nehmi, 2012).

Nas *commodities* agrícolas, como a soja e o milho, existem vários fatores que influenciam na oferta e demanda e, conseqüentemente, no preço do produto. O crescimento populacional e aumento da renda per capita de países emergentes, como China e Índia, são os principais motivos para o aumento do consumo dessas mercadorias, devido a vasta utilização como matérias primas para a produção industrial, na produção de proteína animal e no consumo alimentício da população (Arruda, 2008).

Além disso, a crescente utilização desses grãos na produção de etanol e outros biocombustíveis contribuem de forma significativa na demanda por essas *commodities* (Nascimento, 2008). Por outro lado, condições climáticas tais como, temperatura, precipitação, geada, granizo, entre outros, impactam de forma significativa na produção, seja de forma positiva ou negativa alterando a oferta desses produtos no mercado mundial.

Devido à vasta abrangência deste mercado e o grande volume de operações, é necessária uma estrutura organizacional eficiente para gerenciá-lo, estabelecendo regras, fornecendo local, equipamento e pessoal adequados ao amparo das transações comerciais. Essa estrutura organizacional é denominada de Bolsa (Santos, 1993).

2.1.1 Bolsa

Conceitua-se como Bolsa o lugar no qual se concentram propostas de oferta e de procura, de bens e/ou direitos, com o intuito de viabilizar a realização de transações comerciais, estabelecendo, por consequência, o preço. A bolsa é o local no qual se concentram as propostas de oferta e procura de bens e ou direitos, com o intuito de contribuir para que os participantes realizem transações comerciais com total transparência entre as partes (Santos, 1993).

Existem vários tipos de bolsas, sendo as principais: bolsa de valores e bolsa de mercadorias. Na bolsa de valores são negociados títulos financeiros como ações de empresas, enquanto que na bolsa de mercadorias são negociadas as *commodities* (Stolf, 1992).

Todas as bolsas são associações de seus membros. Elas não compram ou vendem mercadorias, nem determinam os preços (Castro, 2002). Seu objetivo principal é regulamentar e normatizar o mercado, provendo informações e as divulgando de forma transparente ao público, bem como seus preços e demais condições garantindo, assim, um mecanismo adequado à formação do preço (Santos, 1993).

Como o mercado de *commodities* é padronizado, possibilita a estocagem das mercadorias e tem preço determinado pelo mercado internacional, as mercadorias são facilmente negociadas em bolsas, tanto no mercado à vista quanto de contratos futuros. Por isso, ao longo dos séculos, surgiram importantes bolsas de mercadorias que são essenciais para o mercado atual de *commodities* como as bolsas de Chicago (CBOT), de Nova Iorque (NYMEX e NYBOT) e de Londres (LIFFE e LME) (Hull, 1995).

No Brasil, a Bolsa de valores e mercadorias é a Brasil, Bolsa e Balcão (B3). A B3 surgiu após a fusão da Bolsa de Valores, Mercadorias e Futuros de São Paulo

(BM&FBOVESPA) com a Central de Custódia e de Liquidação Financeira de Títulos (CETIP), aprovada pela Comissão de Valores Mobiliários (CVM) e pelo Conselho Administrativo de Defesa Econômica (CADE) em 22 de março de 2017.

A B3 negocia diversos ativos e derivativos, dentre eles, as *commodities* como, milho, soja, álcool, boi gordo e café. Elas são negociadas com contratos específicos que determinam prazos de vencimento, quantidades e valores mínimos.

2.1.2 Tipos de Mercado de *Commodities*

O mercado de *commodities* está segmentado e as mercadorias podem ser negociadas em diversos tipos: no mercado físico (ou mercado disponível), no mercado a termo, no mercado de futuro ou no mercado de opções (Pereira, 2009; Stolf, 1992).

O mercado físico consiste basicamente na troca de produto físico por dinheiro, no qual são realizadas operações de compra e venda para liquidação física. Corresponde ao mercado de entrega efetiva, em que se estabelece um contrato bilateral irrevogável que pode determinar liquidação imediata ou futura (Stolf, 1992).

O mercado a termo é o mais simples dos mercados de derivativos. São operações de compra e venda para liquidação ao final de um determinado prazo ou, antecipadamente, por solicitação do comprador, ou seja, as duas partes se comprometem a comprar e vender determinado ativo em uma data futura. Desta forma, quando um investidor compra a termo uma determinada mercadoria, firma-se um contrato de “compra e venda” com data, preço, quantidade e qualidade pré-definidos (Aguilar, 2014; Stolf, 1992). Vale ressaltar, que no mercado a termo são realizados negócios para entrega futura, mas com definição atual de valor. Este tipo de operação pode ser considerado uma forma de tanto o vendedor como o comprador eliminarem o risco de flutuação indesejada no preço.

Da evolução dos contratos a termo resultou na formação dos mercados de futuros. Neste, são realizadas operações de compra e venda para liquidação em data futura. Assim como no mercado a termo, toda operação estabelece um contrato com data e quantidade definidos, com

exceção do preço, o qual é determinado pela oferta e pela demanda (ordens de venda ou de compra em bolsa). Desta forma, as posições assumidas sofrem ajustes diários de preços e podem ser liquidadas ou por diferença antes do seu vencimento ou por entrega física (Pereira, 2009; Stolf, 1992).

O contrato futuro é padronizado e negociado em bolsa com ajustes diários. Um contrato futuro pode ser genericamente descrito como um acordo realizado em uma data inicial entre as partes para trocar, em uma data futura, uma dada quantidade de uma *commodity* por uma determinada quantia de uma moeda. Além de assegurar preços para produtores, o contrato futuro é um facilitador para a negociação de *commodities* como instrumentos financeiros. Este mercado pode ser ampliado para outros tipos de investidores que desejam tomar posições sobre ele, como fundos de investimentos, tesourarias de *commodities* e qualquer outro tipo de atores do mercado (Aguiar, 2014).

Além disso, no mercado de futuro não há a obrigação de entrega física da mercadoria, diferentemente do contrato a termo. De forma geral, um contrato futuro não é elaborado com a intenção de efetivar a entrega, mas sim procurar sair de suas posições efetuando uma operação oposta (Santos, 1993). Ao efetuarem um contrato futuro, as duas partes estabelecem um preço para a mercadoria no futuro. Se o preço no futuro for exatamente o que foi negociado, ninguém sai ganhando e nem perdendo. Se o preço no futuro for diferente do que foi contratado, um dos dois irá perder e o outro, irá ganhar. Logo, existe um processo de transferência de risco neste mercado.

Existem outras variações de Contratos Futuros em mercadorias conhecidas como "opções". No mercado de opções, não se negociam as mercadorias, mas o direito sobre elas. Desta forma, toda operação efetuada firma-se um contrato garantindo o direito de compra ou venda de um determinado produto, com preços e prazos de exercícios pré-estabelecidos (Stolf, 1992). Neste mercado, o contrato de opção garante o direito sem que haja a obrigação de comprar ou vender a mercadoria. Este direito pode ser exercido a qualquer momento dentro de um prazo de tempo definido previamente. O titular somente irá exercer a opção, se o preço do mercado físico for superior ao preço estipulado na opção, pois ele pode exercer a opção pagando

um preço menor e vender a mercadoria no mercado a um preço maior, obtendo lucro (Santos, 1993).

Este mercado é considerado uma alternativa relevante para investimento e *hedge*, em virtude de sua flexibilidade, possibilitando estabelecer expectativas específicas para o retorno do investimento. Desta forma, ao comprar uma opção, o investidor estará se protegendo contra preços desfavoráveis, mas, ao mesmo tempo, poderá aproveitar-se de mudanças favoráveis nos preços (Rodrigues & Cunha, 2013).

2.1.3 Participante do Mercado

O mercado de derivativos de *commodities* permite que seus participantes atuem com objetivos distintos, produtores podem utilizá-lo para proteger-se contra oscilações do preço de venda, enquanto que a indústria as quais utilizam *commodities* como matéria prima pode utilizar o mercado para fixar o preço de seus insumos. Outros participantes, especialistas na formação de preços, podem utilizar o mercado com o intuito de fazer lucros com as oscilações nos preços. Neste mercado há dois tipos principais de participantes: os *hedgers* e os especuladores (Pereira, 2009).

A palavra *hedge*, em inglês, significa proteção. No contexto do mercado de *commodities* este termo pode ser entendido como uma estratégia de gerenciamento de risco que tem por objetivo mitigar os riscos provocados por oscilações de preços. Como os preços do mercado físico e do mercado futuro tendem a oscilar paralelamente, o investidor toma posições iguais e opostas nos dois mercados, esperando que a oscilação adversa em um seja aproximadamente compensada por uma oscilação de preço correspondente no outro (Rodrigues Capelletto, Lima de Oliveira, & Carvalho, 2007; Stolf, 1992).

Desta forma, os investidores os quais utilizam este procedimento são denominados *hedgers*. Este participante consiste de pessoas jurídicas (individual, coletiva ou acionária), como por exemplo, produtores, cooperativas, comerciantes, exportadores, importadores, fundidores, beneficiadores, entre outros.

Hedger é o participante que atua basicamente no mercado de futuros para proteger-se contra a volatilidade dos preços das *commodities*. O intuito principal deste participante é o de gerenciar o risco, assegurando o preço para uma determinada mercadoria ou ativo financeiro negociado em Bolsa (Stolf, 1992).

Define-se especulador como um investidor que se dispõe a assumir um risco, em contrapartida, a uma expectativa de ganho. É o indivíduo que transaciona contratos futuros com o objetivo de auferir lucro através de uma antecipação bem sucedida do movimento dos preços. Em síntese, é o especulador que proporciona ao *hedger* a oportunidade de transferência de risco, conferindo liquidez ao mercado. Quando a presença dos especuladores não é sentida no mercado, os *hedgers* só conseguem negociar entre si, restringindo as oportunidades de transferência de riscos em decorrência da maior volatilidade dos preços; diz-se, então, que o mercado é estreito (Stolf, 1992).

No Brasil os participantes do mercado de *commodities* atuam principalmente na negociação de mercadorias agrícolas e minerais, destacando-se a soja e milho. Neste sentido, obter informações e compreender a conjuntura deste mercado torna-se fundamental.

2.1.4 Mercado da Soja e Milho

O Brasil é um país que produz e exporta diversas *commodities*, principalmente as minerais e agrícolas. As *commodities* agrícolas têm crescido exponencialmente nos últimos anos, fazendo com que o país seja um dos maiores produtores e exportadores de produtos agrícolas, dentre eles, cabe destacar a soja e o milho.

A soja é uma das principais oleaginosas cultivadas no mundo. Ela contém um alto teor de óleo, proteína e ácidos graxos, devido à sua qualidade nutricional. É utilizada em diversos segmentos, bem como, na alimentação humana e animal, na produção de óleo e biocombustíveis, entre outras utilidades industriais, gerando uma grande demanda mundial (Bellaloui et al., 2013; Boerma & Specht, 2004).

A cultura do milho é uma das mais importantes dentro do cenário de produção agropecuária no mundo, devido à sua vasta utilização no processo de nutrição animal. É o cereal mais consumido pelos setores de aves e suínos, sendo também muito utilizada na indústria alimentícia e de bebidas para consumo humano, além de ser uma importante matriz energética na produção de biocombustíveis, como o etanol. Por essas razões, a produção deste cereal é de grande importância na balança comercial de muitos países. Atualmente, o milho é o grão mais produzido no mundo, sendo responsável por 42% de todos os grãos produzidos, seguido pelo trigo (30%), e arroz (18%) (CONAB, 2017).

A soja e o milho estão entre os principais grãos cultivados no mundo, fazendo parte do conjunto de atividades agrícolas com maior destaque no mercado mundial. Este mercado é baseado essencialmente na Lei Geral da Oferta e da Demanda, na relação entre preço e a quantidade de oferta e demanda do produto, e nas relações comerciais entre os países produtores-exportadores e países consumidores-importadores.

De acordo com os dados do Departamento de Agricultura dos Estados Unidos (USDA), a demanda mundial por estes cereais (soja e milho) praticamente duplicou entre o período de 1999 a 2017. O consumo do milho teve um aumento de 79% e a soja de 116% nesse período. Há uma tendência que o aumento da demanda por esses grãos se mantenha, ou até mesmo, cresça nos próximos anos.

Assim como a demanda, a oferta desses grãos manteve uma trajetória de crescimento nas últimas décadas, apresentando uma maior oscilação ao longo dos anos se comparado à demanda devido, principalmente, a fatores relacionados a variações climáticas e o surgimento de pragas ou doenças no cultivo desses grãos. A Figura 1 ilustra a trajetória de crescimento da oferta e demanda da soja e milho nos últimos anos.




Figura 1 – Série histórica produção/consumo mundial de soja e milho

Fonte: adaptado (USDA, 2018)

A oferta e a demanda dessas *commodities* possuem trajetórias de crescimento similares, sem apresentar grandes oscilações (Figura 1). No entanto, os preços desses grãos no mercado apresentam uma alta oscilação ao longo do tempo (Figura 2), caracterizando-o como um mercado altamente instável e imprevisível.




Figura 2 – Série histórica do preço da tonelada de soja e milho na bolsa de Chicago

Fonte: adaptado (CBOT, 2019)

Essas características e outros aspectos inerentes ao agronegócio, fazem com que o mercado agrícola seja altamente complexo, apresentando vários riscos e incertezas aos agricultores e demais participantes dessa cadeia de produção. Os riscos estão associados a diversos fatores, dentre eles, fatores climáticos, mercadológicos e conjunturais, que influenciam diretamente na rentabilidade desta atividade (Martins & Martinelli, 2010). Diante disso, torna-se cada vez mais necessário uma gestão de riscos eficiente neste setor.

2.2 GESTÃO DE RISCOS NO AGRONEGÓCIO

O agronegócio apresenta características muito específicas se comparada a outros setores produtivos da economia. Uma das características mais marcantes é a magnitude e natureza dos riscos presentes neste setor, como a alta volatilidade dos preços das *commodities* e do câmbio. Além disso, a agricultura apresenta alguns riscos que não são comuns no processo industrial relacionados a fatores climáticos por exemplo, estiagem, geada, granizo, entre outros, ou biológicos, bem como pragas, doenças, etc (Abussamra, 2006; Burgo, 2005).

Devido a essas características, a gestão de riscos é fundamental para minimizar possíveis resultados negativos e potencializar o retorno do investimento, proporcionando um ambiente mais estável e previsível (Abussamra, 2006). A gestão de riscos preocupa-se com a análise e seleção de alternativas para minimizar ocorrência de potenciais riscos envolvidos no negócio e seus possíveis efeitos (Burgo, 2005). Segundo o *Project Management Base of Knowledge* (PMBOK), as cinco principais estratégias para gerenciar riscos são: prevenir (ou evitar), transferir, mitigar, aceitar e explorar (PMBOK, 2012).

A estratégia de prevenir tem por objetivo eliminar a causa do risco, implementando ações para retirar qualquer chance que o risco ocorra. No entanto, eliminar os riscos nem sempre é possível, pois em muitas situações não é possível aplicar essa alternativa.

A ação de transferir confere à outra parte a responsabilidade por seu gerenciamento. Essas transferências podem ser realizadas por meio de seguros, cláusulas contratuais, limites de

responsabilidades, garantias, etc. A transferência de um risco não o elimina nem diminui a probabilidade de sua ocorrência, apenas define quem ficará com o ônus.

Mitigar é uma das estratégias mais utilizadas no gerenciamento de riscos, no qual consiste em reduzir a probabilidade de ocorrência ou o impacto de um risco a um nível abaixo do limite aceitável, ou seja, mesmo que ele ocorra, os efeitos gerados por ele serão menores e mais fáceis de corrigir.

Quando há eventos de riscos com baixa probabilidade de ocorrência e seus impactos são relativamente baixos, ou quando simplesmente não há nada que possa fazer em relação ao mesmo, pode-se simplesmente aceitar os riscos. A aceitação do risco pode ser do tipo ativa ou passiva. A passiva não exige nenhuma providência, já a ativa não inclui plano de prevenção, mas um plano de contingência caso o risco ocorra. Na prática, não se mexe na probabilidade, mas no impacto que o risco pode causar.

Existem riscos com impactos positivos, ou seja, a ocorrência de um evento que traz vantagens para o negócio, quando esses eventos acontecem a estratégia é explorar ao máximo este cenário, como, por exemplo, o aumento exponencial da demanda de um determinado produto, pode ocasionar a falta do produto no mercado e conseqüentemente o aumento do preço. Neste cenário é necessário elaborar ações para aproveitar ao máximo as condições favoráveis do mercado.

Os riscos no agronegócio podem ser classificados em quatro categorias: risco de produção, risco de mercado, risco institucional e risco financeiro (Gomes, 2000; Harwood, Heifner, Coble, Perry, & Somwaru, 1999). Para cada categoria pode ser aplicada uma ou mais estratégias de gerenciamento de risco.

Os riscos de produção são aqueles que afetam diretamente a produção, sendo que os principais fatores de riscos estão relacionados a eventos climáticos incontroláveis, bem como granizo, excesso de chuva, estiagem, vendavais, variações bruscas de temperatura, etc. A tecnologia de produção exerce um papel fundamental na tentativa de diminuição destes riscos. O desenvolvimento de novas variedades de sementes e técnicas de plantio aumentam a eficiência da produção e a resistência aos eventos naturais indesejáveis. Outra alternativa é a

contratação de seguros, entretanto, essa opção não é muito desenvolvida no Brasil devido ao alto custo (Moreira, 2009).

Riscos de mercado estão relacionados às variações de preços de venda dos produtos produzidos, dos preços dos insumos necessários à produção e dos níveis de demanda. Essas variações são difíceis de prever e ocorrem após o investimento realizado. As oscilações na oferta e demanda e na situação econômica nacional e internacional, pode ocasionar quedas significativas de preços de venda ou aumentos dos preços dos insumos afetando a rentabilidade do produtor. Algumas alternativas gerenciais para reagir a estes tipos de riscos incluem a utilização de informações de mercado como subsídios para o planejamento, a diversificação da produção e do mercado de vendas e a utilização de *hedge* (por meio de contratos de futuros e de contratos de opções). Existem também os contratos de produção que se apresentam como uma alternativa interessante para a gestão dos riscos de produção e de mercado. Neste tipo de contrato, o comprador realiza a compra de forma antecipada da produção e assume as decisões sobre a definição de variedades e práticas culturais adotadas. Essa opção pode ser bastante interessante para os pequenos produtores que não possuem recursos financeiros para investir na produção e/ou na diversificação (Moreira, 2009).

Os riscos institucionais referem-se a alterações na legislação sejam elas, políticas fiscais, tarifárias e de juros, normas sanitárias, restrições ambientais e na disponibilidade do crédito rural subsidiado, promovido ou incentivado pelo governo. Alterações nas regras de uso de agrotóxicos nas lavouras, a determinação de barreiras fiscais ou limitações de cotas de importação por parte de países estrangeiros, são exemplos de riscos institucionais que afetam diretamente a rentabilidade do produtor. Normalmente, para os riscos institucionais, os produtores rurais não possuem ferramentas ou práticas gerenciais que permitam a diminuição de sua incidência. A prevenção a esse tipo de risco é a mais subjetiva de todas, no entanto, deve ser considerada no planejamento e mitigação dos seus riscos (Moreira, 2009).

Os riscos financeiros são aqueles envolvidos no financiamento da produção, o custo do capital necessário para produção, no qual flutuações desfavoráveis nas taxas de juros de empréstimos e baixa liquidez para honrar os compromissos, são as principais fontes dos riscos

financeiros. Para diminuir esses riscos, é importante o gerenciamento eficiente do endividamento total e dos custos de produção, além de contar com uma reserva financeira e realizar um seguro de crédito (Moreira, 2009).

Neste sentido, a gestão de riscos é um elemento central na gestão da estratégia de qualquer empreendimento, sendo um processo de análise metódico e minucioso sobre os riscos inerentes ao negócio, com o objetivo de atingirem uma vantagem sustentada na realização de suas atividades. É importante ressaltar que na literatura risco e incerteza são diferentes. A incerteza está relacionada a eventos envolvendo probabilidades não mensuráveis, ao contrário do risco, que está relacionado a um evento suscetível de medição, uma incerteza mensurável, ou seja, um evento que é possível de se prever (Knight, 1921).

Portanto, pode-se dizer que os riscos são eventos que possuem probabilidades mensuráveis de ocorrência e, conseqüentemente, são passíveis de serem mensurados e previstos. Desse modo, torna-se imprescindível a utilização de técnicas e ferramentas para estimar, avaliar e gerenciar os riscos envolvidos no ambiente de negócios, implementando ações para eliminar as chances que determinado risco ocorra ou pelo menos minimizar o impacto dos efeitos causados.

Neste sentido, existem procedimentos que podem ser adotados para mitigar os riscos de mercados, dentre eles, as alternativas que se demonstram mais eficientes são as operações *hedge* no mercado de futuros, venda antecipada da produção e seguro agrícola.

2.2.1 Operações no Mercado para o Gerenciamento de Riscos

A expansão dos mercados de derivativos financeiros abriu a possibilidade de realização de operações de cobertura de riscos sobre os mais variados tipos de ativos, com o objetivo de reduzir os riscos associados à volatilidade dos preços deste mercado. A utilização de operações no mercado de futuros como estratégia de gestão de riscos se baseia na compensação de ganhos ou perdas no mercado a vista pelo resultado da operação (Forigo, Zago, & Abreu, 2010).

As operações de *hedge* (proteção) no mercado de futuros é uma forma de minimizar riscos e garantir preços. Dentre essas negociações cabe destacar os contratos de futuros e os contratos de opções como principais instrumentos de negociação nesse mercado (Lozardo, 1998).

O contrato de futuro é um acordo formal entre duas partes negociando uma mercadoria estabelecendo um preço e data no futuro. O objetivo desta operação é proteger o valor de uma determinada mercadoria numa data específica. A chamada “trava”, é uma forma que o investidor ou produtor tem para se proteger de volatilidades nas cotações. Desta forma, realizar a operação de *hedge* no mercado de futuros oferece uma oportunidade de estabelecer um preço aproximado com meses de antecedência da venda ou da compra atual, além de proteger de eventuais oscilações desfavoráveis no preço (Stolf, 1992).

Outra alternativa é utilizar o mercado de opções no qual firma-se um contrato garantindo o direito de compra ou venda de um determinado produto, com preços e prazos pré-estabelecidos. Ao realizar o contrato de opções o investidor irá se proteger de variações no preços (fixando um valor no contrato) e, além disso, poderá aumentar seus rendimentos aproveitando flutuações favoráveis no preço, deixando de exercer a opção, em caso de aumento (opção de venda) ou diminuição (opção de compra) do preço (Stolf, 1992).

No entanto, as duas operações de *hedge* citadas ainda não são difundidas no agronegócio brasileiro. As operações utilizadas para a proteção contra variações de preços no cenário nacional baseiam-se na venda antecipada da produção. Este tipo de negociação é utilizado pelos participantes do mercado agrícola brasileiro devido à maior facilidade de acesso e simplicidade. As negociações não ocorrem em bolsas de valores, elas são realizadas em empresas que estão mais próximas ao produtor, como as cooperativas, agroindústrias e *tradings* (Silva, 2012).

A venda antecipada da produção consiste na comercialização da produção antes da colheita, comprometendo a parcela vendida para entrega em um período posterior (entrega futura). A venda antecipada da produção ocorre principalmente em três formas distintas: venda antecipada com preço pré-fixado, venda antecipada com preço a fixar e *barter* (troca).

Na venda antecipada com preço pré-fixado é realizado um contrato com o preço na referida data, com o compromisso de entrega fisicamente do produto acordada para um momento posterior (entrega futura). Com esse tipo de venda, o produtor compromete uma parte da produção, em contrapartida, o produtor obtém uma proteção (*hedge*) de venda do produto, já que o preço fica fixado na data do contrato de venda. Existem algumas variações neste tipo de contrato, no qual há a possibilidade de fixar o preço em dólar e efetuar o pagamento no mesmo dia da celebração do contrato (Silva, 2012).

A venda antecipada com preço a fixar é um tipo de contrato no qual o produtor recebe de forma antecipada o pagamento da venda da mercadoria, trata-se de uma modalidade de entrega futura. No entanto, diferentemente da venda antecipada com preço pré-fixado, a fixação do preço ocorre apenas no momento da entrega do grão e a diferença entre o preço vigente no momento da entrega e o preço na data do contrato é acertado neste momento (Silva, 2012). Desta forma, cabe destacar que esta alternativa não provê proteção (*hedge*) contra a variação de preços, pois o preço não é fixado previamente. Porém, é uma alternativa para financiar os custos de produção.

A operação de troca (*barter*) refere-se a troca direta de mercadoria por insumos. É uma negociação pré-fixada em que o produtor antecipa a remuneração da soja para conseguir os insumos para a safra. É uma operação que não há transação monetária, pois envolve apenas o produto. É um mecanismo interessante pelo fato de demonstrar uma organização conjunta dos agentes da cadeia para diminuir a necessidade de crédito bancário, visto que o produtor recebe o insumo e comercializa a sua produção sem a necessidade de desembolso financeiro (Silva, 2012).

No estabelecimento do contrato, é pré-definido um volume de sacas de produção (grão) contra uma quantidade específica de insumos recebidos. Portanto, nesse caso, o produtor recebe o pagamento pela venda com preço fixado na data vigente, comprometendo-se à entrega futura da mercadoria. Esta modalidade de venda é muito utilizada para o custeio das principais *commodities* agrícolas (soja e milho) no Brasil (Silva, 2012).

No entanto, cabe destacar que as operações de venda antecipada e *barter*, são alternativas para mitigar os riscos de mercado, ou seja, de variação de preços. Entretanto, outra categoria de risco também requer uma atenção especial, trata-se dos riscos de produção. Sendo de fundamental importância a implementação de ações para minimizar os riscos relacionados às perdas de produtividade da safra. Uma das principais operações utilizadas para mitigar os riscos de produção consiste em realizar seguros agrícolas.

Ao contratar um seguro agrícola, se estabelece o limite máximo de indenização (LMI) ou limite máximo de garantia (LMG) das coberturas contratadas. Esse é o valor que será considerado para indenização, no caso de ocorrência de evento climático adverso amparado pelo seguro. Existem alguns tipos básicos de seguros agrícolas com diferentes critérios para a formação do LMI, dentre essas opções, a mais utilizada no cenário nacional é o seguro de custeio (MAPA, 2017).

No seguro de custeio o LMI é calculado com base no valor do desembolso para o custeio da lavoura segurada. Basicamente este seguro é acionado quando a produtividade obtida é inferior à produtividade garantida na apólice. A indenização será calculada de acordo com nível de cobertura contratado e produtividade esperada (MAPA, 2017).

O nível de cobertura refere-se a um percentual de proteção garantido pela apólice aplicável à produtividade esperada ou faturamento esperado. Quanto maior o nível de cobertura, maior a proteção oferecida pela apólice. Já a produtividade esperada consiste em um valor de referência do potencial produtivo da lavoura segurada, geralmente, baseado na média histórica de produtividade da área a ser segurada. Vale ressaltar que o valor do seguro está associado a cobertura de riscos contratada (tais como chuva excessiva, seca, geada, granizo, raio e incêndio), que também depende de outros fatores, como práticas de manejo ou sistemas de produção utilizados, localização e as condições climáticas da região (MAPA, 2017).

No Brasil existe o Programa de Garantia da Atividade Agropecuária (Proagro), um programa do Governo Federal o qual garante o pagamento de financiamentos rurais de custeio agrícola quando a lavoura amparada tiver sua receita reduzida por causa de eventos climáticos ou pragas e doenças sem controle. O Banco Central é o administrador do Proagro e as normas

que as regulamentam são aprovadas pelo Conselho Monetário Nacional (CMN). O Banco Central é o órgão de fomento de recursos e o responsável pelo pagamento das indenizações (BACEN, 2019).

O Proagro funciona como um seguro para garantir que os agricultores e os pecuaristas, estejam protegidos contra problemas que podem surgir durante o cultivo da safra ou criação dos animais. O programa tem como foco principal os pequenos e os médios produtores, embora esteja aberto a todos, desde que dentro do limite de cobertura estabelecido na regulamentação (BACEN, 2019).

Por fim, cabe destacar que as informações fornecidas pelo gerenciamento de risco podem subsidiar a tomada de decisão dos administradores, auxiliando na elaboração de ações para eliminar ou mitigar os riscos ou até mesmo aproveitar oportunidades geradas pela ocorrência desses eventos. As práticas em gestão de risco proporcionam maior confiança no alcance dos resultados desejados limitando, de forma efetiva, os riscos a níveis aceitáveis e auxiliando os gestores na tomada de decisão. Diante disso, pode-se afirmar que a gestão de risco integra o processo decisório da organização e, por este motivo, deve estar alinhada ao planejamento estratégico da mesma (IBGC, 2017).

2.3 PLANEJAMENTO ESTRATÉGICO

O planejamento consiste no processo de antecipar o futuro e determinar planos de ação para atingir objetivos; e o termo estratégia, refere-se aos meios para se chegar a esses objetivos (Boone & Kurtz, 1998). Neste sentido, o planejamento estratégico pode ser entendido como, processo contínuo e sistemático para elaborar e implementar ações sobre o futuro da organização. Trata-se de um processo fundamental para a sobrevivência do empreendimento, pois permite que a organização consiga adaptar-se de forma eficiente às mudanças do ambiente de negócios, aumentando a probabilidade de aproveitar as oportunidades e explorar suas potencialidades com menor risco (Drucker, 1998; Kerzner, 2006).

De acordo com Tiffany e Peterson (1998), o planejamento estratégico é uma visão específica do futuro, por meio do qual a empresa analisa o setor de atuação, o mercado, os concorrentes, os produtos e serviços, os preços, as vantagens a longo prazo, a lucratividade, entre outros aspectos referentes ao negócio.

No planejamento estratégico são definidos objetivos e metas da organização. Para isto é necessário o levantamento e a análise de um vasto conjunto de informações que visam auxiliar os gestores na tomada decisão, a fim de direcionar a empresa ao cenário previsto (Crawford, 2011).

Segundo Zuin e Queiroz (2006), o planejamento estratégico é essencial para manter a competitividade de uma organização, e que se tratando de empreendimentos rurais, esse processo se torna ainda mais necessário, por se tratar de um mercado complexo, instável e de alto risco. Diante disso, o planejamento orçamentário torna-se fundamental para formulação de metas e objetivos coerentes.

2.3.1 Planejamento Orçamentário

De acordo com Lunkes (2003), o planejamento orçamentário (PO), é o plano financeiro estratégico de uma empresa ou organização para a gestão, no qual deve-se estimar e determinar a melhor relação entre resultados e despesas para atender às necessidades, características e objetivos da empresa em um determinado período.

Segundo Zdanowicz (1989), o orçamento é definido como o instrumento que descreve o plano geral de operações e/ou investimentos por um determinado período, orientado por objetivos e metas propostas pela alta direção.

O orçamento é um instrumento de planejamento voltado para o futuro, o qual pode ser utilizado como ferramenta de simulação das operações futuras de uma empresa. Sendo assim, uma ferramenta explícita de formulação de metas a serem cumpridas, a fim de prever a obtenção dos recursos necessários, num prazo previamente determinado. Assim, cabe ao administrador

organizar, direcionar, planejar, coordenar e controlar essas operações da empresa (Acadrolí, 2000; Sanvicente & Santos, 1995).

No agronegócio, o planejamento orçamentário se faz cada vez mais necessário, devido à globalização e os avanços tecnológicos neste setor. O planejamento é importante no sentido de alertar os empresários rurais quanto às mudanças na economia, no hábito dos consumidores, na tecnologia, no comportamento climático, nos custos de produção, na oferta e demanda dos produtos, entre outras alterações. O planejamento orçamentário permite ao empresário rural um resultado antecipado de cada atividade, tanto no plano empresarial quanto no operacional (Acadrolí, 2000).

No planejamento, o orçamento deve ser elaborado visando o futuro da empresa, definindo os objetivos, metas e resultados a serem alcançados. No orçamento são previstos receitas, despesas, custos, produção e o lucro para um determinado período. Neste processo é importante realizar uma análise de investimentos minuciosa, a fim de obter o melhor retorno sobre o capital investido com o menor risco.

2.3.2 Análise de Investimentos

Segundo Megliorini e Vallim (2009), análise de investimentos consiste em antecipar, por meio de estimativas, os resultados oferecidos pelos projetos. Esta análise envolve a decisão de aplicar ou não recursos em um determinado projeto por um período de tempo com o objetivo de obter o melhor retorno do investimento (A. Souza & Clemente, 2004).

Segundo Holanda (1975), esta análise é necessária, pois os recursos são escassos frente às amplas e variadas necessidades a que devem atender, justificando a preocupação de utilizá-los de forma racional e eficiente. Neste sentido, torna-se fundamental a utilização de técnicas de análise de investimentos mais eficientes para a mensuração do resultado, possibilitando aumentar a eficiência, a racionalidade e a segurança das decisões, através da maximização do rendimento dos recursos (Holanda, 1975). Portanto, diante dos recursos limitados e escassos,

as decisões no que se refere, ao que produzir, como produzir, quanto produzir e onde produzir devem ser tomadas de forma racional (Neves, 1982).

A análise de investimentos pode ocorrer de duas formas, a primeira considera que todos os dados de entrada sejam perfeitamente conhecidos, a segunda considera que os dados de entrada são incertos ou desconhecidos. A qualidade da informação determina o ambiente em que as decisões serão tomadas. De acordo com Abreu e Stephan (1982), as informações pertinentes à tomada de decisão podem estar nas seguintes condições: sob absoluta certeza, incerteza ou de risco. Na situação de certeza, o resultado real corresponde sempre ao resultado esperado, enquanto na situação de incerteza uma ação pode gerar vários resultados possíveis, porém cujas as probabilidades não são conhecidas. A situação de risco é similar à situação de incerteza, ou seja, cada ação pode implicar uma série de resultados possíveis. No entanto, cada qual pode ocorrer conforme uma probabilidade conhecida.

O agronegócio, conforme já destacado, apresenta vários riscos e incertezas aos produtores e aos demais participantes deste mercado. Portanto, a eficiência econômica dos agentes que atuam neste setor está diretamente relacionada à melhor relação entre retorno e risco. Para mensurar esta relação de retorno e risco é necessário o cálculo de alguns indicadores econômicos, financeiros e de risco conforme apresentados na Tabela 1.

Tabela 1

Indicadores econômicos, financeiros e de risco

Indicador	Descrição
Receita bruta por hectare (RBha)	Corresponde à receita esperada, decorrente da venda da produção por hectare.
Custo operacional por hectare (COPha)	Representa a soma do custo variável e fixo por hectare.
Custo econômico por hectare (CEha)	Corresponde ao custo operacional de produção por hectare acrescido do custo de oportunidade por hectare.
Lucro operacional por hectare (LOha)	É a diferença entre a receita bruta e o custo operacional por hectare.
Lucro financeiro por hectare (LFha)	É o somatório do lucro operacional e depreciações por hectare, representando o retorno monetário unitário obtido pelo produtor após o desconto dos custos desembolsáveis. Enquanto o lucro operacional possibilita avaliar o retorno obtido

Indicador	Descrição
	pelo produtor considerando o desgaste de máquinas, equipamentos e benfeitorias, o lucro financeiro estima a remuneração do produtor, descontando apenas os custos desembolsáveis.
Lucro econômico por hectare (LEha)	É a diferença entre a receita bruta e o custo econômico, por hectare.
Lucratividade por hectare (LUCh)	Consiste na divisão do lucro operacional pela receita bruta, por hectare, multiplicando tal resultado por cem.
Value-at-Risk (VaR)	O VaR é entendido como o valor de risco do investimento. É uma medida de perda potencial máxima do valor de um ativo (ou carteira de ativos), sobre um período pré-fixado, com dada probabilidade. De acordo com Mina e Xiao (2001), <i>Value-at-Risk</i> (VaR) é uma das estatísticas mais importantes e amplamente utilizados para medir o risco potencial de perdas econômicas. O índice mede o pior cenário possível de perdas esperadas, em um determinado horizonte de tempo e sobre condições normais de mercado, considerando um determinado nível de confiança (Jorion, 1999).
Taxa Mínima de Atratividade (TMA)	A taxa mínima de atratividade consiste na taxa mínima de retorno que cada projeto deve proporcionar para remunerar o capital investido nele. Este índice é utilizado para mensurar qual alternativa de investimento apresenta-se mais atrativa (Meghiorini & Vallim, 2009). Para uma proposta ser atrativa, deve render no mínimo, a taxa de juros equivalente à rentabilidade das aplicações correntes e de pouco risco. Souza e Clemente (2004), conceituam a taxa mínima de atratividade como sendo a melhor taxa, com baixo grau de risco, disponível para aplicação do capital em análise. A taxa mínima de atratividade é estimada com base na taxa de juros praticada no mercado.
Valor Presente Líquido (VPL)	O valor presente líquido é a métrica de análise de investimento mais conhecida e utilizada. O VPL é a concentração de todos os valores esperados de um fluxo de caixa na data zero, usando como taxa de desconto a TMA (A. Souza & Clemente, 2004). O VPL é utilizado para análise de investimentos isolados que envolvam o curto prazo ou que tenham baixo número de períodos. O VPL é a soma algébrica de todos os fluxos de caixa descontados para o instante presente, a uma determinada taxa de juros (Motta & Calôba, 2009).
Taxa Interna de Retorno (TIR)	Gitman (2010), conceitua a TIR como sendo a taxa de desconto que iguala o VPL de uma oportunidade de investimento a zero. A empresa obterá esta taxa se aplicar recursos em um projeto e receber as entradas de caixa previstas. Conforme Casaroto Filho e Kopittke (2000), “os investimentos com TIR maior que a TMA são considerados rentáveis e são passíveis de análise”. Esse indicador não depende da taxa de juros vigente no mercado de capitais, este valor calculado é intrínseco ao projeto e não depende de qualquer outra variável, além dos fluxos de caixa do projeto

Indicador	Descrição
	(Cavalcanti & Plantullo, 2007). A TIR pode ser utilizada para analisar a dimensão do retorno como também para analisar a dimensão risco. Na dimensão retorno ela pode ser interpretada como um limite superior para a rentabilidade de um projeto de investimento. Na dimensão risco, quanto mais próxima for a TIR comparada à TMA, maior será o risco no que tange ao retorno financeiro do investimento (A. Souza & Clemente, 2004).
Índice de Lucratividade (IL)	O índice de lucratividade é medido por meio da relação entre o valor presente de fluxo de caixa positivo (entradas) e o valor presente dos fluxos de caixa negativos (saídas), usando como taxa de desconto a taxa de atratividade do projeto (TMA). Este índice indica quanto o projeto oferece de retorno para cada unidade monetária investida em termos de valor presente (Assaf Neto, 2010; Kassai, Casanova, & Santos, 2005).

A utilização desses indicadores permite que os gestores possam acompanhar, avaliar, sugerir, decidir, interferir no processo visando atingir determinado objetivo. Além disso, esses indicadores são utilizados na projeção de cenários futuros, possibilitando avaliar de forma mais assertiva o retorno do investimento e mensurar os riscos envolvidos.

2.4 SIMULAÇÃO DE CENÁRIOS

Segundo Wright e Spers (2006), a elaboração de cenários não é uma atividade de predição, mas um esforço e exercício de fazer descrições plausíveis e consistentes de situações futuras possíveis, apresentando os condicionantes do caminho entre a situação atual e cada possível cenário futuro, evidenciando os fatores relevantes às decisões que precisam ser tomadas. O método de cenários é um importante instrumento do processo de tomada de decisões. A utilização de cenários possibilita que a organização pense de forma sistemática e estratégica sobre a variedade de potenciais resultados, sem a influência de seus próprios vieses, opiniões e preconceitos (Turner, 2008).

Segundo Weimer-Jehle (2006), a metodologia de geração de cenários requer uma imagem global que expressa quais combinações de fatores e suas variantes descrevem uma projeção de prognósticos para cenários ótimo, previsível ou pessimista. De modo geral, o

método de elaboração de cenários implica em uma descrição consistente da evolução dinâmica de um sistema gerado por variáveis e fatores que se interagem de forma dependente. A função dos cenários não é acertar eventos futuros, mas considerar as forças que podem direcionar o futuro por determinados caminhos, auxiliando os gestores a compreender a dinâmica do ambiente de negócios, reconhecer novas possibilidades, avaliar opções estratégicas e decisões de longo prazo (Schwartz, 2000).

A simulação de cenários é muito utilizada no planejamento estratégico das empresas, no qual os gestores precisam dispor de recursos informativos que facilitem a previsão dos acontecimentos, amenizando impactos negativos. A simulação aponta as possibilidades futuras, a partir das mudanças de variáveis presentes no processo de tomada de decisão, criando um ambiente racional para isto. A técnica de simulação de cenários é uma ferramenta importante quando a empresa precisa decidir entre inúmeras alternativas e não tem clareza sobre o que levaria ao melhor resultado (Buarque, 2003; Reibstein & Chussil, 1999).

Embora a geração de cenários não seja atividade de predição, ou seja, não irá prever exatamente o cenário que irá acontecer, mas gerar um conjunto de cenários possíveis de acontecer e estimar os efeitos que cada cenário pode “causar” caso ocorra. É fundamental que essas estimativas tenham um nível de precisão confiável. Porém, a projeção de dados futuros confiáveis não é uma tarefa trivial, ainda mais em ambientes altamente instáveis como a economia brasileira e mundial tratando-se de *commodities* agrícolas.

Diante disso, nota-se cada vez mais a necessidade de empregar métodos matemáticos e estatísticos que permitam gerar informações úteis diante dos desafios da gestão moderna. Welsch (1996), menciona que as estimativas devem basear-se em fatos conhecidos e em inferências adequadas, no qual o processo de estimação esteja apoiado em técnicas matemáticas, possibilitando uma maior acurácia nas previsões, tendo em vista que um dos principais objetivos do orçamento é alcançar a previsão de resultados futuros. Neste sentido, um dos métodos estatísticos amplamente utilizado na literatura para a simulação de cenário é o método de Monte Carlo.

2.4.1 Método de Monte Carlo

De acordo com Donatelli e Konrath (2005), o método de Monte Carlo é uma técnica de amostragem que faz uso de variáveis aleatórias e distribuição de probabilidades para definir o comportamento do sistema em estudo. O método tem por objetivo estimar a distribuição de resultados possíveis de uma ou mais variáveis de interesse, com base em uma ou mais variáveis de entrada que se comportam de forma probabilística de acordo com alguma distribuição estipulada (Evans & Olson, 1998).

O método consiste em simular uma grande quantidade de cenários gerando, de forma aleatória, valores dentro de faixas de variação esperada para cada variável. Inicialmente, geram-se valores aleatórios para as variáveis de entrada do modelo através da sua função de distribuição, posteriormente calculam-se os resultados e, por fim, repete-se os passos anteriores até que se gere uma função de distribuição para os resultados. Para utilizar a técnica de simulação de Monte Carlo é necessário, a priori, determinar as variáveis que fazem parte do sistema e estimar sua frequência. A frequência deve ser baseada em dados históricos ou até mesmo em projeções. A geração de números aleatórios determinará uma série provável dentro dessa distribuição (Andrade, 1998; Crundwell, 2008).

Dependendo da natureza do problema, diferentes distribuições de probabilidade podem ser utilizadas para as variáveis independentes. Podem-se utilizar distribuições, tais como uniforme, normal, triangular. A distribuição uniforme considera que todos os valores são igualmente prováveis, o que caracteriza um maior grau de incerteza quanto aos valores das variáveis envolvidas. Já a distribuição normal conhecida também como distribuição gaussiana é uma das mais importantes distribuições contínuas. Esta distribuição está fundamentada no teorema central do limite, o qual garante que mesmo que os dados não sejam distribuídos segundo uma normal, a média dos dados converge para uma distribuição normal conforme o número de dados aumenta. Uma distribuição normal pode ser descrita somente em função de sua média (μ) e seu desvio-padrão (σ) (D. Montgomery & Runger, 2016). De acordo com Assis

et al. (2006), a distribuição triangular é apropriada nos casos em que é possível determinar o valor mais provável da variável aleatória, bem como seu valor mínimo e máximo quando uma função linear parece apropriada para a descrição da distribuição dos valores dos erros das variáveis.

A simulação de Monte Carlo tem como principal benefício fornecer ao tomador de decisão uma gama de resultados possíveis e as probabilidades de ocorrência dos mesmos, bem como os riscos associados às ocorrências de resultados indesejáveis, sendo possível se estabelecer uma estrutura de correlação entre os fatores de risco a partir dos cenários projetados. Além disso, o método é considerado o mais eficiente para o cálculo do *Value at Risk* (VaR), que significa valor de risco, sendo um dos indicadores mais utilizados no gerenciamento de risco, pois a técnica captura em grande quantidade riscos, inclusive os não-lineares, os de volatilidade e, até mesmo, do modelo e não assume tantas premissas quanto os outros métodos (Saliby & Araújo, 2001).

No entanto, há uma complexidade em estabelecer as distribuições de frequências para as variáveis de entrada, principalmente quando trata-se de informações extremamente voláteis como preços de *commodities* e cotação do dólar. Por este motivo, as estimativas devem basear-se em fatos conhecidos e em inferências adequadas, no qual o processo de estimação esteja apoiado em técnicas matemáticas, possibilitando uma maior acurácia nas previsões (Welsch, 1996).

Neste sentido, a utilização de modelos de previsão para as variáveis de entrada do método de Monte Carlo torna-se de grande relevância. Diante disso, algumas das principais técnicas para a previsão de preços são apresentadas a seguir.

2.5 MODELO DE PREVISÃO DE PREÇOS

Dentre as diversas técnicas existentes para projeção/previsão de dados, a técnica de análise preditiva vem adquirindo destaque no que diz respeito à previsão de resultados. A análise preditiva é uma técnica estatística para modelar e encontrar padrões utilizando-se de

dados históricos a fim de realizar previsões de tendências, padrões de comportamento ou eventos futuros. Desde o final século XIX, utiliza-se este tipo de técnica para apoiar o processo de gestão de negócios.

Os métodos preditivos mais indicados para previsão de preços são os modelos de séries temporais (estocásticas). Uma série temporal é um conjunto de observações ordenadas no tempo e que apresentam dependência serial; ou seja, as suas observações estão ligadas diretamente umas às outras; portanto, uma série temporal deve considerar a ordem cronológica das observações (Morettin & Tolói, 2006).

Para a análise de uma série temporal, inicialmente deve-se modelar o fenômeno a ser estudado. A partir de então é realizada uma análise do comportamento da série, posteriormente, estimativas são geradas e, por fim, avalia-se os fatores que influenciam no comportamento da série, tendo em vista a definição da relação causa e efeito. Segundo Morettin e Tolói (2006), os objetivos da análise de séries temporais são: caracterizar os fenômenos que dão origem à série temporal; fazer previsões de valores futuros, sendo que as previsões podem ser a curto e longo prazo; descrever o comportamento da série; verificar a existência de tendências, ciclos e variações sazonais e procurar periodicidades relevantes nos dados.

Existem diversos tipos de modelos de séries temporais, as técnicas mais utilizadas para a previsão de preços são os modelos autorregressivos integrados e de médias móveis (ARIMA) e os modelos de inteligência artificial, como as redes neurais artificiais (Teixeira Jr, 2013).

2.5.1 Modelo Autorregressivo Integrado e de Médias Móveis - ARIMA

Os modelos autorregressivos integrados e de médias móveis, proposto por Box e Jenkins, (1970) resultam da combinação de três componentes: o componente Auto Regressivo (AR), o filtro de Integração (I) e o componente de Médias Móveis (MA). Uma série temporal pode conter os três componentes ou apenas um subconjunto deles, permitindo modelar a variável resposta por meio de componentes autorregressivos e de médias móveis de forma simultânea, podendo ou não apresentar sazonalidade (Fava, 2000). Os modelos ARIMA são

adequados para descrever séries não estacionárias, ou seja, séries que não possuem média constante no período analisado. O modelo ARIMA pode ser classificado de diferentes maneiras, conforme os parâmetros AR(p) (autorregressivos de ordem p), MA(q) (média móvel de ordem q) e I(d) (integrado de ordem d) (Morettin & Tolói, 2006).

O modelo autorregressivo AR(p) é um processo iterativo em que há a identificação da ordem (p) por meio da função de autocorrelação. A partir daí faz-se a estimativa de um modelo de previsão, bem como a análise dos resíduos para a avaliação da existência de vieses e/ou grandes erros de estimativas. Esse componente prevê valores futuros com base em uma combinação linear de valores passados.

O modelo de média móvel de ordem (q), MA(q) é usado quando há autocorrelação entre os resíduos, ou seja, existe uma relação de dependência entre o conjunto de erros em períodos passados. Esse modelo em série temporal utiliza como previsão para uma determinada observação no futuro, a média das observações passadas. As médias móveis podem ser simples, centradas ou ponderadas. O termo média móvel é utilizado porque, à medida que a próxima observação está disponível, a média das observações é recalculada.

Por fim, o modelo ARIMA contém o parâmetro de Integração I(d), que representa o componente sazonal ou de tendência da série. Ele é utilizado quando há necessidade de aplicar transformações por meio de diferenças para tornar a série estacionária. O valor do parâmetro (d) representa o número de diferenças necessárias para tornar uma série estacionária. Esse parâmetro também é conhecido como ordem de integração (Margarido, 1998).

Segundo Gujarati (2006), existem alguns pressupostos que precisam ser considerados a fim de obter os melhores resultados na utilização da metodologia ARIMA. O principal refere-se à estacionariedade da série de dados, ou seja, a série deve oscilar em torno de uma média e apresentar variância constante. Caso a série não seja estacionária, será necessário transformar os dados originais. A transformação mais comum consiste em aplicar diferenças sucessivas da série original até se obter uma série estacionária. Para as séries temporais, a estacionariedade é fundamental para previsão de dados futuros, a qual tem como premissa que o futuro se comportará de acordo com o passado (Morettin & Tolói, 2006; Stock & Watson, 2004).

Nos modelos de séries temporais deve-se verificar a dependência entre os dados. Para isso são utilizadas as funções de autocorrelação (ACF) e autocorrelação parcial (PACF). A função de autocorrelação (ACF) descreve o comportamento de uma variável com base no conhecimento exclusivo dos seus valores passados, medindo a correlação entre pares de valores da série defasados em um e mais períodos. O coeficiente de autocorrelação é uma das principais estatísticas na análise de séries temporais. Esse coeficiente tem como principal característica medir como ela está autocorrelacionada às observações de uma série temporal afastadas k períodos entre si. Além de analisar a correlação total entre pares de observações é importante verificar a correlação simples entre Y_t e Y_{t-k} depois de eliminar o efeito que os valores intermediários exercem sobre elas. A função de autocorrelação parcial é uma medida da correlação entre as observações de uma série temporal que são separadas por k unidades de tempo (D. C. Montgomery, Johnson, & Gardiner, 1990).

Ao trabalhar com séries temporais, esses e outros conceitos devem ser compreendidos pelo pesquisador a fim de que o modelo gerado seja o mais coerente possível. Uma metodologia para o desenvolvimento e ajuste de modelos de séries temporais é a metodologia Box-Jenkins.

Segundo Morettin e Tolói (2006) a metodologia de Box e Jenkins constitui-se em ajustar modelos autorregressivos integrados a médias móveis – ARIMA(p, d, q) a um conjunto de informações. Esse conjunto de dados constitui a base para a construção do modelo mais adequado. A construção de um modelo ARIMA baseado na metodologia Box-Jenkins obedece a um ciclo iterativo, composto por quatro etapas: identificação, estimação, verificação e previsão (Morettin & Tolói, 2006).

A etapa de identificação busca a ordem dos parâmetros do ARIMA (p, d, q). A identificação da ordem (p) e (q) é feita por meio da função de autocorrelação (ACF) e da função de autocorrelação parcial (PACF). Além disso, nesta etapa é verificada a estacionariedade da série, que pode ser realizada por meio de testes para identificação de raiz unitária, como o Dickey-Fuller Aumentado (Said & Dickey, 1984) ou Phillips-Perron (Phillips & Perron, 1988), quando a hipótese alternativa é estacionariedade da série. Também é possível verificar estacionariedade observando a existência de tendência ou sazonalidade no gráfico plotado da

série temporal ou por meio do comportamento vagaroso na queda da (ACF) ao longo das defasagens.

Na etapa de estimação, realiza-se a estimativa dos parâmetros do componente autorregressivo, do componente de médias móveis e da variância que foram identificados na etapa anterior.

A etapa de verificação consiste em analisar, por meio da análise dos resíduos, se o modelo escolhido descreve adequadamente o comportamento da série. Os resíduos devem apresentar ausência de autocorrelação. O teste de Ljung-Box busca testar a existência significativa de autocorrelação dos resíduos em algum k defasagem. A inexistência de autocorrelação dos resíduos em nenhuma defasagem implica a ausência de correlação temporal na estrutura dos resíduos do modelo (Enders, 1996).

Por fim, a Etapa de previsão realiza as previsões da série a partir do modelo selecionado na etapa anterior. Vale ressaltar que esta etapa é realizada apenas se as etapas anteriores forem satisfatórias. Assim, sempre que o modelo não se mostrar adequado, o processo deve ser repetido (Morettin & Tolói, 2006).

2.5.2 Redes Neurais Artificiais - RNA

Segundo Fauseff (1994), as Redes Neurais Artificiais (RNA) são generalizações de modelos matemáticos de cognição humana ou biologia neural, onde as similaridades dos neurônios biológicos e computacionais são identificadas. As redes neurais são métodos computacionais com capacidade de se adaptar e de aprender a realizar uma tarefa ou comportamento, a partir de um conjunto de dados (R. Souza, 2008).

A principal diferença entre RNA e as abordagens estatísticas, tais como os modelos ARIMA, é que as redes neurais não estabelecem hipóteses ou suposições sobre a distribuição ou propriedades dos dados e, desta forma, tendem a ser mais úteis em situações práticas.

As RNAs são consideradas uma das técnicas mais importantes de modelagem de séries temporais não lineares e não paramétricas, fornecendo precisão na modelagem de dados

complexos. Seus principais benefícios são a capacidade de aproximar qualquer função mensurável contínua com uma precisão arbitrária; imposição de poucas suposições para a sua aplicação; capacidade de generalização, mesmo sendo aplicados em meios não estacionários e, por fim, utilizam menos parâmetros se comparado a outros métodos (Khashei & Bijari, 2010).

As RNAs são formadas por um conjunto de neurônios, onde cada um consiste em uma unidade de processamento completa que atua em paralelo com outros neurônios na rede. Uma rede neural artificial é composta basicamente por um conjunto de neurônios interligados a outros três tipos de elementos denominados: sinapse, somador e função de ativação. (Amaral Júnior & Távora Júnior, 2010).

A Sinapse representa a conexão entre neurônios, para cada conexão existirá um peso associado. Dessa forma, cada entrada que está ligada a um dado neurônio deve ser multiplicada pelo seu respectivo peso.

O Somador é a estrutura responsável por realizar a soma do resultado da multiplicação dos sinais de entrada pelos seus respectivos pesos sinápticos, considerando todas as conexões que chegam ao neurônio.

A função de ativação é uma função matemática utilizada para gerar uma saída, a qual é enviada ao próximo nó do sistema. O objetivo da função de ativação é limitar a amplitude da saída do neurônio. As funções de ativação mais conhecidas são as funções sigmoide, linear, passo e logística.

Além disso, existe o elemento *threshold*, que é utilizado como parâmetro de ajuste das saídas da função soma (geralmente, esse elemento é desprezado). Pode ser comparado com o termo independente (intercepto) do modelo de regressão linear. A Figura 3, ilustra a estrutura de um neurônio artificial.

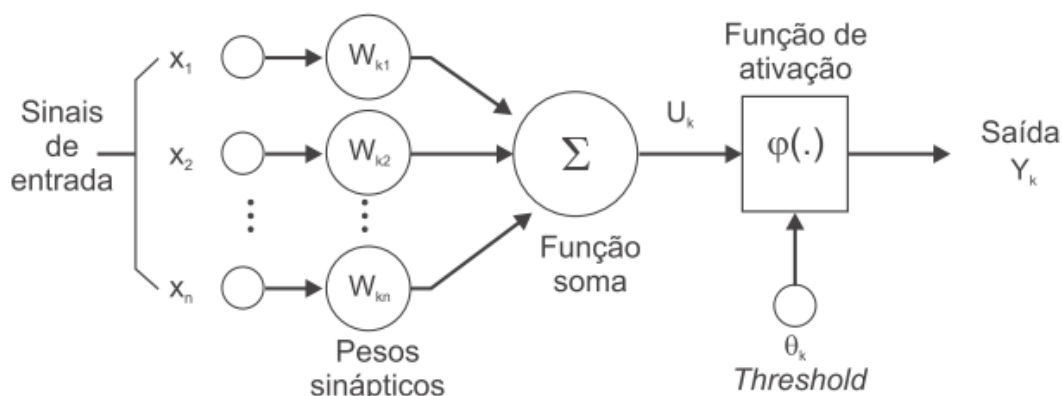


Figura 3 – Modelo não linear de um neurônio artificial

Fonte: Haykin (2001)

Conforme já mencionado, uma RNA é formada por um conjunto de neurônios. Definir a quantidade e a forma que esses neurônios são organizados é denominada de arquitetura, ou topologia, de redes neurais artificiais. A topologia irá afetar o desempenho da rede, assim como as aplicações para as quais ela é desejada. Geralmente, as RNAs têm uma camada de entrada, zero ou mais camadas intermediárias ou (escondidas) e uma camada de saída. Desse modo, uma rede neural passa a ser formada por um arranjo sequencial de três tipos básicos de neurônios: neurônios de entrada, neurônios intermediários e neurônios de saída.

A camada de entrada é utilizada para captar estímulos externos (valores iniciais) e repassá-los para a camada intermediária. A camada de saída apenas retrata o resultado produzido pela RNA em resposta a uma dada entrada. Entre as camadas de entrada e saída, pode haver uma ou mais camadas intermediárias, cujas saídas dos neurônios não são acessadas por procedimentos externos à RNA (Amaral Júnior & Távora Júnior, 2010).

São as camadas ocultas e a função de ativação que permitem a rede neural representar relações não lineares, as quais são muito problemáticas para técnicas multivariadas (Barreto, 2002). A Figura 4 traz um exemplo de arquitetura de uma rede neural artificial.




Figura 4 – Exemplo de arquitetura de uma rede neural artificial

Fonte: adaptado de Haykin (2001)

Uma das características mais importantes de uma rede neural refere-se à sua capacidade de aprendizado. O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos da rede de uma forma ordenada para alcançar o objetivo desejado. A habilidade de aprender conforme o ambiente e melhorar o seu desempenho, após o processo iterativo de ajustes é denominado treinamento (S. Haykin, 2001).

Segundo Haykin (2001), aprendizagem (ou treinamento) é o processo pelo qual os parâmetros livres de uma rede neural são adaptados através de estímulos fornecidos pelo ambiente. O tipo de treinamento é definido pela forma na qual os parâmetros são modificados, sendo os principais tipos de aprendizagem: supervisionada, não supervisionada e por reforço.

No processo de aprendizagem supervisionada existe o conhecimento prévio do resultado, o ajuste dos pesos ocorre quando o sistema compara a saída da rede com a resposta conhecida. No processo de aprendizagem não-supervisionada, não existe um supervisor para avaliar o desempenho da rede em relação ao conjunto de treinamento, a rede se adapta às regularidades estatísticas dos dados de entrada. A aprendizagem por reforço enfatiza a aprendizagem do indivíduo através da interação direta com o ambiente, sem se basear em uma supervisão ou um modelo completo deste ambiente, visando minimizar um índice escalar de desempenho. O objetivo desta aprendizagem é minimizar uma esperança do erro acumulado, ao invés de simplesmente tratar o erro atual.

Em geral, quando se tem o conhecimento prévio do resultado, utiliza-se o processo de aprendizagem supervisionada. Este processo funciona de forma semelhante à resolução de um problema de ajuste (aproximação) de curvas. Basicamente, o aprendizado acontece ao tentar ajustar sucessivamente uma superfície não-linear buscando o melhor “encaixe” ao conjunto de dados de treino, em um espaço multi-dimensional, de acordo com algum critério estatístico de “melhor ajuste” pré-estabelecido (R. Souza, 2008).

Todo processo de aprendizagem é definido por um algoritmo. Existem vários algoritmos desenvolvidos para este propósito, dentre eles está o algoritmo *Backpropagation* (retropropagação) muito utilizado para o treinamento supervisionado de uma rede neural multicamada. Neste método, o aprendizado é efetuado com base no erro incluso na resposta fornecida pela rede, o que significa que a diferença entre a resposta atual da simulação e a desejada deve ser minimizada, sendo necessário, o ajuste dos pesos sinápticos associados às entradas dos neurônios. Assim, o erro calculado na camada de saída é retropropagado às camadas anteriores, servindo de base para a modificação de todos os pesos, até que a resposta obtida pela rede seja satisfatória (Carvalho, Braga, & Ludermir, 1998; Rumelhart & McClelland, 1986).

No processo de aprendizagem, as funções de ativação são muito importantes, pois elas representam o componente matemático presente em cada neurônio artificial. A função de ativação é a transformação não linear que é realizada ao longo do sinal de entrada. Esta saída transformada é então enviada para a próxima camada de neurônios como entrada.

Existem várias funções de ativação na literatura, no entanto, as funções mais utilizadas são: *Rectifier Linear Unit* (ReLU), Tangente Hiperbólica e Maxout.

A função *Rectifier Linear Unit* (ReLU) ou unidade linear retificadora é uma função de ativação linear que faz a saída zero se a entrada é negativa, caso contrário a saída é a própria entrada (He, Zhang, Ren, & Sun, 2015). A função ReLU é definida pela Equação 1:

$$f(x) = \max(0, x) \quad (1)$$

A função Tangente Hiperbólica (TanH) funciona de forma semelhante à função logarítmica ou (sigmoide), no entanto, ela é simétrica em relação à origem variando de -1 a 1. A função TanH é definida conforme Equação 2:

$$\text{TanH}(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2)$$

A função Maxout aplica k produtos escalares diferentes para x, ou seja, calcula vários valores alternativos e retorna o maior (Goodfellow, Warde-Farley, Mirza, Courville, & Bengio, 2013). A função Maxout é uma versão generalizada da função ReLU com dois canais diferentes de zero, que é expressa pela Equação 3:

$$f(x) = \max(0, x * k', x * k'') \quad (3)$$

Ainda no que diz respeito ao processo de aprendizagem supervisionada, as saídas da rede vão gradativamente se aproximando ao valor das saídas desejadas para um conjunto de padrões de treinamento. No entanto, cabe ressaltar que esta característica não é mais importante, pois o aspecto mais desejado em uma rede neural é a sua capacidade de generalização (Diniz, 2018).

A generalização de uma RNA refere-se à sua capacidade de produzir respostas adequadas e coerentes para padrões ou exemplos de testes diferentes daqueles empregados em seu treinamento. Neste sentido, o processo de aprendizagem pode enfrentar problemas como *underfitting* e *overfitting*.

O termo *overfitting*, do inglês, significa sobreajuste ou superajuste. Ele ocorre quando o modelo se ajustou demais aos dados com os quais está sendo treinado, porém não consegue generalizar com a mesma eficiência para novos dados. Este problema ocorre principalmente quando o modelo de RNA é submetido a um treinamento excessivo, fazendo com que a rede neural consiga extrair relacionamentos extremamente específicos do conjunto de treinamento (memorização), até mesmo se confundindo com ruídos e ocasionando o problema de *overfitting* (Diniz, 2018; Simon Haykin, 1998).

Já o problema de *underfitting* ocorre quando o modelo não se adapta bem sequer aos dados com os quais foi treinado. Arquiteturas RNA muito simples, com um número reduzido de parâmetros livres (pesos das conexões e limiares), muitas vezes não são capazes de extrair relacionamentos complexos do conjunto de treinamento, geralmente são as causas deste problema (Diniz, 2018; Simon Haykin, 1998).

Desta forma, pode-se dizer que a ocorrência de *overfitting* faz com que os resultados sejam excessivamente tendenciosos aos padrões de treinamento, enquanto que o problema de *underfitting* ocasiona o aumento da variância das saídas da RNA. Uma arquitetura teoricamente otimizada deve ser um meio termo entre estes dois problemas.

Portanto, para obter melhores resultados, a capacidade de generalização de um modelo RNA precisa ser assegurado. Existem técnicas que são comumente empregadas para assegurar uma generalização adequada de uma RNA, dentre elas, destacam-se os métodos que particionam o conjunto de dados, por exemplo: *Random sub-sampling*, *k-fold cross-validation* e *bootstrapping* (Diniz, 2018; Simon Haykin, 1998).

Este tipo de abordagem utiliza um subconjunto de dados para validação. Este processo busca antecipar o comportamento em situações reais assumindo que o erro, em ambos os casos, será semelhante ao erro de validação, sendo considerado uma boa estimativa do erro de generalização (S. Haykin, 2001).

A técnica *Random sub-sampling* consiste em aplicações sucessivas de particionamentos aleatórios dos dados disponíveis em dois grupos: os dados de treinamento e os dados para validação. A média dos erros dos dados de validação é considerada como sendo a estimativa do erro de generalização (Prechelt, 1994).

O método de validação cruzada denominado *k-fold* consiste em dividir o conjunto total de dados em k subconjuntos mutuamente exclusivos do mesmo tamanho, sendo um conjunto para validação e os demais são utilizados para o treinamento da RNA. Este processo é realizado k vezes alternando de forma circular o subconjunto de teste, ou seja, todos os subconjuntos são utilizados pelo menos uma vez tanto para a validação quanto para o treinamento. Recomenda-

se utilizar este método com o valor de k maior ou igual a 10, obtendo assim uma validação mais consistente (Kohavi, 1995).

A validação por meio do método *bootstrap*, consiste em utilizar uma amostragem com reposição para formar o conjunto de treinamento. Retira-se uma amostra aleatória de tamanho n de um conjunto de m exemplos com reposição e esta amostra é usada para o treinamento. Os exemplos dos dados originais, que não estão no conjunto de treino, são usados como teste. Este procedimento é indicado quando o conjunto de dados é pequeno, devido ao uso de amostragens com reposição de uma forma intensiva, objetivando reduzir as incertezas e imitar o componente randômico de um processo (Miguez, 2012).

Por fim, cabe ressaltar, que o poder computacional de uma rede neural se dá pela estrutura paralelamente distribuída e sua habilidade de aprender produzindo saídas adequadas para entradas que não estavam presentes durante o processo de aprendizagem, o que caracteriza a generalização. Assim, torna-se possível uma rede neural resolver problemas complexos decompondo-os em tarefas relativamente simples, atribuindo-as à rede neural (S. Haykin, 2001).

2.5.3 Critérios de Seleção e Validação de Modelos

Quando há um conjunto de diferentes modelos é necessário realizar testes e utilizar critérios para mensurar o ajuste do modelo em relação aos dados e selecionar os melhores modelos de previsão. Segundo Burnham e Anderson (2003), os critérios de seleção de modelos *Akaike information criterion* (AIC) e *Bayesian information criterion* (BIC) são os mais utilizados na literatura, sendo aplicados em diferentes áreas do conhecimento, como biometria, econometria, pesquisa operacional, séries temporais, regressão espacial, entre outras.

Esses critérios levam em consideração a complexidade do modelo no momento de seleção. São critérios que, essencialmente, penalizam a verossimilhança, utilizando o número de variáveis do modelo e o tamanho da amostra. Esta penalização é feita subtraindo-se do valor

da verossimilhança uma determinada quantidade, que irá depender do número de parâmetros do modelo (Ye, Meyer, & Neuman, 2008).

Akaike (1974) propôs utilizar a informação de *Kullback-Leibler* para a seleção de modelos. Ele estabeleceu uma relação entre a máxima verossimilhança e a informação de *Kullback-Leibler*, posteriormente chamado de Critério de Informação de Akaike (AIC).

O critério de informação de Akaike (1974) é uma medida relativa da qualidade de ajuste de um modelo estatístico estimado. Fundamenta-se no conceito de entropia, oferecendo uma medida relativa das informações perdidas, quando um determinado modelo é usado para descrever a realidade. O AIC é um critério que avalia a qualidade do ajuste do modelo paramétrico, estimado pelo método da máxima verossimilhança, no qual o melhor modelo será o que minimize o valor do AIC (Burnham & Anderson, 2003).

O critério de informação Bayesiano (BIC), também chamado de Critério de Schwarz, foi proposto por Schwarz (1978). Esse método possui um formato semelhante ao AIC, embora tenha um embasamento teórico diferente. Seguindo um ponto de vista bayesiano, é um critério de avaliação de modelos definido em termos da probabilidade. O termo relativo ao número de parâmetros, no caso do BIC, é multiplicado por um fator correspondente ao logaritmo natural do número de observações da amostra (Brockwell & Davis, 2010; Burnham & Anderson, 2003).

De forma geral, escolhe-se o modelo que apresente menor valor AIC e BIC. Além de considerar os modelos mais parcimoniosos, ou seja, aqueles que apresentam o menor número de parâmetros. Por fim, é recomendável que esses critérios sejam avaliados conjuntamente, pois são complementares e não excludentes (Enders, 1996).

Por fim, deve-se verificar a acurácia do modelo, mensurando o nível de precisão das previsões geradas. Previsões muito próximas dos dados reais significam erros de precisão baixos; logo, o modelo possui um bom nível de precisão, caso contrário, o mesmo deve ser alterado ou ajustado. Para analisar e decidir o melhor modelo de previsão que se ajusta aos dados deve-se considerar algumas métricas, dentre elas, os indicadores de erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro absoluto médio (MAE), erro

percentual médio (MPE), erro percentual absoluto médio (MAPE) e erro médio absoluto de escala (MASE), que são apresentadas, respectivamente, das Equações 4 a 9.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (6)$$

$$MPE = \frac{1}{n} \sum_{i=1}^n 100 * \frac{(Y_i - \hat{Y}_i)}{Y_i} \quad (7)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n 100 * \frac{|Y_i - \hat{Y}_i|}{Y_i} \quad (8)$$

$$MASE = \frac{1}{n} \sum_{i=1}^n \frac{(Y_i - \hat{Y}_i)}{\frac{1}{n} \sum_{t=2}^n |Y_t - \hat{Y}_t|} \quad (9)$$

em que: n representa a quantidade total de elementos, Y representa o valor observado e \hat{Y} representa o valor estimado.

Além dos indicadores de erros apresentados, existem outras métricas relevantes para avaliar a precisão dos modelos de previsão, dentre elas, destaca-se o índice de concordância de Willmott, d (Willmott, 1981; Willmott & Wicks, 1980). Este índice fornece o grau de exatidão entre as variáveis envolvidas, uma vez que relaciona a diferença entre os valores estimados em relação e os valores observados.

De acordo com Willmott (1981), o índice de concordância, d (Equação 10), é uma medida descritiva que reflete a precisão dos valores preditos (variável Y) em relação aos valores observados (variável X). Este índice pode assumir valores entre 0 e 1, sendo que um indica uma perfeita concordância e zero representa uma total discordância entre os valores observados e preditos.

$$d = 1 - \frac{\sum_{i=1}^n (Y_i - X_i)^2}{\sum_{i=1}^n (|Y_i - \bar{X}| + |X_i - \bar{X}|)^2} \quad (10)$$

em que: Y representa o valor verdadeiro de interesse, X representa o valor estimado, \bar{X} corresponde à média dos valores de X (padrão) e n o número de pares de valores.

Cabe destacar que o índice de concordância de Willmott, possibilita uma fácil interpretação dos resultados e pode ser aplicado em comparações de concordância para diferentes modelos/métodos, independentemente das unidades de medida das variáveis.

Além disso, é importante ressaltar que as previsões podem ser geradas para mais de um passo à frente. Basicamente, há dois tipos de previsão: 1-passo-a-frente (*single-step*) ou vários-passos-a-frente (*multi-step*). A previsão 1-passo-a-frente ocorre quando a rede é utilizada para prever uma única observação futura. No entanto, para aplicações práticas de longo prazo, este tipo de previsão tem pouca utilidade, sendo necessário expandir o horizonte de previsão para vários passos à frente (Diniz, 2018).

A previsão do tipo vários-passos-a-frente pode ser realizada seguindo um modelo incremental, no qual a rede prevê todos os valores intermediários da série até k passos à frente, usando os valores previstos anteriormente para prever os próximos valores. Sendo de grande relevância para modelos aplicados a previsões de médio e longo prazo (Diniz, 2018).

3 METODOLOGIA

Nessa seção são apresentados os procedimentos metodológicos empregados no desenvolvimento da pesquisa, com o propósito de atingir os objetivos estabelecidos neste estudo. Diante disso, o presente capítulo descreve de forma sucinta as etapas de desenvolvimento do trabalho, o delineamento da pesquisa, a coleta de dados, a modelagem dos dados por meio de técnicas estatísticas, o processo de geração de cenários econômicos e a especificação do sistema computacional desenvolvido neste estudo.

3.1 DELINEAMENTO DA PESQUISA

No que tange à abordagem do problema, esta pesquisa é considerada quantitativa, tendo em vista o emprego de ferramentas e instrumentos estatísticos que foram utilizados para o tratamento e análise dos resultados. A abordagem quantitativa caracteriza-se pela utilização de métodos matemáticos para previsão de preços para as *commodities* de soja e milho, além dos cálculos de indicadores econômicos, financeiros e de risco. No que se refere aos seus objetivos, trata-se de uma pesquisa documental, pois analisa dados históricos pertinentes ao contexto agrícola do cultivo de soja e milho. No tocante à natureza do problema, é considerada aplicada, uma vez que está fundamentado em informações legítimas extraídas do mundo real, com a perspectiva de mensurar, analisar e produzir dados a serem aplicados em uma situação real.

3.2 ETAPAS DE DESENVOLVIMENTO DO TRABALHO

Esta pesquisa se divide em três etapas (Figura 5). A primeira consistiu no levantamento bibliográfico, na definição de um referencial teórico e na coleta de dados. A segunda etapa fez-

se o desenvolvimento de modelos de previsão de preços de *commodities* e a etapa final elaborou-se as simulações de cenários econômicos.

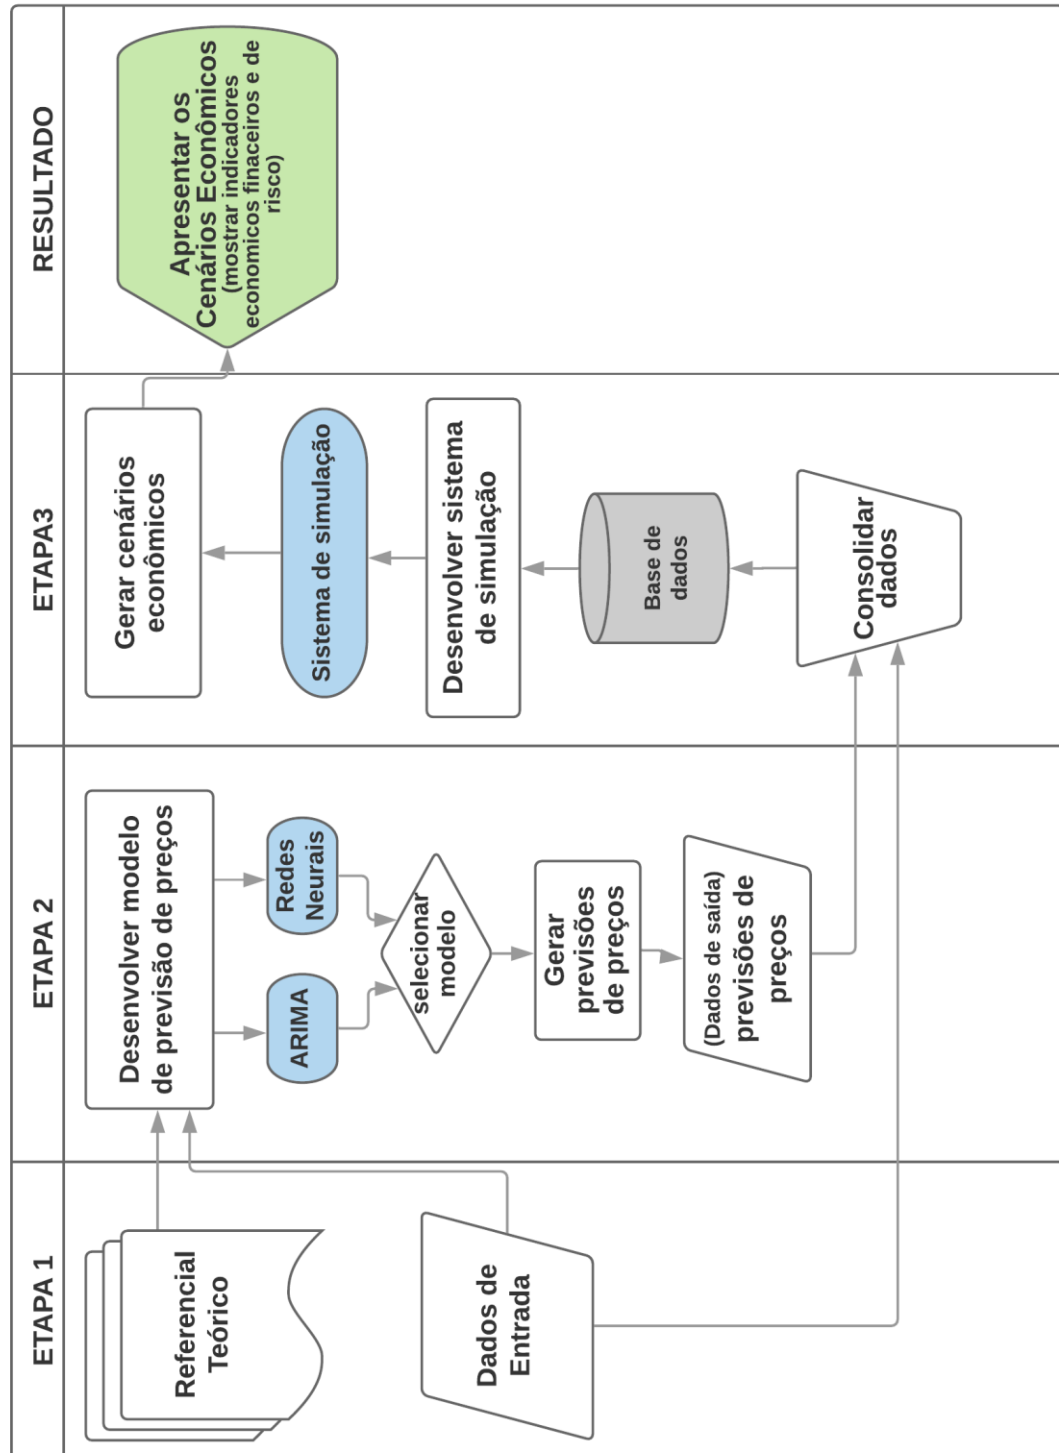


Figura 5 – Diagrama de etapas do trabalho

Fonte: do Autor

Na primeira etapa foi definido o referencial teórico sobre mercado de *commodities* em especial o mercado da soja e do milho, gerenciamento de risco, planejamento estratégico, análise de cenários e métodos estatísticos para previsão de preços. Além disso, foi realizada a coleta de dados referente aos preços mensais da soja e do milho na bolsa de Chicago, os preços médios mensais pagos aos agricultores no Paraná, a cotação e as previsões do dólar do BACEN e dados de produtividade e custos de produção para a região oeste do estado do Paraná.

Na segunda etapa foram gerados os modelos de previsão de preços para as *commodities* de soja e milho. Para isso, foram desenvolvidos modelos por meio de duas técnicas distintas: o modelo econométrico ARIMA e redes neurais artificiais. Para cada tipo de modelagem foram gerados seis modelos, divididos por tipo de cultura (soja e milho) e por tipo de período (mensal, bimestral e trimestral); desta forma, ao todo foram desenvolvidos doze modelos de previsões de preços. Vale mencionar que o uso de diferentes séries temporais de dados é motivado por se tratar de previsões no curto e médio prazo, pois o ciclo de cultivo da soja e milho varia entre quatro a seis meses. Sendo selecionado o modelo que obteve o melhor desempenho preditivo (de acordo com os critérios de seleção e validação) para cada tipo de cultivo e período. Após a seleção dos modelos será gerado as previsões de preços para um e dois ciclos posteriores, assim obtendo previsões de preços para os seis meses subsequentes. Os valores previstos e o intervalo de confiança dos mesmos, foram utilizados na projeção de cenários da etapa seguinte;

Na terceira e última etapa foi consolidado em um único sistema as informações coletadas e as geradas pelos modelos de previsão de preços, utilizando-as como variáveis de entrada para o método de Monte Carlo na simulação de cenários econômicos futuros, posteriormente, os cenários foram analisados por meio de indicadores econômico-financeiros, tais como: lucro operacional, margem de lucro e Value-at-Risk (VaR), para verificar a viabilidade e riscos do cultivo da soja e milho para a região oeste do estado do Paraná.

3.3 COLETA DE DADOS

Os dados utilizados nesta pesquisa são considerados dados secundários que estão disponíveis de forma gratuita em plataformas digitais na internet, colados de diferentes fontes. As informações obtidas consistem em dados econômicos como por exemplo, o preço da soja e do milho, o custo de produção, a cotação do dólar, o valor do prêmio de exportação, além da produtividade das culturas.

A informação de preço consiste em dados históricos da cotação (em dólar) mensal das *commodities* na bolsa de Chicago (CBOT, 2019), referentes ao período do mês de janeiro de 1990 a maio de 2019, totalizando 353 observações para cada cultura (soja e milho). É importante frisar que, por meio desses dados, foram geradas as três séries temporais (mensal, bimestral e trimestral) que foram utilizadas pelos modelos de previsão de preços.

Além disso, foi necessário obter dados de preços médios mensais pagos aos produtores para cada tipo de cultura no estado do Paraná e os valores médios mensais do prêmio de exportação aplicado ao porto de Paranaguá. Isto porque, na maioria das vezes, a simples conversão do preço (dólar para reais) da *commodity* na bolsa de Chicago não corresponde ao preço praticado no mercado interno brasileiro. Essa diferença está associada principalmente ao valor do prêmio aplicado aos terminais portuários. Essas informações foram coletadas do portal eletrônico da Secretaria da Agricultura e do Abastecimento do Paraná (SEAB).

Foram coletados dados de produção, produtividade e custo de produção da soja e milho dos últimos 15 anos. Esses dados foram obtidos junto a SEAB por meio eletrônico. Neste momento, vale destacar que os dados de custo de produção e preços pagos aos produtores referem-se a uma média a nível estadual, enquanto que as informações sobre produtividade consistem numa média regional que, neste caso, refere-se ao núcleo regional de Cascavel, localizado na região oeste do estado do Paraná. Ao tomar esta decisão, verificou-se que os preços praticados nas diferentes praças do estado, não possuem uma diferença significativa.

No entanto, a produtividade média por hectare apresenta variabilidade entre as regiões do estado, desta forma, optou-se por utilizar preço médio estadual e uma média regional para a produtividade. Além disso, é importante frisar que não há informações disponíveis sobre os custos de produção de forma detalhada por município ou região, apenas em nível estadual.

Quanto à cotação do dólar, dois tipos de informações foram coletados. A primeira consiste na série histórica mensal do dólar; a segunda refere-se às previsões da cotação para os doze meses à frente fornecidas pelo Banco Central do Brasil (BACEN). Foram obtidas as previsões para a cotação do dólar médio, dólar máximo e dólar mínimo realizadas dos últimos 10 anos.

Essas informações compõem a base de dados do sistema computacional que foram utilizadas no método de Monte Carlo para a simulação de cenários econômicos. Além disso, foi necessário obter as previsões de preços das *commodities* gerados pelos modelos de previsão preços, cujo seu processo metodológico será apresentado a seguir.

3.4 MODELAGEM DE DADOS

Após realizada a coleta dos dados, foram gerados os modelos ARIMA e RNA para previsão de preços. É importante destacar que as duas técnicas são distintas e, portanto, seus procedimentos metodológicos também são. O processo de desenvolvimento para cada tipo de modelagem é descrito a seguir.

3.4.1 Modelagem ARIMA

Para o desenvolvimento de modelos ARIMA, foi utilizada a metodologia Box-Jenkins. Este processo consiste em ajustar o modelo a um conjunto de dados, seguindo um ciclo iterativo, composto por quatro etapas: identificação, estimação, verificação e previsão (MORETTIN; TOLOI, 2004).

No entanto, antes de iniciar o processo de modelagem, alguns pressupostos foram verificados, bem como o tamanho da amostra, que não deve conter menos que 50 observações. Os dados não podem apresentar valores negativos e a série deve ser estacionária ou passível de estacionariedade que foi verificada pelo teste Dickey-Fuller Aumentado. Além disso, verificou-se a dependência entre os dados por meio das funções de autocorrelação (ACF) e autocorrelação parcial (PACF).

Em seguida, na etapa de estimação, foram calculados os indicadores AIC e BIC para todas as combinações entre zero a cinco para os parâmetros (p, d, q) que formam os componentes autorregressivos, integrado ou de diferenças e de médias móveis. Sendo selecionados os melhores modelos segundo o critério de informação AIC e BIC.

Os modelos selecionados foram submetidos à análise dos resíduos, no qual foram verificados se os mesmos se tratam de um ruído branco, ou seja, quando os resíduos possuem as propriedades estatísticas de média zero, variância constante e não apresentam autocorrelação. Também foi aplicado o teste de *Ljung-Box*, o qual verifica a existência significativa de autocorrelação dos resíduos em algum nível de defasagem. Por fim, buscou-se mensurar o nível de precisão das previsões dos modelos selecionados por meio dos indicadores de erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro absoluto médio (MAE), erro percentual absoluto médio (MAPE) e o erro médio absoluto de escala (MASE), além do índice de concordância de Willmott.

3.4.2 Modelagem RNA

O desenvolvimento dos modelos de redes neurais artificiais seguiram o processo proposto por Hair et al.(2005) composto por cinco etapas: (i) preparação dos dados, (ii) definição da estrutura do modelo, (iii) estimativa do modelo, (iv), avaliação dos resultados do modelo e (v) validação do modelo.

Na preparação dos dados, as informações foram tabuladas em planilhas eletrônicas; em seguida, verificou-se a ausência de *outliers* e dados faltantes. A partir dos dados iniciais (preços

mensais), geraram-se os arquivos com os dados de entrada para as RNAs, sendo um arquivo para cada tipo de série temporal (mensal, bimestral e trimestral), no qual foram adicionadas as informações de preços a um determinado grau de defasagem, data e o valor previsto pelo modelo RNA de periodicidade inferior. O conjunto de dados de entrada das RNAs é apresentado na Tabela 2.

Tabela 2

Dados de entrada para os modelos RNAs

Tipo Série Temporal	Conjunto de Dados
Mensal	Data, preço, preço anterior 1, preço anterior 2 e preço anterior 3
Bimestral	Data, preço, preço anterior 1, preço anterior 2, valor prev. RNA mensal
Trimestral	Data, preço, preço anterior 1, preço anterior 2, valor prev. RNA bimestral

Na segunda etapa, definiu-se a estrutura do modelo em três componentes principais: arquitetura, função de ativação e aprendizagem. Vale ressaltar que não existe na literatura um processo sistematizado que forneça a melhor arquitetura de RNA para um determinado problema. Por este motivo, é importante ressaltar que a definição da estrutura da rede neural consiste em um processo incremental, no qual várias estruturas são geradas, estimadas e analisadas, buscando a melhor combinação de modelo estrutural.

No entanto, este processo iniciou-se com algumas configurações pré estabelecidas, bem como, a definição do número máximo de cinco camadas da rede, sendo uma camada de entrada, uma camada de saída e no máximo três camadas intermediárias (ocultas). A definição do número de neurônios em cada camada seguiu o seguinte critério: a camada de entrada possui a quantidade de neurônios igual ao número de variáveis de entrada; a camada de saída possui apenas um neurônio e, para as camadas intermediárias, gerou-se um subconjunto de possibilidades de acordo com número de variáveis de entrada mais um, multiplicado por um número inteiro k que compreende o intervalo de 1 a 3.

Além disso, utilizou-se três funções de ativação diferentes, que são: *Rectifier Linear Unit* (ReLU), Tangente Hiperbólica e *Maxout*, e o algoritmo de aprendizado utilizado foi o da retropropagação do erro (*backpropagation*), utilizando a taxa de aprendizado adaptável

ADADELTA para sua otimização estocástica de descida de gradiente, que possui dois parâmetros de configuração: *rho* e *epsilon*, no qual foram utilizados os seguintes valores para *rho*: (0.9, 0.95, 0.99 e 0.999) e *epsilon*: ($1e^{-10}$, $1e^{-8}$, $1e^{-6}$ e $1e^{-4}$). Além disso, cabe mencionar outra configuração adicional tal como o critério de parada do algoritmo de aprendizagem, que foi definido um limite máximo de cinco mil épocas ou quando o erro não diminui 0.01% em dez ciclos consecutivos nos dados de treinamento.

Desta forma, na etapa de estimativa de modelos, várias combinações foram desenvolvidas, sendo divididos em dois grupos (soja e milho), no qual cada grupo possui três modelos com periodicidades, mensal, bimestral e trimestral. Foram selecionados os melhores modelos de cada grupo e tipo de período, adotando-se como critério de seleção o erro quadrático médio (MSE).

A partir dos modelos selecionados, iniciou-se a etapa de avaliação dos resultados do modelo, no qual as RNAs passaram pelo processo de treinamento e validação utilizando a abordagem de validação cruzada de 10 vezes, com proporção de 80% dos dados para treino e 20% para teste. Posteriormente, os modelos foram validados pelo processo de validação dois-passos-a-frente. Por fim, calculou-se os indicadores MSE, RMSE, MAE, MAPE e o índice de concordância de Willmott, a fim de mensurar a acurácia dos modelos gerados.

Após o desenvolvimento dos modelos de previsão de preços para ambas as técnicas (ARIMA e RNA), comparou-se o desempenho preditivo entre elas, selecionando os modelos que apresentaram melhor nível de acurácia. Em seguida, foram geradas as previsões de preços para um e dois ciclos posteriores, assim obtendo previsões de preços para os seis meses subsequentes. Além dos valores previstos, também foram calculados seus respectivos intervalos de confiança. Vale mencionar que essas estimativas são de suma importância para geração de cenários, conforme descrito na seção seguinte.

3.5 SIMULAÇÃO DE CENÁRIOS

Quanto aos procedimentos para simulação de cenários, foi utilizado o método de Monte Carlo com as seguintes variáveis de entrada: produtividade, custo de produção, preço, valor do prêmio de exportação e dólar. As variáveis de saída foram: receita bruta, lucro (operacional, financeiro, econômico) e lucratividade, sendo que a unidade de medida foi expressa em reais por hectare (R\$/ha).

Para cada variável de entrada foi determinada a sua função de distribuição, sendo que para variáveis de produtividade e prêmio de exportação foi utilizado a distribuição normal, sendo, portanto, necessária a determinação da média e o desvio padrão desses dados. Como a produtividade das culturas tem tendência crescente ao longo do tempo, optou-se por restringir os dados a um período de seis anos anteriores a data da simulação para o cálculo da média e desvio padrão enquanto que, para o prêmio de exportação, utilizou-se os últimos dez anos.

Para as variáveis preço e dólar foi utilizada a distribuição triangular, na qual é necessário ter a informação de média, limite superior e inferior, compondo um intervalo de confiança. A média do preço foi o valor previsto por um dos modelos matemáticos propostos (ARIMA ou RNA) e em seguida foi calculado seu intervalo de confiança. Para o dólar bastou utilizar os valores das previsões de dólar médio, mínimo e máximo disponibilizadas pelo BACEN.

É importante destacar que a variável custo de produção possui características diferentes das demais variáveis, pois esta informação, geralmente, é conhecida antes mesmo do início do plantio, ou seja, no início da simulação. De modo geral, seu valor sofre, no máximo, pequenas alterações até o término da colheita e, por este motivo, o valor do custo de produção foi considerado fixo durante as simulações, sendo o mesmo obtido da SEAB.

Após a definição de todas as variáveis e suas respectivas funções de distribuição, iniciou-se o processo de simulação de cenários utilizando o método de Monte Carlo. Portanto, geraram-se, de forma aleatória, um valor numérico dentro da faixa de variação esperada para

cada variável de entrada e, posteriormete, calculou-se o valores de saída, compondo assim um cenário. Este processo foi repetido várias vezes até obter o número de cenários desejados.

Quanto à quantidade de cenários projetados, Lustosa, Ponte e Dominas (2004) indicam que a simulação deve ser replicada mais de cem vezes para que se obtenha uma amostra representativa. No entanto, não há recomendação quanto ao número máximo de simulações a serem realizadas. Sendo assim, devido à grande quantidade de combinações possíveis foi necessário a geração de um grande número de cenários. Aqui, foram definidos cinquenta mil cenários a serem gerados pelo sistema.

A partir do conjunto de cenários gerados, foram criados três cenários denominados: otimista, realista e pessimista. Esses são os cenários que são apresentados ao usuário final do sistema computacional. O cenário otimista será a média dos 50% melhores cenários de acordo com o lucro, enquanto que o cenário pessimista consiste na média dos 50% piores cenários. Já o cenário realista será a média geral dos cenários projetados. Para cada cenário foi calculado os indicadores de receita bruta, lucro (operacional e econômico) e margem de lucro operacional, além do indicador *Value-at-Risk* (VaR) que foi calculado apenas uma vez, pois, deve-se considerar todos os cenários projetados (Figura 6).

cenário	produtividade	custo	preço	dólar	receita	lucro
1	50	2000	25	3,2	4000	2000
2	60	2000	30	3,4	5100	300
3	70	2000	35	3,6	6300	4100
N-1	88	2000	39	3,8	7176	5176
N	90	2000	40	4	7400	5400

Figura 6 – Geração dos cenários pessimista, realista e otimista

Fonte: do Autor

Além disso, foram gerados cenários implementando ações de gerenciamento de riscos. As ações elaboradas visam mitigar os riscos de produção e de mercado. O mecanismo utilizado para gerenciamento de risco de produção foi o seguro de safra, mais especificamente, o PROAGRO, pois o mesmo consta nas planilhas de custos de produção disponibilizadas pela SEAB.

Para o gerenciamento de riscos de mercado foi utilizado procedimentos de *hedge* para proteção contra oscilações de preços. As estratégias adotadas foram: venda antecipada com preço pré-fixado e a operação de troca (*barter*). Ambas visam negociar de forma antecipada um percentual estimado da produção para cobrir os custos financeiros do plantio. No entanto, a estratégia de venda antecipada com preço pré-fixado também é efetuada quando o preço no mercado físico ultrapassar um determinado limite de variação em relação ao preço previsto.

Portanto, ao simular os cenários econômicos com a operação de *barter* definida, o sistema computacional estima o percentual de venda da produção necessária para cobrir os custos do plantio, baseado nas informações de produtividade média e o preço do grão no mês inicial da simulação, efetuando a venda antecipada desse percentual da produção no valor vigente no início da simulação.

Na venda antecipada com preço fixado, assim como operação de *barter*, o sistema computacional estima o percentual de venda da produção necessária para cobrir os custos, porém só irá efetuar a venda se esse percentual for inferior a 70%, ou seja, caso seja necessário vender mais que este percentual para apenas garantir os custos financeiros da atividade agrícola. Desta forma, considera-se mais vantajoso assumir os riscos e não efetuar a venda antecipadamente.

Além disso, essa alternativa possui outro critério, no qual é utilizado um limite de variação de 10% no preço previsto, ou seja, se na simulação o valor previsto para a *commodity* possui uma diferença maior que 10%, tanto para mais ou para menos, em relação ao preço praticado no mercado nacional. Especificamente nas “praças” do estado do Paraná, define-se que tal momento é pertinente para efetuar a venda antecipada, pois em caso de aumento do preço no mercado físico, garante-se um rendimento maior do que o previsto com alta no preço, caso o preço diminua além do percentual limite. Portanto, é provável que o valor da mercadoria fique abaixo do previsto, sendo melhor negociá-la para evitar perdas ainda maiores. Para esse critério, definiu-se o percentual de venda antecipada de 60% do restante da produção. A Tabela 3 apresenta as estratégias de gerenciamento de riscos que foram utilizadas nas simulações dos cenários econômicos realizadas neste trabalho.

Tabela 3

Estratégias de gerenciamento de riscos

Estratégia	Seguro	Venda Antecipada
Sem Estratégia	Nenhum	Nenhum
ProAgro e Barter	ProAgro com nível de cobertura de 80%	Barter sobre o percentual necessário para cobrir os custos financeiros do plantio.
ProAgro e Venda PreFixada	ProAgro com nível de cobertura de 80%	Venda PreFixada, sendo necessário atender pelo menos um dos critérios estabelecidos: 1. Se percentual necessário para cobrir os custos do plantio for menor ou igual a 70%. 2. Se a diferença entre preço do mercado físico e o preço previsto for maior que 10%.

Diante disso, vale ressaltar que a operação de venda antecipada com preço fixado só é efetuada quando pelo menos um dos critérios é atendido. Caso os dois critérios sejam atendidos no mesmo cenário, o sistema realiza as duas operações: a primeira para cobrir os custos de produção; e a segunda para assegurar o preço.

O detalhamento do sistema computacional desenvolvido e suas tecnologias são apresentados a seguir.

3.6 ESPECIFICAÇÃO DO SISTEMA COMPUTACIONAL

O presente trabalho utilizou-se de dados coletados de diferentes fontes, que podem apresentar distintas unidades de medidas, escalas, entre outros. Portanto, para padronizar os dados e verificar sua coesão, consolidou-se esse conjunto de informações em uma única base de dados. Esta base de dados consiste em um banco de dados computacional, gerenciado por um Sistema de Gerenciamento de Banco de Dados (SGBD) que, neste caso, foi o *software* PostgreSQL, uma ferramenta gratuita utilizada para gerenciar banco de dados de sistemas computacionais.

Cabe mencionar que todas as informações coletadas e geradas pelos modelos de previsão de preço foram consolidadas neste banco de dados, ou seja, esta base de dados armazena as informações de custo de produção, produtividade, valor do prêmio de exportação, cotação da soja, do milho e do dólar, e as previsões geradas pelos modelos de previsão de preços. Desta forma, o sistema computacional fica responsável por ler essas informações do banco de dados e realizar as simulações de cenários, exibindo na tela os resultados para o usuário.

O sistema computacional proposto neste trabalho foi desenvolvido na linguagem de programação JAVA utilizando o *framework JavaServer Faces* (JSF). O JSF é uma ferramenta que segue a especificação Java para a construção de interfaces para o usuário baseadas em componentes de aplicações *web*. Além disso, com o intuito de prover uma interface mais “amigável” ao usuário, foi utilizado a biblioteca de componentes de interface gráfica para as aplicações *web PrimeFaces*, possibilitando uma gama maior de gráficos e componentes de interface.

Quanto à arquitetura do sistema, foi utilizado o padrão arquitetural MVC (*Model-View-Controller*). O padrão MVC possibilita a divisão do projeto em camadas muito bem definidas, tendo como principais benefícios, a possibilidade de isolar as regras de negócios da lógica de apresentação (interface com o usuário). Isto possibilita a existência de várias interfaces com o usuário que podem ser modificadas sem que haja a necessidade da alteração das regras de negócios, proporcionando muito mais flexibilidade e produtividade.

No que diz respeito à conexão com o banco de dados e a manipulação dos mesmos, foi utilizado o *framework* Hibernate, que é amplamente utilizado no mercado. Sua principal função é abstrair o mapeamento, economizando esforços e preocupações com a tarefa de persistência dos dados. Vale ressaltar, que todas as tecnologias citadas são disponibilizadas de forma gratuita.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Nesse capítulo serão apresentados e discutidos os resultados obtidos no presente estudo. Para uma melhor compreensão e discussão dos resultados, o capítulo foi organizado em três seções principais: modelos de previsão de preços, simulação de cenários econômicos e sistema computacional.

A primeira seção consiste na análise dos resultados dos modelos ARIMA e RNA, discutindo e analisando o desempenho preditivo dos modelos.

Na segunda seção são apresentados os resultados das simulações de cenários econômicos para o cultivo da soja e milho no estado do Paraná, bem como sua análise de risco e desempenho econômico. Por fim, discute a viabilidade desta atividade e apresentam algumas medidas que visam mitigar os riscos desta atividade.

A última seção consiste na apresentação do sistema computacional desenvolvido e suas funcionalidades.

4.1 MODELOS DE PREVISÃO DE PREÇOS

Uma vez definida a base de dados e os procedimentos metodológicos utilizados na elaboração dos modelos de previsão de preços, realizou-se testes para avaliar a eficácia na previsão de preços de mercado de soja e milho.

No entanto, antes de iniciar a discussão sobre os resultados, convém mencionar que o objetivo principal desta pesquisa é geração de cenários econômicos em um horizonte de tempo de até seis meses por meio de uma ferramenta computacional. Desta forma, vale ressaltar que os modelos de previsão de preços foram planejados para atender este objetivo e, por este motivo, foram criados três modelos com periodicidade diferentes para cada cultura, sendo elas, (mensal, bimestral e trimestral). A utilização de modelos com esta estrutura possibilita a

previsão de valores para até seis meses com apenas dois ciclos a frente o que favorece, de forma significativa, na acurácia das estimativas.

Além disso, outro ponto importante a frisar refere-se à distinção das técnicas utilizadas, pois há uma grande diferença entre a modelagem ARIMA (Autorregressivos Integrados de Médias Móveis) e a de Redes Neurais Artificiais e, por este motivo, é interessante analisar cada tipo de modelagem de forma separada, respeitando suas características e comparando-as no final por meio das métricas de acurácia.

4.1.1 ARIMA

Conforme a metodologia de Box-Jenkins (1976) foi definido um conjunto de combinações dos parâmetros (p), (d) e (q) e, em seguida, foram calculados seus respectivos valores AIC e BIC, utilizados como critérios de seleção dos modelos (Tabela 4).

Tabela 4

Modelos selecionados de acordo com os valores de AIC e BIC

	Período	Parâmetros (p,d,q)	AIC	BIC	Shapiro-Wilk (p-valor)
ARIMA - Soja	Mensal	(3,1,0)	3947,55	3963,05	1,30e ⁻¹¹
	Mensal	(4,1,2)	3944,77	3971,90	4,12e ⁻¹⁰
	Mensal	(3,2,3)	3941,70	3968,80	3,15e ⁻¹⁰
	Bimestral	(4,1,2)	2108,34	2130,58	4,10e ⁻⁵
	Bimestral	(4,2,3)	2104,90	2130,26	3,70e ⁻⁵
	Bimestral	(5,2,3)	2101,63	2130,16	2,18e ⁻⁴
	Trimestral	(2,2,3)	1441,66	1458,18	1,26e ⁻⁵
	Trimestral	(3,2,1)	1442,91	1456,68	2,26e ⁻³
	Trimestral	(5,2,3)	1443,80	1468,58	3,12e ⁻²
ARIMA - Milho	Mensal	(2,1,2)	3507,05	3526,43	3,11e ⁻¹⁵
	Mensal	(2,1,3)	3508,88	3532,13	3,80e ⁻¹⁵
	Mensal	(5,2,3)	3515,72	3550,57	8,12e ⁻¹⁶
	Bimestral	(2,1,2)	1864,75	1880,63	2,07e ⁻⁸
	Bimestral	(3,1,4)	1865,87	1891,28	2,16e ⁻⁷
	Bimestral	(4,2,3)	1863,14	1888,50	1,53e ⁻⁸
	Trimestral	(2,1,2)	1284,46	1298,27	7,09e ⁻⁹
	Trimestral	(3,2,3)	1279,06	1298,33	5,71e ⁻⁹
	Trimestral	(3,2,4)	1282,91	1304,94	2,00e ⁻⁸

Vale ressaltar que essas duas métricas fornecem uma medida relativa das informações perdidas, quando um determinado modelo é usado para descrever a realidade, no qual o melhor modelo será o que minimize os valores de AIC e BIC. Foram selecionados os três melhores modelos para cada tipo de período e cultura (Tabela 4). Os modelos foram selecionados de acordo com os valores de AIC e BIC.

Após a seleção desse conjunto de modelos (18 modelos ao todo), realizou-se uma análise dos resíduos, por meio do teste Shapiro-Wilk (Tabela 4), para verificar se os resíduos seguem uma distribuição normal e do teste de Ljung-Box (Apêndice 1), para constatar a existência significativa de autocorrelação dos resíduos em algum nível de defasagem.

Analisando os valores de AIC e BIC e os testes aplicados, verificou-se que, para a soja, os modelos mensal (4,1,2), bimestral (5,2,3) e trimestral (3,2,1) apresentaram melhor ajuste aos dados; já para o milho, os modelos mensal (2,1,2), bimestral (4,2,3) e trimestral (3,2,4) obtiveram melhor ajuste, esses seis modelos foram os escolhidos (Tabela 5).

Cabe destacar o bom ajuste aos dados que os seis modelos selecionados apresentaram. O Apêndice 1 apresenta de forma gráfica esta análise, no qual é possível observar que os resíduos não possuem padrão ou tendência, não possuem autocorrelação e seguem uma distribuição normal dos dados, que também foi confirmada no teste de Shapiro-Wilk.

Ao analisar a acurácia dos modelos de previsão, convém iniciá-la pelo erro médio absoluto da escala (MASE), pois permite verificar se as estimativas de um modelo possuem um desempenho melhor que as obtidas por um método ingênuo. Quando o valor deste indicador é maior ou igual a um, se diz que o método é ingênuo. Neste caso, como todos os modelos apresentam o valor MASE menor que um (Tabela 5), pode-se afirmar que os modelos gerados possuem um desempenho preditivo melhor do que um método ingênuo.

Analisando os modelos (Tabela 5) por período, verificou-se que os modelos mensais possuem um maior nível de acurácia se comparado aos demais. Este aumento no erro nas séries temporais bimestrais e trimestrais em relação à série mensal também é observado nos indicadores MSE e RMSE, confirmando a maior acurácia dos modelos mensais, fato que já era esperado e ocorreu devido à sua menor variabilidade nos dados mensais.

Tabela 5

Estatísticas de erro dos modelos ARIMA

Modelo	Período	Parâmetros	MSE	RMSE	MAE	MAPE	MASE	D willmott
ARIMA SOJA	Mensal	(4,1,2)	3641	60	41	4,7%	0,988	0,960
	Bimestral	(5,2,3)	7741	88	63	7,5%	0,983	0,918
	Trimestral	(3,2,1)	12700	113	79	9,4%	0,973	0,858
ARIMA MILHO	Mensal	(2,1,2)	1074	33	21	6,0%	0,985	0,947
	Bimestral	(4,2,3)	2005	45	30	8,4%	0,950	0,906
	Trimestral	(3,2,4)	2954	54	35	10,0%	0,902	0,850

O modelo mensal gerado para o preço da soja apresentou, em média, um erro absoluto médio (MAE) de 41 dólares na cotação da tonelada da mercadoria na bolsa de Chicago, o que representou erro percentual absoluto médio (MAPE) de 4,7%, enquanto que os seus modelos bimestrais e trimestrais tiveram, respectivamente, erro percentual médio de 7,5% e 9,4% (Tabela 5). Este padrão também foi observado nos modelos desenvolvidos para o mercado do milho. O modelo mensal apresentou MAE de 21 dólares no preço da tonelada, o que representou um MAPE de 6% no valor previsto. Os modelos bimestrais e trimestrais apresentaram MAPE de 8,4% e 10%, respectivamente (Tabela 5).

Para avaliar o desempenho preditivo entre os modelos da soja e milho, é pertinente que se utilize indicadores que forneçam valores independentes da escala dos dados. Para esta análise comparativa de modelos, utilizou-se dos indicadores MAPE e o índice de concordância desenvolvido por Willmott (1981).

Com base no erro percentual absoluto médio (MAPE) é possível constatar que os modelos de previsão de preços da soja possuem maior acurácia, pois os modelos apresentam um erro percentual médio entre 4,7% a 9,4%, enquanto que os modelos para o milho possuem MAPE entre 6% a 10%. O indicador de Willmott reforça esta constatação, no qual o índice de concordância dos dados para os modelos da soja estão entre 96% a 85,8%, enquanto que para o milho este índice varia entre 94,7% a 85%. Vale ressaltar que, para ambas as culturas, os resultados obtidos por esta métrica, indicam um elevado grau de exatidão entre os valores observados e os estimados pelos modelos.

Diante disso, o presente trabalho buscou comparar os resultados obtidos a outros estudos na literatura. No entanto, pesquisas que utilizaram a técnica de modelagem ARIMA para previsão de preços de soja e milho, com séries temporais bimestrais e trimestrais não foram encontradas, apenas estudos com séries mensais. Contudo, devido a alterações de escalas e a falta de indicadores independentes da escala dos dados, não foi possível comparar os resultados com outros estudos.

4.1.2 REDES NEURAIS ARTIFICIAIS

No desenvolvimento dos modelos de redes neurais artificiais, buscou-se determinar a melhor estrutura da rede. A definição da estrutura da rede neural consiste em um processo incremental, no qual várias estruturas são geradas, estimadas e analisadas, buscando a melhor combinação de modelo estrutural. Desta forma, vários modelos com diversas combinações de parâmetros foram desenvolvidos e divididos em dois grupos (soja e milho), no qual cada grupo possui três modelos com periodicidade, mensal, bimestral e trimestral. Sendo selecionado o melhor modelo de cada grupo e tipo de período (Tabela 6).

Constatou-se que as estruturas arquiteturais selecionadas possuem a função de ativação *Maxout* e todas possuem mais de uma camada oculta (Tabela 6). De acordo com (Barreto, 2002), a utilização de camadas intermediárias (ocultas) permite solucionar problemas mais complexos, extraindo características mais significativas dos padrões de entrada.

Tabela 6

Topologia dos modelos RNAs

Modelo	Período	Função ativação	Camadas Ocultas	Neurônios camadas ocultas
RNA SOJA	Mensal	Maxout	3	(15, 10, 5)
	Bimestral	Maxout	2	(18, 12)
	Trimestral	Maxout	2	(18, 6)
RNA MILHO	Mensal	Maxout	3	(15, 15, 10)
	Bimestral	Maxout	2	(18, 18)
	Trimestral	Maxout	3	(18, 12, 6)

Após definir a arquitetura da rede, os modelos foram submetidos ao processo de treinamento e validação, no qual foi utilizado a abordagem de validação cruzada de 10 vezes.

Vale ressaltar que, devido a limitações da ferramenta, apenas os indicadores MSE, RMSE e MAE foram calculados nesta etapa. Analisando esses indicadores constatou-se que os modelos de RNAs bimestrais e trimestrais (Tabela 7) apresentaram melhor precisão de suas estimativas quando comparados aos modelos mensais. A justificativa para isto, é que os modelos bimestrais e trimestrais possuem em sua entrada de dados, a previsão do preço do modelo de período inferior, ou seja, os modelos bimestrais possuem o valor da previsão gerada pelo modelo mensal e assim, sucessivamente. Essa informação adicional na entrada de dados possibilita um melhor ajuste dos pesos e, conseqüentemente, maior acurácia do modelo.

Tabela 7

Resultados modelos RNA validação cruzada

Cultura	Período	MSE	RMSE	MAE
Soja	Mensal	2583	51	37
Soja	Bimestral	940	31	22
Soja	Trimestral	1404	37	27
Milho	Mensal	803	28	19
Milho	Bimestral	215	15	11
Milho	Trimestral	259	16	11

Além disso, pode-se constatar que, no processo de validação cruzada, os modelos RNAs apresentam um melhor desempenho preditivo conforme pode-se constatar pelas métricas erro, no qual tanto o MSE, RMSE e MAE são inferiores aos obtidos pelos modelos ARIMA.

No entanto, o presente trabalho teve como objetivo gerar previsões com dois ciclos a frentes, caracterizando numa previsão a médio prazo e, por este motivo, o processo de validação dos modelos fez uso da abordagem de previsão de dois-passos-a-frente.

Ao analisar a acurácia dos modelos de previsão (Tabela 8), pode-se observar que o erro médio absoluto da escala (MASE) de todos os modelos são menores que um, o que permite afirmar que o desempenho preditivo é melhor do que a de um método ingênuo.

Tabela 8

Resultados modelos RNAs com validação dois-passos-a-frente

Cultura	Período	MSE	RMSE	MAE	MAPE	MASE	D Willmott
SOJA	Mensal	4047	64	48	4,16%	0,961	0,922
SOJA	Bimestral	2355	49	37	3,26%	0,896	0,956
SOJA	Trimestral	648	25	17	1,52%	0,337	0,987
MILHO	Mensal	540	23	18	4,14%	0,931	0,974
MILHO	Bimestral	242	16	12	2,79%	0,587	0,989
MILHO	Trimestral	151	12	9	2,00%	0,385	0,992

Ao comparar as métricas de erro MSE, RMSE e MAE dos dois processos de validação (Tabelas 7 e 8), verificou-se um aumento do erro das estimativas no processo de validação de dois-passos-a-frente. Fato já esperado, pois o processo de validação de dois-passos-a-frente é mais robusto, avalia o erro das previsões que extrapolam o conjunto de dados de treinamento da rede.

Outro fato relevante deste processo de validação refere-se à maior acurácia dos modelos trimestrais, já que no processo de validação cruzada (Tabela 7) os modelos bimestrais foram os que apresentaram melhor desempenho preditivo.

Analisando o desempenho preditivo das RNAs no processo de validação de dois-passos-a-frente, constatou-se que os modelos apresentam um erro percentual absoluto médio (MAPE) entre 1,5% e 4% (Tabela 8), destacando-se os modelos trimestrais com MAPE de 1,52% para a soja e 2% para o milho. Este bom desempenho das previsões geradas também pode ser verificado pelo índice de concordância dos dados (indicador de Willmott), no qual os modelos da soja estão entre 92,2% a 98,7% e, para o milho, este índice varia entre 97,4% a 99,2%, o que demonstra uma alta concordância entre os valores observados e preditos.

Comparando os resultados entre os modelos ARIMA e RNAs, pode-se verificar que para as séries temporais bimestrais e trimestrais, os modelos de redes neurais apresentam um desempenho preditivo superior aos modelos ARIMA (Tabelas 5 e 8), que possuem MAPE aproximadamente 2 a 4 vezes maiores que aos modelos RNAs. A RNA teve melhor acurácia nas previsões de preços mensais para o milho. No entanto, o modelo ARIMA desenvolvido para série de dados mensais da soja, apresentou um desempenho similar ao modelo RNA, no

qual o modelo ARIMA apresentou MAPE de 4,7%, enquanto que a RNA obteve MAPE de 4,16%.

Diante disso, o presente trabalho buscou comparar os resultados obtidos a outros estudos na literatura. No entanto, pesquisas que utilizam RNA para previsão de preços de soja e milho, com séries temporais bimestrais e trimestrais não foram encontradas, desta forma, apenas os resultados das séries mensais foram comparados. Os modelos RNAs mensais gerados possuem um desempenho superior se comparado ao estudo de Ferreira & Moura (2011), no qual utilizaram RNAs para previsão de preços da soja, do boi gordo, do milho e do trigo.

Por fim, cabe destacar que o modelo ARIMA desenvolvido para série de dados mensais da soja, apresentou um similar ao modelo RNA. Porém, devido à maior robustez do processo de validação dos modelos de redes neurais artificiais aplicados na presente pesquisa, optou-se por utilizar todos os modelos RNAs gerados nas simulações de cenários econômicos para o cultivo da soja e milho. Os resultados obtidos dessas simulações são discutidos na seção seguinte.

4.2 CENÁRIOS ECONÔMICOS

Nesta seção são apresentados os resultados das simulações de cenários econômicos geradas para o cultivo da soja e milho das últimas cinco safras, compreendendo o período entre o ano de 2015 a 2019. Os cenários projetados (otimista, realista e pessimista) foram avaliados sobre a perspectiva da precisão de suas estimativas em relação ao cenário real. Além de avaliar a eficiência das estratégias de gerenciamento de riscos utilizadas na pesquisa.

Os resultados são apresentados em duas seções, uma para cada cultivo, nas quais são analisados os cenários econômicos simulados e discutido a lucratividade e os riscos financeiros envolvidos.

4.2.1 Soja

Analisando os cenários econômicos previstos e o cenário real, observa-se que o lucro operacional dos dados reais ficou dentro da faixa de valores previstos entre os cenários otimista e pessimista (Figuras 7, 8 e 9). Nas safras de 2015 a 2017, nas quais o lucro obtido no cenário real ficou mais próximo do cenário otimista, constatou-se que, de fato, houve uma produtividade acima da média, entre 59 a 65 sacas por hectare enquanto que a média era de aproximadamente 50 sc/ha, já os preços se mantiveram próximos ao previsto. No entanto, em 2019, o preço e a produtividade ficaram abaixo das estimativas, fazendo com que o cenário realista ficasse mais próximo do cenário pessimista, conforme apresentado as Figuras 7, 8 e 9 e, de forma mais detalhada, no Apêndice 2.

Além disso, outro ponto que deve ser analisado nesse tipo de empreendimento é a margem de lucro e o lucro econômico. Para as safras analisadas, o cultivo da soja apresentou em média uma margem de lucro de 34% e um lucro econômico médio de apenas R\$ 632,00, enquanto que o lucro operacional médio foi de R\$ 1315,00 (Apêndice 2). O lucro econômico é menos da metade do lucro operacional, isto ocorre porque o cultivo de grãos requer um grande investimento para aquisição da terra e maquinários. Desta forma, ao calcular, este indicador é descontado do lucro operacional o valor de remuneração da terra e do capital próprio.

Considerando que todo o processo de cultivo da soja leva em média, aproximadamente, cinco meses, e o produtor obtém em média um lucro econômico de R\$ 632 por hectare para esse período, isto representa um lucro econômico médio mensal de apenas R\$ 126 por hectare. Diante disso, pode-se afirmar que cultivo da soja apresenta um baixo lucro econômico.




Figura 7 - Cenários econômicos da soja sem Gerenciamento de Risco

Fonte: do Autor.




Figura 8 - Cenários econômicos da soja com seguro ProAgro e Barter

Fonte: do Autor.




Figura 9 - Cenários econômicos da soja com seguro ProAgro e venda antecipada Prefixada

Fonte: do Autor.

Ao avaliar as estratégias de gerenciamento de risco utilizadas, verificou-se que a alternativa de seguro ProAgro com venda prefixada foi a mais eficiente no que diz respeito à diminuição de risco sem comprometer de forma relevante a margem de lucro (Tabela 9).

A partir da média e desvio padrão do lucro operacional dos cenários gerados (todos os cinquenta mil) e por meio da distribuição normal é possível calcular a probabilidade de obter um lucro operacional igual ou menor que zero.

Diante disso, verificou-se que estratégia de seguro ProAgro com venda prefixada aplicada nas safras entre os anos de 2015 a 2019 diminuiu, em média, cerca de 12% a chance de ter prejuízos se comparado aos cenários sem gerenciamento de risco, enquanto, que a alternativa composta pelo seguro ProAgro e *barter*, diminuiu, em média, aproximadamente 10% de chances de obter prejuízo.

Neste sentido, pode-se observar que os valores de risco (Var) ao nível de 10% de significância nos cenários com gerenciamento de risco, possuem um valor positivo, tal fato, indica que esses cenários possuem mais de 90% de chances de obter lucro operacional positivo, enquanto que os cenários sem o gerenciamento, apresentaram em todos os casos, valores negativos, demonstrando a eficácia das estratégias de riscos empregadas.

Outro fato importante observado é que a utilização dessas estratégias de gerenciamento de risco não comprometeu de forma expressiva no lucro, no qual, pode-se verificar (Tabela 9) que a margem de lucro operacional para os cenários otimista, realista e o cenário com dados reais, se mantiveram muito próximas. A maior variação ocorreu no cenário pessimista, quando as operações de gerenciamento de risco se mostram eficientes.

Tabela 9

Operações de gerenciamento de risco para o cultivo da soja

Safr	Operações de Gerenciamento de Risco	Value at Risk (VaR)	Prob. Prejuízo	Cenários Margem Lucro Op.			
				Otimista	Realista	Pessimista	Real
2019	Seg. ProAgro e Venda PreFixada	R\$ 646,24	2%	51%	42%	29%	29%
	Seg. ProAgro e Barter	R\$ 418,89	5%	52%	40%	25%	28%
	Sem operações	-R\$ 294,05	13%	53%	38%	14%	24%
2018	Seg. ProAgro e Venda PreFixada	R\$ 281,43	4%	43%	33%	19%	36%
	Seg. ProAgro e Barter	R\$ 136,48	7%	43%	32%	16%	36%
	Sem operações	-R\$ 392,51	16%	47%	31%	7%	38%
2017	Seg. ProAgro e Venda PreFixada	R\$ 314,30	4%	44%	33%	20%	44%
	Seg. ProAgro e Barter	R\$ 157,34	7%	44%	32%	17%	44%
	Sem operações	-R\$ 456,66	17%	47%	30%	5%	44%
2016	Seg. ProAgro e Venda PreFixada	R\$ 431,50	4%	50%	40%	25%	47%
	Seg. ProAgro e Barter	R\$ 242,81	6%	51%	39%	22%	47%
	Sem operações	-R\$ 470,73	16%	53%	36%	8%	47%
2015	Seg. ProAgro e Venda PreFixada	R\$ 184,32	6%	44%	33%	18%	43%
	Seg. ProAgro e Barter	R\$ 78,60	8%	45%	32%	15%	43%
	Sem operações	-R\$ 454,74	20%	47%	29%	0%	44%

Além disso, vale frisar que a alternativa com operação de venda prefixada obteve a maior média de lucro operacional (R\$ 1.513,21) por hectare considerando o período analisado, seguido pela alternativa com operação de *barter* com lucro de R\$ 1.506,52 por hectare; e, por último, a opção sem gerenciamento de risco com lucro de R\$ 1.485,36 por hectare.

4.2.2 Milho

Ao analisar os cenários econômicos gerados para o cultivo do milho, pode-se observar que o lucro operacional obtido no cenário real, na maioria das vezes, esteve dentro da faixa de valores previstos entre os cenários otimista e pessimista (Figuras 10, 11 e 12).

Nas safras de 2015, 2016 e 2019 nas quais o lucro obtido no cenário real ficou mais próximo do cenário otimista, constatou-se que, de fato, houve uma produtividade acima da média. Em 2015, a região oeste do Paraná, obteve uma produtividade média de 115 sacas por hectare, muito acima da média dos anos anteriores (74 sc/ha). Em 2016 também houve um produtividade acima da média, pois foram colhidas 92 sacas por hectare enquanto que a média esperada era de 82 sc/ha. Para 2019, a produtividade média prevista foi de 90 sc/ha, no entanto, foram colhidas 117 sc/ha neste ano. Já os preços para essas safras se mantiveram próximos ao previsto. Por este motivo, o cenário real dessas safras tiveram uma lucratividade mais próxima do cenário otimista.

Entretanto, a simulação para a safra de 2017 superestimou o preço do grão no mercado nacional. O valor previsto foi de R\$ 24,00 a saca, porém, a cotação real ficou em R\$ 18, fazendo com que o cenário real ficasse mais próximo ao cenário pessimista, conforme pode-se verificar nas Figuras 10, 11 e 12 e de forma mais detalhada no Apêndice 2.

Analisando a margem de lucro e o lucro econômico das safras de milho, verificou-se que este empreendimento apresentou, em média, uma margem de lucro de apenas 1% e um lucro econômico médio negativo (prejuízo) de R\$ 569, enquanto que o lucro operacional médio foi de apenas R\$ 186,00 por hectare (Apêndice 2).

Ao comparar a margem de lucro e o lucro econômico do cultivo do milho com os da soja, constatou-se que o cultivo da soja apresenta valores superiores em ambos os indicadores. Diante disso, pode-se afirmar que cultivo da soja demonstrou-se economicamente um empreendimento mais vantajoso se comparado ao milho. Além disso, o fato do cultivo do milho apresentar lucro econômico médio negativo sugerindo que esta atividade não seja viável, sendo

imprescindível que o gestor faça uma análise minuciosa do mercado, antes de decidir pelo seu cultivo.

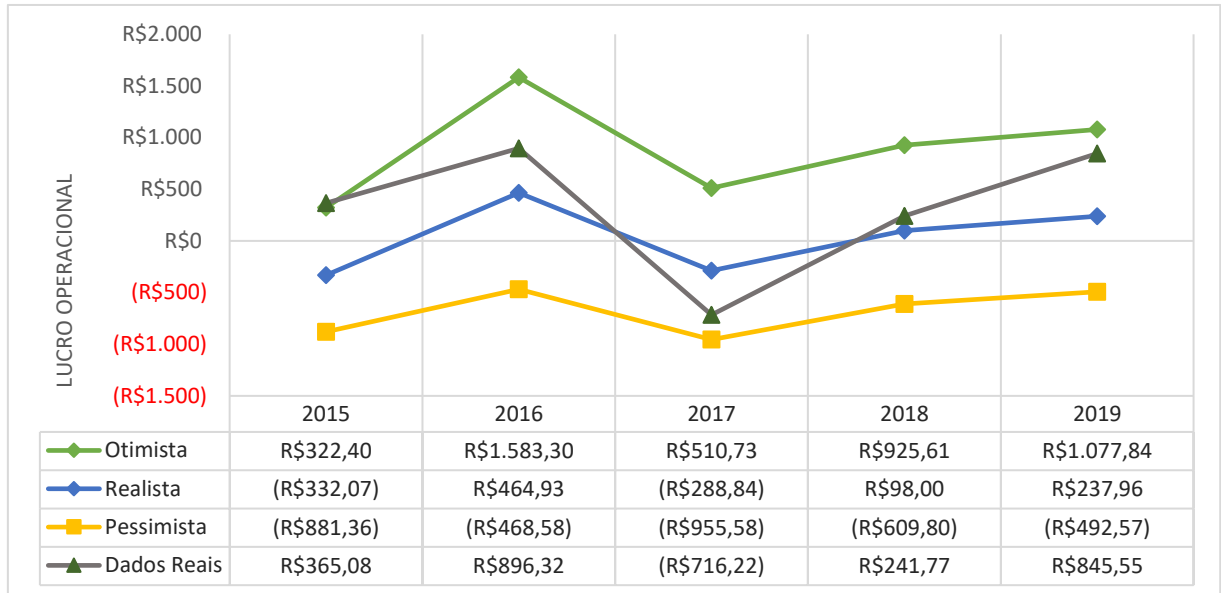


Figura 10 - Cenários econômicos do milho sem Gerenciamento de Risco

Fonte: do Autor.




Figura 11 - Cenários econômicos do milho com seguro ProAgro e Barter

Fonte: do Autor.




Figura 12 - Cenários econômicos do milho com seguro ProAgro e venda antecipada PreFixada

Fonte: do Autor.

Ao avaliar as estratégias de gerenciamento de risco utilizadas, verificou-se que a alternativa de *barter* com seguro ProAgro foi a mais eficiente na diminuição dos riscos para o cultivo do milho. Esta estratégia apresentou os menores valores de risco (Tabela 10), de acordo com o indicador VaR ao nível de 10% de significância. No entanto, ao contrário do cultivo da soja, todos os cenários gerados apresentam valores negativos, o que significa que o cultivo do milho nas safras analisadas tiveram mais de 10% de chances de obter prejuízo em todos os cenários projetados.

Em média, o valor de risco para o cultivo do grão utilizando seguro e *barter* ficou em R\$ 451,53 de prejuízo, já o cultivo utilizando venda prefixada obteve uma média de R\$ 728,60 negativos, enquanto que o cultivo sem gerenciamento de risco apresentou em média R\$ 1.090,20 de prejuízo.

Outro fato importante observado é que a utilização da operação de *barter* diminuiu consideravelmente a possibilidade de obter lucros maiores, diferentemente do que foi observado no cultivo da soja. Isto ocorreu porque a safra de milho no período analisado necessitou de um percentual elevado da produção para cobrir os custos do plantio.

No entanto, a estratégia de *barter* obteve a maior média de lucro operacional (R\$ 421,79) considerando o período analisado, seguido pela alternativa de venda prefixada com

lucro de R\$ 366,25; e, por último, a opção sem gerenciamento de risco com lucro operacional de R\$ 326,50.

Tabela 10

Operações de gerenciamento de risco para o cultivo do milho

Safra	Operações de Gerenciamento de Risco	Value at Risk (VaR)	Prob. Prejuízo	Cenários Margem Lucro Op.			
				Otimista	Realista	Pessimista	Real
2019	Seg. ProAgro e Venda PreFixada	-R\$ 732,35	35%	30%	10%	-19%	19%
	Seg. ProAgro e Barter	-R\$ 438,95	34%	19%	7%	-10%	26%
	Sem operações	-R\$ 911,55	37%	30%	8%	-24%	25%
2018	Seg. ProAgro e Venda PreFixada	-R\$ 714,34	38%	28%	7%	-24%	14%
	Seg. ProAgro e Barter	-R\$ 359,55	28%	24%	10%	-8%	9%
	Sem operações	-R\$ 1.016,76	42%	28%	4%	-35%	9%
2017	Seg. ProAgro e Venda PreFixada	-R\$ 876,98	54%	18%	-7%	-43%	-29%
	Seg. ProAgro e Barter	-R\$ 616,93	74%	4%	-11%	-31%	-17%
	Sem operações	-R\$ 1.320,27	59%	18%	-15%	-73%	-46%
2016	Seg. ProAgro e Venda PreFixada	-R\$ 500,71	25%	41%	21%	-9%	30%
	Seg. ProAgro e Barter	-R\$ 212,92	18%	36%	21%	1%	27%
	Sem operações	-R\$ 1.014,59	32%	41%	17%	-25%	28%
2015	Seg. ProAgro e Venda PreFixada	-R\$ 818,60	60%	14%	-12%	-48%	15%
	Seg. ProAgro e Barter	-R\$ 629,32	89%	-4%	-19%	-38%	18%
	Sem operações	-R\$ 1.187,84	65%	14%	-20%	-78%	15%

Diante disso, pode-se afirmar que o cultivo da soja apresenta uma lucratividade média muito superior, obtendo lucros quatro vezes maiores se comparado ao cultivo do milho. Além disso, o cultivo do milho apresenta uma probabilidade maior de ter prejuízos.

4.3 SISTEMA COMPUTACIONAL

Nesta seção são apresentadas as funcionalidades implementadas no sistema computacional para a simulação de cenários econômicos da soja e do milho. Este *software* atua sobre uma plataforma *World Wide Web (WEB)*, ou seja, pode ser acessado por meio da internet.

Diante disso, o sistema possui uma arquitetura centralizada, ou seja, os dados são armazenados e atualizados em um servidor central. Desta forma, o usuário final não precisa

atualizar os dados ou manutenções no sistema, sendo esta tarefa atribuída ao responsável pelo servidor central. Para ter acesso ao sistema, a pessoa deverá ter um cadastro de login e senha.

O *software* possui um *layout* simples e intuitivo, composto por um menu superior que dá acesso às demais funcionalidades que são: cadastro de custos de produção, série histórica, previsões, simulação de cenários econômicos e ajuda (Figura 13).

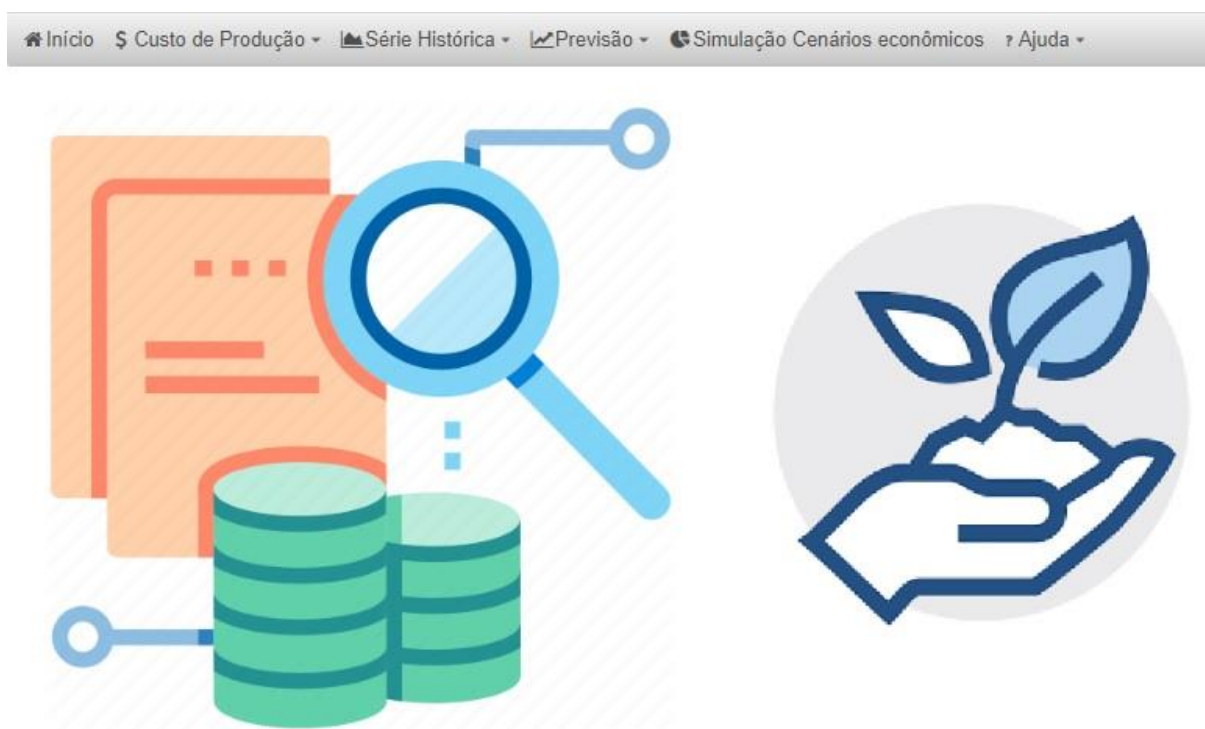


Figura 13 - Tela inicial do sistema

Fonte: do Autor.

O sistema possui um cadastro de custos de produção para o cultivo da soja e do milho. Este cadastro foi baseado na planilha de custos de produção disponibilizada pela SEAB, contém informações detalhadas, bem como, fertilizantes, sementes, depreciação com maquinários entre outras, sendo organizadas em três grupos de custos (custos variáveis, custos fixos e custos de oportunidade) (Figura 14). No sistema, já foram cadastrados os custos de produção da soja e do milho entre período de 2013 a 2019, com os respectivos dados fornecidos pela SEAB. No entanto, o sistema possibilita que o usuário cadastre seu próprio custo de produção.

Cadastro de Custos de Produção

Cultura: <input type="text" value="Soja"/>	Descrição: <input type="text" value="Custos de Produção Soja - SEAB Ago/2019"/>
Mês: <input type="text" value="8"/> Ano: <input type="text" value="2019"/>	Unid. Medida: <input type="text" value="sc/ha"/> Prod. média: <input type="text" value="60 sc/ha"/> Preço médio: <input type="text" value="70,00 R\$"/>

Custos Variáveis		Valor Total: R\$ 2.103,88/ha
Op. de máquinas e implementos <input type="text" value="356,34 R\$"/>	Desp. de manutenção de benfeitorias <input type="text" value="35,76 R\$"/>	
Mão-de-obra temporária <input type="text" value="43,63 R\$"/>	Sementes <input type="text" value="424,20 R\$"/>	
Fertilizantes <input type="text" value="511,34 R\$"/>	Agrotóxicos <input type="text" value="422,57 R\$"/>	
Despesas gerais <input type="text" value="33,00 R\$"/>	Transporte externo <input type="text" value="103,95 R\$"/>	
Assistência técnica <input type="text" value="36,54 R\$"/>	Seguro/PROAGRO <input type="text" value="53,82 R\$"/>	
Juros <input type="text" value="82,73 R\$"/>		

Custos Fixos		Valor Total: R\$ 620,58/ha
Dep. máquinas e implementos <input type="text" value="284,67 R\$"/>	Dep. benfeitorias e instalações <input type="text" value="47,68 R\$"/>	
Correção do solo <input type="text" value="94,09 R\$"/>	Cultura <input type="text" value="0,00 R\$"/>	
Seguro do capital <input type="text" value="24,46 R\$"/>	Mão-de-obra permanente <input type="text" value="169,68 R\$"/>	

Custos de Oportunidade		Valor Total: R\$ 815,21/ha
Remuneração do Capital próprio <input type="text" value="212,47 R\$"/>	Remuneração da terra <input type="text" value="602,74 R\$"/>	

Custo Operacional: R\$ 2.724,46/ha	Custo Total: R\$ 3.539,67/ha
---	-------------------------------------

Figura 14 - Cadastro de custos de Produção

Fonte: do Autor.

O sistema provê uma tela para visualizar e analisar dados históricos, fornecendo informações de cinco itens (cotação da soja, cotação do milho, cotação do dólar, produtividade da soja e produtividade do milho), esses dados são projetados em um gráfico de linha (Figura 15). Neste gráfico é possível ampliar ou diminuir a área projetada e aplicar filtro na linha temporal dos dados.

Esta funcionalidade possibilita ao gestor uma análise histórica sobre determinada informação, permitindo verificar padrões e tendências no dados.




Figura 15 - Série Histórica

Fonte: do Autor.

Além disso, é possível visualizar, analisar e comparar os dados históricos com os dados previstos (Figura 16). As previsões dos preços da soja, milho e dólar podem ser visualizadas por tipos de períodos (mensal, bimestral e trimestral), exibindo-as de forma simultânea ou selecionando apenas os tipos de períodos desejados. Esta funcionalidade permite ao gestor verificar o quão precisas são as previsões geradas pelo sistema.

Vale ressaltar que as previsões visualizadas nessa tela são geradas pelas RNAs - no caso da soja e do milho. Para o dólar são as previsões coletadas do BACEN. E, para as produtividades da soja e do milho são realizadas estimativas com base nos dados históricos.

Outro ponto importante a frisar é que as estimativas de produtividade para o presente estudo foram feitas para a região oeste do estado do Paraná. No entanto, pode-se coletar dados de produtividade para qualquer outra região, não restringindo o sistema a uma localidade específica.




Figura 16 – Previsões

Fonte: do Autor

Por fim, tem-se a simulação de cenários econômicos. Para iniciar a simulação é necessário selecionar algumas configurações, bem como, a cultura (soja ou milho), data de início e término da simulação, selecionar o custo de produção, seguro agrícola e as opções de venda antecipada. Os modelos de estimativa de produtividade, previsão de preço da *commodity* e previsão do dólar, já vem selecionados por padrão e não há outras opções para selecionar (Figura 17).

Simulação de Cenários Econômicos

Configurações

Cultura: <input type="text" value="Soja"/>	Data Início: <input type="text" value="01/10/2017"/>	Data Término: <input type="text" value="01/02/2018"/>
Custo Produção: <input type="text" value="1 - Custo produção Soja - SEAB Fev/2018"/>	Custo Operacional: R\$ 2.376,03/ha	Custo Total: R\$ 3.169,81/ha
Est. Produtividade: <input type="text" value="Média (últimos 5 anos) SEAB-PR"/>	Prod. Média: 3.354	Prod Desvio Padrão: 545
Modelo Prev. Preço: <input type="text" value="Redes Neurais"/>	Valor Premio: 2.85	Desv Pad. Premio: 2.11
Modelo Prev. Dólar: <input type="text" value="Banco Central - BACEN"/>		

Seguro ProAgro? Venda Antecipada?

[Carregar Estimativas](#)

Estimativas

Previsão	Mês/Ano	Valor Previsto	Limite Inferior	Limite Superior	Visualizar
Preço Soja	02/2018	R\$ 1.034,06	R\$ 831,49	R\$ 1.236,63	View
Cotação Dólar	02/2018	R\$ 3,18	R\$ 2,88	R\$ 3,42	View

[Gerar Cenários](#)

Figura 17- Configuração da simulação de cenários econômicos

Fonte: do Autor

Após configurar os parâmetros da simulação é necessário carregar as estimativas, sendo possível também visualizá-las (Figura 17) para, posteriormente, gerar a simulação.

Os resultados da simulação são exibidos em outra tela, composta por um gráfico que projeta o lucro operacional do cenários otimista, realista, pessimista e dados reais, além de apresentar tabelas com informações financeiras e de risco (Figura 18).

As informações financeiras consistem em: custo operacional, custo econômico, produtividade, preço, receita bruta, lucro operacional, lucro econômico e margem de lucro. Já as informações de risco, referem-se ao indicador de valor de risco (VaR) aos níveis de significância de 1%, 5% e 10% e as probabilidades. São calculadas as seguintes probabilidades: a probabilidade de obter prejuízo, a probabilidade de obter lucro operacional menor ou igual ao lucro operacional previsto nos cenário pessimista, realista e otimista.

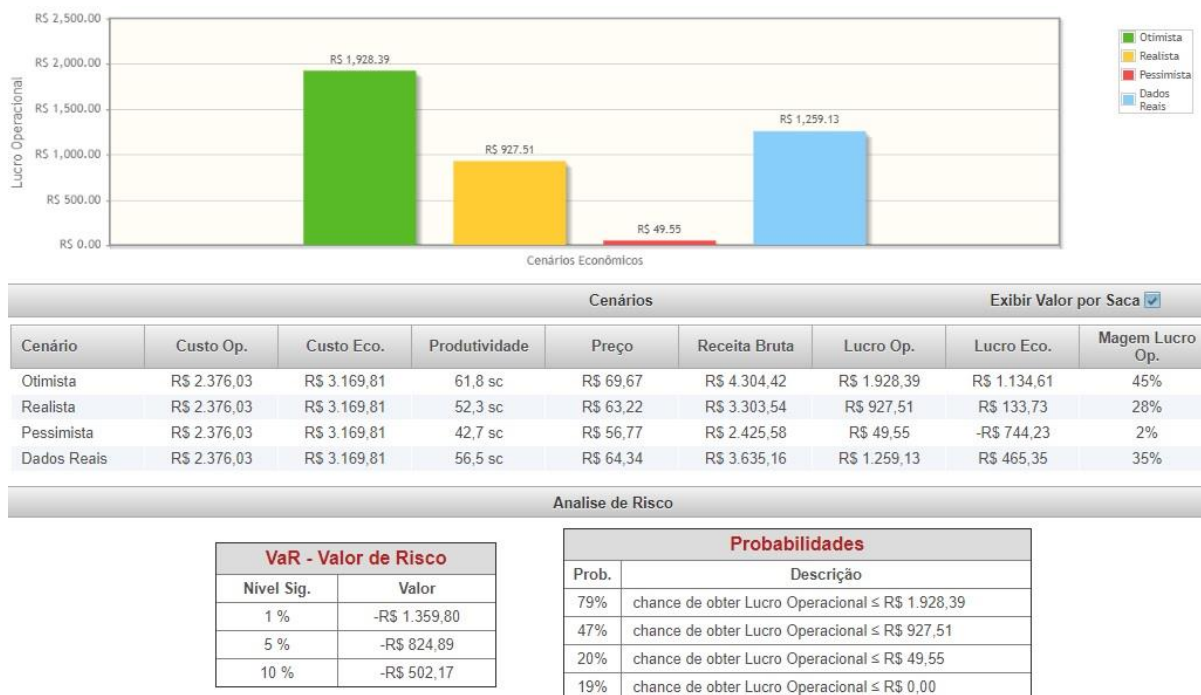


Figura 18 - Resultados simulação de cenários econômicos

Fonte: do Autor

Esse conjunto de informações permite ao gestor uma análise detalhada da viabilidade do cultivo e seus riscos financeiros, além de oferecer a possibilidade de realizar várias simulações com diferentes estratégias de gerenciamento de risco, de custos de produção e de datas para início e término da simulação, para ambos os cultivos.

Por fim, cabe ressaltar que a simulação computacional de cenários econômicos é uma ferramenta que possibilita projetar e analisar diversos cenários econômicos em pequeno intervalo de tempo a um baixíssimo custo, tornando-a uma ferramenta de grande relevância, auxiliando os gestores no processo de tomada de decisão.

5 CONCLUSÃO

A presente pesquisa se propôs a desenvolver um sistema computacional para simulação de cenários econômicos para o cultivo da soja e milho com objetivo de avaliar viabilidade e mensurar os riscos envolvidos, auxiliando os gestores na tomada de decisão.

Os modelos de previsão de preços foram mais precisos com uso de RNAs do que com ARIMA. Quanto à qualidade das previsões geradas pelos modelos, o bom desempenho preditivo foi constatado pelos indicadores MASE, MAE, MAPE e o índice de concordância de Willmott. As RNAs geradas para previsão de preço da soja apresentaram MAE entre 16 a 41 dólares por tonelada do produto e MAPE entre 1,5% a 4,7% e índice de concordância entre os valores observados e estimados entre 95% a 98%. Este bom desempenho também foi observado nos modelos de previsão de preços do milho, que apresentaram MAE entre 12 a 23 dólares por tonelada, MAPE entre 2% a 4% e índice de concordância Willmott entre 97% a 99%.

Quanto aos cenários simulados, concluiu-se que cultivo da soja possui uma lucratividade maior, com menor chance de obter prejuízos, se comparado ao cultivo do milho. Destacou-se que o cultivo do milho para o período analisado apresentou lucro econômico médio negativo, o que sugere que esta atividade não seja viável, sendo imprescindível que o gestor faça uma análise minuciosa do mercado antes de decidir pelo seu cultivo.

Além disso, verificou-se que as estratégias de gerenciamento de risco se demonstraram eficientes, reduzindo os riscos, sem comprometer a lucratividade do empreendimento, conforme observou-se que, os cenários com dados reais que fizeram uso de estratégias de gerenciamento de risco, tiveram um lucro médio superior ao cenário real sem o gerenciamento.

Diante disso, pode-se afirmar que a utilização de ferramentas de simulação de cenários econômicos para o cultivo de grãos (soja e milho) é de grande relevância, pois permite ao gestor estimar os lucros de cada cultivo e mensurar os riscos financeiros envolvidos, além de avaliar o impacto da utilização de estratégias de gerenciamento de risco. Todo esse conjunto de informações auxilia, de forma significativa, os gestores na tomada de decisão, seja na decisão

de qual cultura irá fazer o plantio ou na elaboração de ações (seguro ou venda antecipada) para minimizar as chances de obter prejuízos ao final da safra.

Vale frisar que o sistema computacional desenvolvido é a principal contribuição deste estudo, pois não há ferramenta semelhante na literatura. Sendo uma alternativa eficiente para produtores, empresários rurais, consultores, cooperativas, agroindústrias, entre outros participantes deste mercado.

Vale frisar que embora a pesquisa utilizou-se de informações de produtividade da região oeste do estado do Paraná, o software não possui restrições quanto à localidade, basta apenas inseri-las na base de dados.

No entanto, cabe ressaltar que as estimativas de produtividade geradas nos cenários simulados em vários casos não tiveram uma boa precisão, gerando estimativas geralmente abaixo do valor real, ao contrário do que foi observado para a variável preço, no qual suas estimativas tiveram um alto nível de precisão, comprovando o bom desempenho preditivo dos modelos RNAs desenvolvidos.

Quanto à limitação da pesquisa, destaca-se que a estimativa de produtividade de safra, na qual foi baseada em uma média histórica, não se demonstrou eficiente nas simulações, sendo esta uma proposta para futuras pesquisas. Além disso, é pertinente realizar estudos visando aumentar a gama de cultivos e de estratégias de gerenciamento de risco para ser utilizados nas simulações.

REFERÊNCIAS

- Abreu, P., & Stephan, C. (1982). *Análise de Investimentos*. Rio de Janeiro: Campus.
- Abussamra, L. . (2006). Gestão de riscos no agronegócio. *Revista AgroAnalysis*, 26.
- Acadrolí, I. L. (2000). *A influência do orçamento de despesas operacionais no desempenho dos gestores e no resultado de uma empresa comercial: o caso da agrofel comércio de produtos agrícolas ferrarin Ltda* ((Dissertação de Mestrado). Pós-Graduação em Administração. Universidade Federal de Santa Catarina). Retrieved from <https://repositorio.ufsc.br/xmlui/bitstream/handle/123456789/78692/174716.pdf?sequence=1&isAllowed=y>
- Aguiar, S. da C. G. do E. S. (2014). *Previsão do preço da Commodity do Butadieno a partir do uso de redes Bayesianas* (UFRGS). Retrieved from <https://lume.ufrgs.br/handle/10183/127232>
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. <https://doi.org/10.1109/TAC.1974.1100705>
- Amaral Júnior, J. B., & Távora Júnior, J. L. (2010). Uma análise do uso de redes neurais para a avaliação do risco de crédito de empresas. *Revista Do BNDES*, 1(34), 133–180. Retrieved from <https://web.bndes.gov.br/bib/jspui/handle/1408/3071>
- Andrade, E. L. (1998). *Introdução à pesquisa operacional – métodos e modelos para análise de decisão*. Rio de Janeiro: Livros Técnicos e Científicos Editora.
- Arruda, A. F. de. (2008). *Macroeconomia e preços de commodities agrícolas* (Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo). <https://doi.org/10.11606/D.11.2008.tde-24072008-123523>
- Assaf Neto, A. (2010). *Finanças corporativas e valor* (5th ed.). São Paulo: Atlas.
- Assis, J. P., Neto, D. D., Nass, L. L., Manfron, P. A., Garcia Bonnacarrère, R. A., & Martin, T. N. (2006). Stochastic simulation of climate parameters and potential productivity of maize using triangular distribution. *Pesquisa Agropecuaria Brasileira*, 41(3), 539–543. <https://doi.org/10.1590/S0100-204X2006000300024>
- BACEN. (2019). *PROAGRO – Programa de garantia da atividade agropecuária: resumo de instruções para beneficiário*.
- Barreto, J. M. (2002). *Introdução às redes neurais artificiais*. Florianópolis: UFSC.
- Bellaloui, N., Yin, X., Mengistu, A., McClure, A. M., Tyler, D. D., & Reddy, K. N. (2013).

- Soybean seed protein, oil, fatty acids, and isoflavones altered by potassium fertilizer rates in the midsouth. *American Journal of Plant Sciences*, 04(05), 976–988.
<https://doi.org/10.4236/ajps.2013.45121>
- Boerma, H. ., & Specht, J. E. (2004). *Soybeans: improvement, production and uses* (3rd ed.). Madison: American Society of Agronomy.
- Boone, L. E., & Kurtz, D. L. (1998). *Marketing contemporâneo* (8th ed.). Rio de Janeiro: LTC.
- Box, G., & Jenkins, G. (1970). *Time series analysis: forecasting and control*. San Francisco: Holden-Day.
- Bressan, A. A., & de Lima, J. E. (2009). Modelos de previsão de preços aplicados aos contratos futuros de boi gordo na BM&F. *Nova Economia*, 12(1).
- Brockwell, P. J., & Davis, R. A. (2010). *Introduction to time series and forecasting* (2nd ed.). New York: Springer.
- BUAINAIN, A. M., VIEIRA, P. A., & CURY, W. J. M. (2011). *Gestão do risco e seguro na agricultura brasileira*. Rio de Janeiro: Funenseg.
- Buarque, S. C. (2003, February). Metodologia e técnica de construção de cenários globais e regionais. *Textos Para Discussão PEA*.
- Burgo, M. N. (2005). *Caracterização espacial de riscos na agricultura e implicações para o desenvolvimento de instrumentos para seu gerenciamento*. (Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo). <https://doi.org/10.11606/D.11.2005.tde-09052005-140315>
- Burnham, K. P., & Anderson, D. R. (2003). *Model selection and multimodel inference: a practical information-theoretic approach* (2nd ed.). New York: Springer.
- Carvalho, A. C. P. de L. F., Braga, A. de P., & Ludermir, T. B. P. P.-R. de J. (1998). *Fundamentos de redes neurais artificiais* (p. 246). p. 246. Rio de Janeiro: DCC/IM, COPPE/Sistemas, NCE-UFRJ.
- Casaroto Filho, N., & Kopittke, B. H. (2000). *Análise de investimentos: matemática financeira, engenharia econômica, tomada de decisão, estratégia empresarial* (9th ed.). São Paulo: Atlas.
- Castro, A. L. S. (2002). *Gerenciamento de risco de mercado para produtores de commodities no Brasil* (FGV EAESP). Retrieved from <https://bibliotecadigital.fgv.br/dspace/handle/10438/5494>

- Cavalcanti, M., & Plantullo, V. L. (2007). *Análise e elaboração de projetos de investimento de capital: sob uma nova ótica*. Curitiba: Juruá.
- CBOT. (2019). *CME Group - Chicago Board of Trade (CBOT)*. Retrieved from <https://www.cmegroup.com/company/cbot.html>
- Ceretta, P. S., Righi, P. B., & Schlender, S. G. (2010). Previsão do preço da soja: uma comparação entre os modelos ARIMA e redes neurais artificiais. *Informações Econômicas*, 40(9), 15–27.
- CONAB. (2017). *Perspectivas para a agropecuária – safra 2017/2018* (No. 5). Retrieved from <https://www.conab.gov.br/institucional/publicacoes/perspectivas-para-a-agropecuaria>
- Crawford, J. . (2011). *The strategic project office*. New York: Marcel Dekker.
- Crundwell, F. (2008). *Finance for engineers: evaluation and funding of capital projects*. London: Springer-Verlag London Limited.
- Diniz, H. (2018). *Integração de Redes Neurais Artificiais & Métodos Estocásticos para Previsão de Séries Temporais* (Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo). <https://doi.org/10.11606/D.55.2018.tde-06032018-110702>
- Donatelli, G. D., & Konrath, A. C. (2005). Simulação de Monte Carlo na avaliação de incertezas de medição. *Revista de Ciência & Tecnologia*, 25(13), 5–15.
- Drucker, P. F. (1998). *Introdução à administração* (3rd ed.). São Paulo: Pioneira.
- Enders, W. (1996). *Rats handbook for econometric time series*. New York: John Wiley.
- Evans, J. R., & Olson, D. L. (1998). *Introduction to simulation and risk analysis*. New Jersey: Prentice Hall.
- Fauseff, L. (1994). *Fundamentals of Neural Networks: architectures, algorithms and applications* (1st ed.). Prentice Hall.
- Fava, V. L. (2000). Análise de Séries de Tempo. In M. A. S. Vasconcellos & D. Alves (Eds.), *Manual de econometria: nível intermediário*. São Paulo: Atlas.
- Ferreira, I. (2016). *Opções sobre Commodities* (ISCTE-IUL). Retrieved from <http://hdl.handle.net/10071/13097>
- Ferreira, L., de Moura, G. L., Borenstein, D., & Fischmann, A. A. (2011). Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. *RAI Revista de Administração e Inovação*, 8(4), 6–26. <https://doi.org/10.5773/RAI.V8I4.475>

- Ferreira, L., & Moura, G. de. (2011). UTILIZAÇÃO DE REDES NEURAIIS ARTIFICIAIS COMO ESTRATÉGIA DE PREVISÃO DE PREÇOS NO CONTEXTO DE AGRONEGÓCIO. *RAI-Revista de ...*, 8(4), 6–26. <https://doi.org/10.5773/RAI.V8I4.475>
- Forigo, E. M., Zago, C. A., & Abreu, L. F. (2010). *O hedge como ferramenta para diminuição dos riscos nas operações financeiras de uma cooperativa de agroalimentos*. Retrieved from http://www.inovarse.org/sites/default/files/T10_0229_1249_3.pdf
- Gitman, L. J. (2010). *Princípios de administração financeira* (12th ed.). <https://doi.org/10.1017/CBO9781107415324.004>
- Gomes, A. G. (2000). Administração de riscos: como proteger-se contra riscos na agricultura. *Agriannual 2000: Anuário Da Agricultura Brasileira*.
- Goodfellow, I. J., Warde-Farley, D., Mirza, M., Courville, A., & Bengio, Y. (2013). *Maxout Networks*. Retrieved from <https://arxiv.org/abs/1302.4389>
- Gujarati, D. N. (2006). *Econometria básica* (4th ed.). Rio de Janeiro: Elsevier.
- Harwood, J. L., Heifner, R., Coble, K., Perry, J., & Somwaru, A. (1999). Managing risk in farming: concepts, research, and analysis. *Agricultural Economic Report*, 83.
- Haykin, S. (2001). *Redes neurais: princípios e prática* (2nd ed.). Porto Alegre: Bookman.
- Haykin, Simon. (1998). *Neural Networks: A Comprehensive Foundation* (2nd ed.). Upper Saddle River, NJ, USA: Prentice Hall PTR.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *2015 IEEE International Conference on Computer Vision (ICCV)*, 1026–1034. <https://doi.org/10.1109/ICCV.2015.123>
- Holanda, N. (1975). *Planejamento e projetos, uma introdução às técnicas de planejamento e de elaboração de projetos* (3rd ed.). Rio de Janeiro: APEC.
- Hull, J. (1995). *Introdução aos mercados futuros e de opções* (2nd ed.). São Paulo: Prentice Hall.
- IBGC. (2017). *Gerenciamento de riscos corporativos evolução em governança e estratégia* (19th ed.). Retrieved from www.ibgc.org.br
- Jorion, P. (1999). *Value at risk: the new benchmark for controlling derivatives risk*. Chicago: Irwin.
- Kassai, J. R., Casanova, S. P. de C., & Santos, A. dos. (2005). *Retorno do investimento: abordagem matemática e contábil do lucro empresarial* (3rd ed.). São Paulo: Atlas.

- Kerzner, H. (2006). *Gestão de projetos: As melhores práticas* (2nd ed.). São Paulo: Bookman.
- Khashei, M., & Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with Applications*, 37(1), 479–489.
<https://doi.org/10.1016/J.ESWA.2009.05.044>
- Knight, F. H. (1921). *Risk, uncertainty and profit*. Washington: Beard Books.
- Lima, R. C., Góis, M. R., & Ulises, C. (2007). Previsão de preços futuros de commodities agrícolas com diferenciações inteira e fracionária, e erros heteroscedásticos. *Revista de Economia e Sociologia Rural*, 45(3), 621–644. <https://doi.org/10.1590/S0103-20032007000300004>
- Lozardo, E. (1998). *Derivativos no Brasil: fundamentos e práticas* (1st ed.). São Paulo: BM&F.
- Lunkes, R. J. (2003). *Manual de orçamento*. São Paulo: Atlas.
- Lustosa, P. R. B., Ponte, V. M. R., & Dominas, W. R. (2004). Simulação. In L. J. Corrar & C. R. Theòphilo (Eds.), *Pesquisa operacional para decisão em contabilidade e administração*. São Paulo: Atlas.
- MAPA. (2017). *Guia de Seguros Rurais*.
- Margarido, M. A. (1998). *Transmissão de preços internacionais de suco de laranja para preços ao nível de produtor de laranja no Estado de São Paulo*. IEA São Paulo.
- Marshall, A. (1890). *Principles of Economics*. <https://doi.org/10.1057/9781137375261>
- Martins, T. M., & Martinelli, D. P. (2010). Ciclos e previsão cíclica dos preços de commodities: um modelo indicador antecedente para commodity açúcar. *Revista de Administração, Contabilidade e Economia*, 2, 2–12.
- Matias, M. A., Silva, C. A. T., & Vieira, L. (2005). Análise de padrões de comportamento de preços com fins de projeção de receita: testes estatísticos em uma série temporal de preços da commodity cobre. *Brazilian Business Review*, 2(2), 1–17. Retrieved from http://www.bbbronline.com.br/artigos.asp?sessao=ready&cod_artigo=271
- Megliorini, E., & Vallim, M. A. (2009). *Administração financeira: uma abordagem brasileira*. São Paulo: Pearson Prentice Hall.
- Menezes, I. D. R. de. (2015). *Revisão da literatura empírica acerca das variáveis que impactam a precificação de commodities agrícolas : soja, milho, café e boi gordo* (Universidade de Brasília). Retrieved from <http://bdm.unb.br/handle/10483/11093>
- Miguez, G. A. (2012). *Otimização do algoritmo de Backpropagation pelo uso da função de*

ativação bi-hiperbólica. UFRJ.

- Mina, J., & Xiao, J. Y. (2001). *Return to RiskMetrics: the evolution of a standard*. Retrieved from www.riskmetrics.com
- Montgomery, D. C., Johnson, L. A., & Gardiner, J. S. (1990). *Forecasting and time series analysis* (2nd ed.). New York: McGraw-Hill.
- Montgomery, D., & Runger, G. (2016). *Estatística aplicada e probabilidade para engenheiros* (6th ed.). Rio de Janeiro: LTC.
- Moreira, V. R. (2009). *Gestão dos riscos do agronegócio no contexto cooperativista* (Tese (Doutorado) - Escola de Administração de Empresas de São Paulo). Retrieved from <https://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/4610/71050100638.pdf>
- Morettin, P. A., & Tolói, C. M. C. (2006). *Análise de séries temporais* (2nd ed.). São Paulo: Edgard Blücher.
- Motta, R. da R., & Calôba, G. M. (2009). *Análise de investimentos: tomada de decisões em projetos industriais* (1st ed.). São Paulo: Atlas.
- Nascimento, C. C. (2008). *Uma reflexão sobre os possíveis impactos do crescimento da demanda dos biocombustíveis da oferta e preços das commodities agrícolas* (Universidade Federal de Pernambuco). Retrieved from <https://repositorio.ufpe.br/handle/123456789/3864>
- Nehmi, V. (2012). Por que commodities são cíclicas? Retrieved August 2, 2018, from <https://verios.com.br/blog/por-que-commodities-sao-ciclicas/>
- Neves, C. (1982). *Análise de investimentos: Projetos Industriais e engenharia econômica*. Rio de Janeiro: Zahar.
- Pegden, C. D., Shannon, R. E., & Sadowski, R. P. (1990). *Introduction to simulation using SIMAN* (2nd ed.). New York: McGraw-Hill.
- Pereira, L. M. (2009). *Modelo de formação de preços de commodities agrícolas aplicado ao mercado de açúcar e álcool* (Universidade de São Paulo). <https://doi.org/10.11606/T.12.2009.tde-04062009-155921>
- Phillips, P. C. B., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335–346. <https://doi.org/10.1093/biomet/75.2.335>
- PMBOK. (2012). *Guides. PMI* (5th ed.). PMI.
- Prechelt, L. (1994). *PROBEN 1 - a set of benchmarks and benchmarking rules for neural network training algorithms*.

- Reibstein, D. J., & Chussil, M. J. (1999). Primeiro a lição, depois o teste: usando simulações para analisar e desenvolver estratégias competitivas. In Day, G. S. & Reibstein, D. J. *A dinâmica da estratégia competitiva*. Rio de Janeiro: Campus.
- Ribeiro, C. D. O., Sosnoski, A. A. K. B., & Oliveira, S. M. de. (2010). Um modelo hierárquico para previsão de preços de commodities agrícolas. *Revista Produção Online*, 10(4), 719. <https://doi.org/10.14488/1676-1901.v10i4.225>
- Rodrigues Capelletto, L., Lima de Oliveira, J., & Carvalho, L. N. (2007). Aspectos do hedge accounting não implementados no Brasil. *Revista de Administração - RAUSP*, 42(4), 511–523. Retrieved from <https://www.redalyc.org/articulo.oa?id=223417523010>
- Rodrigues, G. Z., & Cunha, C. A. da. (2013). Operações de hedge de milho para importantes municípios goianos. *Revista de Política Agrícola*, 22(4), 38–55.
- Rumelhart, D., & McClelland, J. (1986). *Parallel Distributed Processing*. Cambridge: MIT Press.
- Said, S. E., & Dickey, D. A. (1984). Testing for unit roots in autoregressive-moving average models of unknown order. *Biometrika*, 71(3), 599–607. <https://doi.org/10.1093/biomet/71.3.599>
- Saliby, E., & Araújo, M. M. S. (2001). Cálculo do valor em risco através de simulação Monte Carlo: uma avaliação de uso de métodos amostrais mais eficientes em portfólios com opções. *XXXIII Simpósio Brasileiro de Pesquisa Operacional*.
- Sandroni, P. (1994). *Novo dicionário de Economia*. São Paulo: Abril.
- Santos, J. P. dos. (1993). *Sistemas de previsão de preços de commodities no mercado futuro* (FGV EAESP). Retrieved from <http://bibliotecadigital.fgv.br/dspace/handle/10438/4468>
- Sanvicente, A. Z., & Santos, C. da C. (1995). *Orçamento na administração financeira*. São Paulo: Atlas.
- Schwartz, P. (2000). *A arte da visão de longo prazo*. São Paulo: Nova Cultural.
- Schwarz, G. (1978). Estimating the dimension of a model. *The Annals of Statistics*, 6(2), 461–464. <https://doi.org/10.1214/aos/1176344136>
- Silva, F. P. (2012). *Financiamento da cadeia de grãos no Brasil: o papel das tradings e fornecedores de insumos* (Universidade Estadual de Campinas). Retrieved from http://repositorio.unicamp.br/jspui/bitstream/REPOSIP/286009/1/Silva_FelipePrince_M.pdf
- Souza, A., & Clemente, A. (2004). *Decisões financeiras e análise de investimentos* (5th ed.).

São Paulo: Atlas.

- Souza, R. (2008). *Previsão de séries temporais utilizando rede neural treinada por filtro de Kalman e evolução diferencial* ((Dissertação de Mestrado). Programa de Pós Graduação em Engenharia de Produção e Sistemas. Pontifícia Universidade Católica do Paraná). Retrieved from <https://docs.ufpr.br/~thom/papers/dissertation.pdf>
- Stock, J. H., & Watson, M. W. (2004). *Econometria*. São Paulo: Addison Wesley.
- Stolf, L. C. (1992). *Mercados futuros: o uso da análise fundamental na previsão de preços de commodities agrícolas no Brasil: o caso da soja* (Tese de Doutorado apresentada ao Curso de Pós-Graduação da EAESP/FGV.). Retrieved from <http://bibliotecadigital.fgv.br/dspace/handle/10438/4525>
- Teixeira, J. C. (2005). Modernização da agricultura no brasil: impactos econômicos, sociais e ambientais. *Revista Eletrônica AGB-TL*, 1(2), 21–42. Retrieved from <http://seer.ufms.br/index.php/RevAGB/article/view/1339>
- Teixeira Jr, L. A. (2013). *Combinação SSA-Wavelet de métodos preditivos com ajuste numérico MINIMAX, na geração de previsões e de cenários* (Tese (Doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica). Retrieved from <https://www.maxwell.lambda.ele.puc-rio.br/22892/22892.PDF>
- Tiffany, P., & Peterson, S. D. (1998). *Planejamento Estratégico: elaboração, implementação e execução*. São Paulo: Pioneira.
- Turner, N. (2008). Future-proofing your organisation. *CEO Journal*, 1.
- USDA. (2018). U.S. Department of agriculture. Retrieved August 29, 2018, from <https://www.usda.gov/topics/data>
- Weimer-Jehle, W. (2006). Cross-impact balances: A system-theoretical approach to cross-impact analysis. *Technological Forecasting & Social Change*, 73, 334–361.
- Welsch, G. A. (1996). *Orçamento Empresarial* (4th ed.). São Paulo: Atlas.
- Williamson, O. E. (1989). *Las instituciones económicas del capitalismo*. Ciudad de México: Fondo de Cultura Económica.
- Willmott, C. J. (1981). ON THE VALIDATION OF MODELS. *Physical Geography*, 2(2), 184–194. <https://doi.org/10.1080/02723646.1981.10642213>
- Willmott, C. J., & Wicks, D. E. (1980). An Empirical Method for the Spatial Interpolation of Monthly Precipitation within California. *Physical Geography*, 1(1), 59–73. <https://doi.org/10.1080/02723646.1980.10642189>

- Wright, J. T. C., & Spers, R. G. (2006). O país no futuro: aspectos metodológicos e cenários. *Estudos Avançados*, 20, 13–28.
- Ye, M., Meyer, P. D., & Neuman, S. P. (2008). On model selection criteria in multimodel analysis. *Water Resources Research*, 44(3). <https://doi.org/10.1029/2008WR006803>
- Zdanowicz, J. E. (1989). *Orçamento operacional: uma abordagem prática*. Porto Alegre: DC Luzzatto Editoras.
- Zuin, L. F. S., & Queiroz, T. R. (2006). *Agronegócios: gestão e inovação*. São Paulo: Saraiva.

APÊNDICE 1 – ANÁLISE DE RESÍDUOS MODELOS ARIMA




Figura 19 Análise Ljung-Box Arima (4,1,2) Soja Mensal

Fonte: do Autor




Figura 20 Análise Ljung-Box Arima (5,2,3) Soja Bimestral

Fonte: do Autor

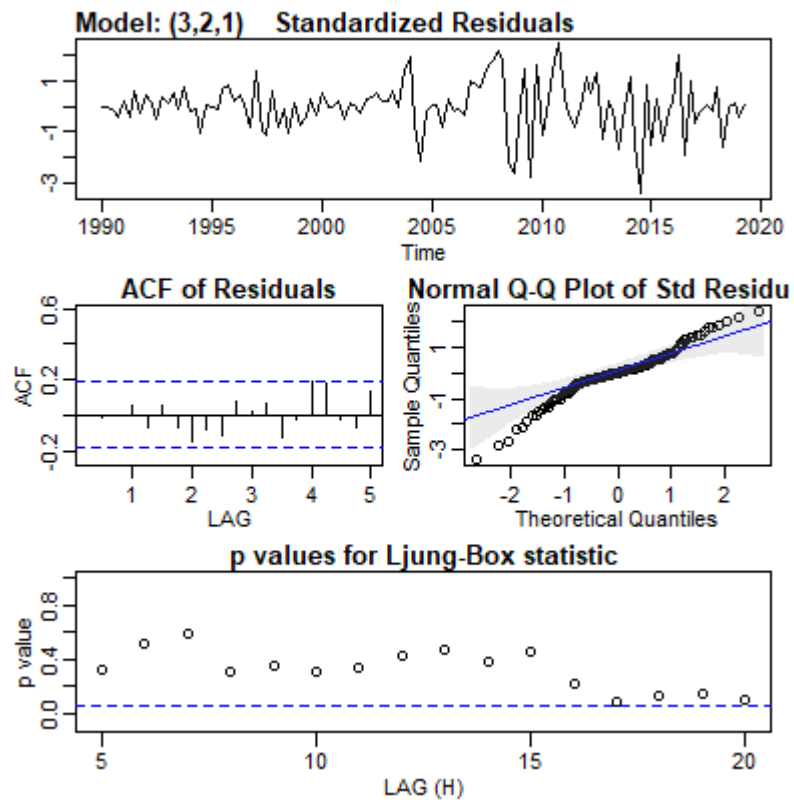


Figura 21 Análise Ljung-Box Arima (3,2,1) Soja Trimestral

Fonte: do Autor

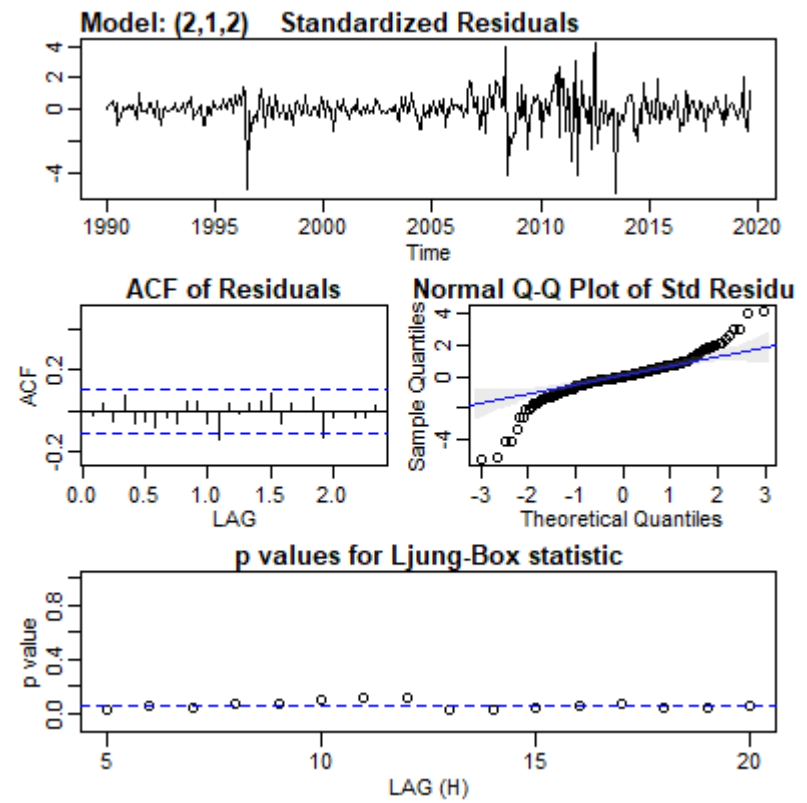


Figura 22 Análise Ljung-Box Arima (2,1,2) Milho Mensal

Fonte: do Autor

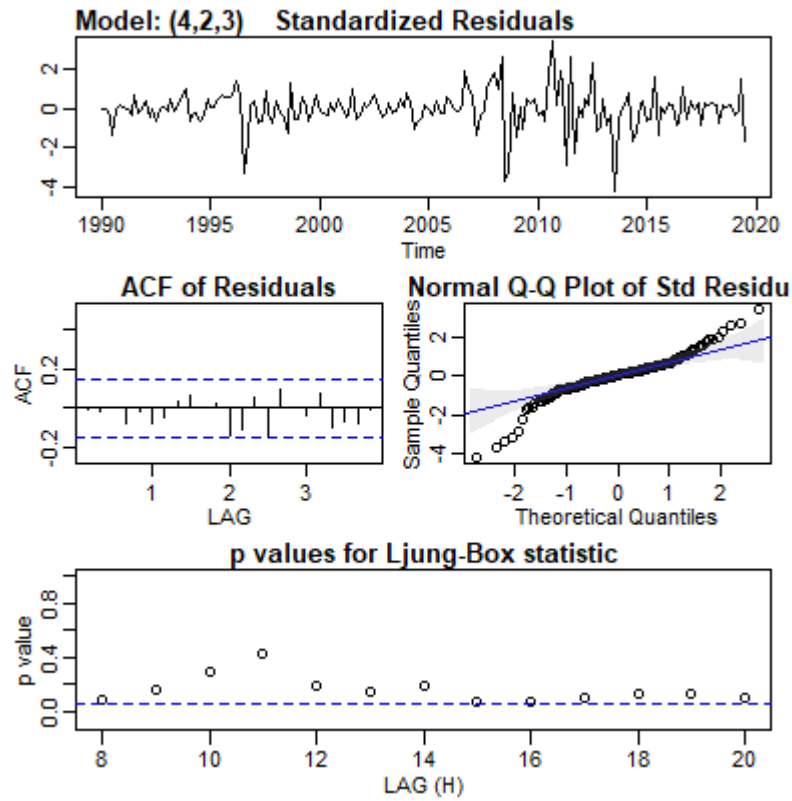


Figura 23 Análise Ljung-Box Arima (4,2,3) Milho Bimestral

Fonte: do Autor

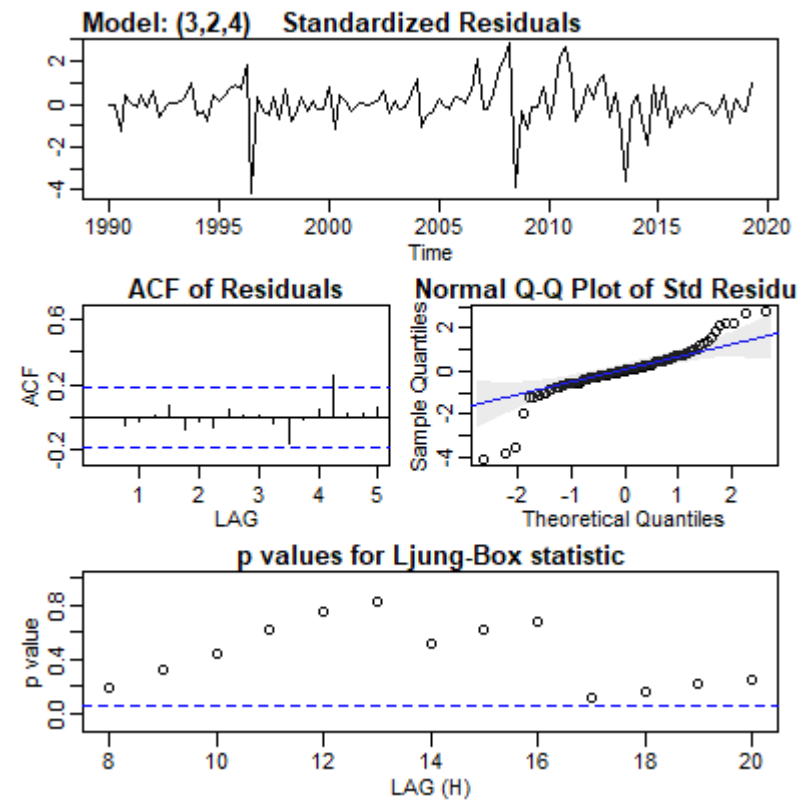


Figura 24 Análise Ljung-Box Arima (3,2,4) Milho Bimestral

Fonte: do Autor

APÊNDICE 2 – CENÁRIOS ECONÔMICOS

Tabela 11

Cenários Econômicos para a soja entre 2015 a 2019

Safra	Operações Ger. de Risco	Cenário	Custo Op.	Produtividade	Preço	Receita Bruta	Lucro Op.	Lucro Eco.	Margem
2019	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.533,13	63,5 sc/ha	R\$ 81,75	R\$ 5.188,87	R\$ 2.655,74	R\$ 1.826,14	51%
		Realista	R\$ 2.533,13	52,8 sc/ha	R\$ 80,07	R\$ 4.354,06	R\$ 1.820,93	R\$ 991,33	42%
		Pessimista	R\$ 2.533,13	42,1 sc/ha	R\$ 78,39	R\$ 3.555,05	R\$ 1.021,92	R\$ 192,32	29%
		Dados Reais	R\$ 2.533,13	48,2 sc/ha	R\$ 74,11	R\$ 3.569,86	R\$ 1.036,73	R\$ 207,13	29%
	Seguro ProAgro e Barter	Otimista	R\$ 2.533,13	63,3 sc/ha	R\$ 82,48	R\$ 5.224,19	R\$ 2.691,06	R\$ 1.861,46	52%
		Realista	R\$ 2.533,13	52,8 sc/ha	R\$ 78,24	R\$ 4.257,30	R\$ 1.724,17	R\$ 894,57	40%
		Pessimista	R\$ 2.533,13	42,3 sc/ha	R\$ 73,99	R\$ 3.379,80	R\$ 846,67	R\$ 17,07	25%
		Dados Reais	R\$ 2.533,13	48,2 sc/ha	R\$ 73,49	R\$ 3.539,78	R\$ 1.006,65	R\$ 177,05	28%
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.533,13	62,9 sc/ha	R\$ 86,37	R\$ 5.433,96	R\$ 2.900,83	R\$ 2.071,23	53%
		Realista	R\$ 2.533,13	52,8 sc/ha	R\$ 77,74	R\$ 4.105,07	R\$ 1.571,94	R\$ 742,34	38%
		Pessimista	R\$ 2.533,13	42,7 sc/ha	R\$ 69,10	R\$ 2.950,75	R\$ 417,62	-R\$ 411,98	14%
		Dados Reais	R\$ 2.533,13	48,2 sc/ha	R\$ 68,94	R\$ 3.320,68	R\$ 787,55	-R\$ 42,05	24%
2018	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.266,37	62,2 sc/ha	R\$ 64,01	R\$ 3.981,27	R\$ 1.714,90	R\$ 944,80	43%
		Realista	R\$ 2.266,37	52,3 sc/ha	R\$ 62,87	R\$ 3.382,75	R\$ 1.116,38	R\$ 346,28	33%
		Pessimista	R\$ 2.266,37	42,3 sc/ha	R\$ 61,73	R\$ 2.806,89	R\$ 540,52	-R\$ 229,58	19%
		Dados Reais	R\$ 2.266,37	56,5 sc/ha	R\$ 62,42	R\$ 3.526,78	R\$ 1.260,41	R\$ 490,31	36%
	Seguro ProAgro e Barter	Otimista	R\$ 2.266,37	62,1 sc/ha	R\$ 64,56	R\$ 4.009,91	R\$ 1.743,54	R\$ 973,44	43%
		Realista	R\$ 2.266,37	52,3 sc/ha	R\$ 61,83	R\$ 3.328,43	R\$ 1.062,06	R\$ 291,96	32%
		Pessimista	R\$ 2.266,37	42,4 sc/ha	R\$ 59,11	R\$ 2.700,65	R\$ 434,28	-R\$ 335,82	16%
		Dados Reais	R\$ 2.266,37	56,5 sc/ha	R\$ 62,35	R\$ 3.522,61	R\$ 1.256,24	R\$ 486,14	36%

Safra	Operações Ger. de Risco	Cenário	Custo Op.	Produtividade	Preço	Receita Bruta	Lucro Op.	Lucro Eco.	Margem
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.266,37	61,8 sc/ha	R\$ 69,67	R\$ 4.304,42	R\$ 2.038,05	R\$ 1.267,95	47%
		Realista	R\$ 2.266,37	52,3 sc/ha	R\$ 63,22	R\$ 3.303,54	R\$ 1.037,17	R\$ 267,07	31%
		Pessimista	R\$ 2.266,37	42,7 sc/ha	R\$ 56,77	R\$ 2.425,58	R\$ 159,21	-R\$ 610,89	7%
		Dados Reais	R\$ 2.266,37	56,5 sc/ha	R\$ 64,34	R\$ 3.635,16	R\$ 1.368,79	R\$ 598,69	38%
2017	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.411,87	61,9 sc/ha	R\$ 69,03	R\$ 4.271,91	R\$ 1.860,04	R\$ 1.150,15	44%
		Realista	R\$ 2.411,87	52 sc/ha	R\$ 67,70	R\$ 3.625,54	R\$ 1.213,67	R\$ 503,78	33%
		Pessimista	R\$ 2.411,87	42,2 sc/ha	R\$ 66,38	R\$ 3.005,29	R\$ 593,42	-R\$ 116,47	20%
		Dados Reais	R\$ 2.411,87	65,5 sc/ha	R\$ 66,11	R\$ 4.332,56	R\$ 1.920,69	R\$ 1.210,80	44%
	Seguro ProAgro e Barter	Otimista	R\$ 2.411,87	61,8 sc/ha	R\$ 69,78	R\$ 4.313,14	R\$ 1.901,27	R\$ 1.191,38	44%
		Realista	R\$ 2.411,87	52 sc/ha	R\$ 66,69	R\$ 3.572,75	R\$ 1.160,88	R\$ 450,99	32%
		Pessimista	R\$ 2.411,87	42,2 sc/ha	R\$ 63,60	R\$ 2.892,82	R\$ 480,95	-R\$ 228,94	17%
		Dados Reais	R\$ 2.411,87	65,5 sc/ha	R\$ 66,11	R\$ 4.332,56	R\$ 1.920,69	R\$ 1.210,80	44%
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.411,87	61,5 sc/ha	R\$ 73,83	R\$ 4.539,06	R\$ 2.127,19	R\$ 1.417,30	47%
		Realista	R\$ 2.411,87	52 sc/ha	R\$ 66,70	R\$ 3.469,89	R\$ 1.058,02	R\$ 348,13	30%
		Pessimista	R\$ 2.411,87	42,6 sc/ha	R\$ 59,56	R\$ 2.535,60	R\$ 123,73	-R\$ 586,16	5%
		Dados Reais	R\$ 2.411,87	65,5 sc/ha	R\$ 65,47	R\$ 4.290,62	R\$ 1.878,75	R\$ 1.168,86	44%
2016	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.208,76	59,6 sc/ha	R\$ 74,03	R\$ 4.414,34	R\$ 2.205,58	R\$ 1.627,53	50%
		Realista	R\$ 2.208,76	48,9 sc/ha	R\$ 72,37	R\$ 3.669,38	R\$ 1.460,62	R\$ 882,57	40%
		Pessimista	R\$ 2.208,76	38,1 sc/ha	R\$ 70,71	R\$ 2.960,13	R\$ 751,37	R\$ 173,32	25%
		Dados Reais	R\$ 2.208,76	58,7 sc/ha	R\$ 70,90	R\$ 4.159,75	R\$ 1.950,99	R\$ 1.372,94	47%
	Seguro ProAgro e Barter	Otimista	R\$ 2.208,76	59,5 sc/ha	R\$ 75,05	R\$ 4.465,90	R\$ 2.257,14	R\$ 1.679,09	51%
		Realista	R\$ 2.208,76	48,9 sc/ha	R\$ 70,89	R\$ 3.597,33	R\$ 1.388,57	R\$ 810,52	39%
		Pessimista	R\$ 2.208,76	38,2 sc/ha	R\$ 66,74	R\$ 2.817,03	R\$ 608,27	R\$ 30,22	22%
		Dados Reais	R\$ 2.208,76	58,7 sc/ha	R\$ 70,90	R\$ 4.159,75	R\$ 1.950,99	R\$ 1.372,94	47%
		Otimista	R\$ 2.208,76	59,1 sc/ha	R\$ 79,57	R\$ 4.704,95	R\$ 2.496,19	R\$ 1.918,14	53%

Safra	Operações Ger. de Risco	Cenário	Custo Op.	Produtividade	Preço	Receita Bruta	Lucro Op.	Lucro Eco.	Margem
2015	Sem Operações de Gerenciamento Risco	Realista	R\$ 2.208,76	48,9 sc/ha	R\$ 70,90	R\$ 3.465,18	R\$ 1.256,42	R\$ 678,37	36%
		Pessimista	R\$ 2.208,76	38,6 sc/ha	R\$ 62,22	R\$ 2.403,30	R\$ 194,54	-R\$ 383,51	8%
		Dados Reais	R\$ 2.208,76	58,7 sc/ha	R\$ 70,92	R\$ 4.160,55	R\$ 1.951,79	R\$ 1.373,74	47%
	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 1.829,25	58,7 sc/ha	R\$ 55,72	R\$ 3.269,08	R\$ 1.439,83	R\$ 908,93	44%
		Realista	R\$ 1.829,25	48,4 sc/ha	R\$ 54,61	R\$ 2.739,43	R\$ 910,18	R\$ 379,28	33%
		Pessimista	R\$ 1.829,25	38 sc/ha	R\$ 53,50	R\$ 2.232,63	R\$ 403,38	-R\$ 127,52	18%
		Dados Reais	R\$ 1.829,25	58,7 sc/ha	R\$ 54,98	R\$ 3.226,48	R\$ 1.397,23	R\$ 866,33	43%
	Seguro ProAgro e Barter	Otimista	R\$ 1.829,25	58,6 sc/ha	R\$ 56,34	R\$ 3.302,15	R\$ 1.472,90	R\$ 942,00	45%
		Realista	R\$ 1.829,25	48,4 sc/ha	R\$ 53,83	R\$ 2.701,59	R\$ 872,34	R\$ 341,44	32%
		Pessimista	R\$ 1.829,25	38,1 sc/ha	R\$ 51,32	R\$ 2.152,52	R\$ 323,27	-R\$ 207,63	15%
		Dados Reais	R\$ 1.829,25	58,7 sc/ha	R\$ 55,00	R\$ 3.227,30	R\$ 1.398,05	R\$ 867,15	43%
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 1.829,25	58,3 sc/ha	R\$ 58,83	R\$ 3.432,49	R\$ 1.603,24	R\$ 1.072,34	47%
		Realista	R\$ 1.829,25	48,4 sc/ha	R\$ 53,33	R\$ 2.578,92	R\$ 749,67	R\$ 218,77	29%
		Pessimista	R\$ 1.829,25	38,4 sc/ha	R\$ 47,82	R\$ 1.835,27	R\$ 6,02	-R\$ 524,88	0%
		Dados Reais	R\$ 1.829,25	58,7 sc/ha	R\$ 55,71	R\$ 3.269,15	R\$ 1.439,90	R\$ 909,00	44%

Tabela 11

Cenários Econômicos para o milho entre 2015 a 2019

Safra	Operações Ger. de Risco	Cenário	Custo Op.	Produtividade	Preço	Receita Bruta	Lucro Op.	Lucro Eco.	Margem Lucro Op.
2019	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.569,37	102,6 sc/ha	R\$ 35,54	R\$ 3.647,21	R\$ 1.077,84	R\$ 208,07	30%
		Realista	R\$ 2.569,37	90,8 sc/ha	R\$ 30,93	R\$ 2.851,03	R\$ 281,66	-R\$ 588,11	10%
		Pessimista	R\$ 2.569,37	78,9 sc/ha	R\$ 26,32	R\$ 2.164,19	-R\$ 405,18	-R\$ 1.274,95	-19%
		Dados Reais	R\$ 2.569,37	117,8 sc/ha	R\$ 26,87	R\$ 3.164,29	R\$ 594,92	-R\$ 274,85	19%
	Seguro ProAgro e Barter	Otimista	R\$ 2.569,37	103,2 sc/ha	R\$ 30,93	R\$ 3.190,76	R\$ 621,39	-R\$ 248,38	19%
		Realista	R\$ 2.569,37	90,8 sc/ha	R\$ 29,86	R\$ 2.753,70	R\$ 184,33	-R\$ 685,44	7%
		Pessimista	R\$ 2.569,37	78,4 sc/ha	R\$ 28,78	R\$ 2.343,23	-R\$ 226,14	-R\$ 1.095,91	-10%
		Dados Reais	R\$ 2.569,37	117,8 sc/ha	R\$ 29,37	R\$ 3.459,32	R\$ 889,95	R\$ 20,18	26%
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.569,37	102,6 sc/ha	R\$ 35,54	R\$ 3.647,21	R\$ 1.077,84	R\$ 208,07	30%
		Realista	R\$ 2.569,37	90,8 sc/ha	R\$ 30,93	R\$ 2.807,33	R\$ 237,96	-R\$ 631,81	8%
		Pessimista	R\$ 2.569,37	78,9 sc/ha	R\$ 26,32	R\$ 2.076,80	-R\$ 492,57	-R\$ 1.362,34	-24%
		Dados Reais	R\$ 2.569,37	117,8 sc/ha	R\$ 29,00	R\$ 3.414,92	R\$ 845,55	-R\$ 24,22	25%
2018	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.352,28	101,6 sc/ha	R\$ 32,27	R\$ 3.277,89	R\$ 925,61	R\$ 104,83	28%
		Realista	R\$ 2.352,28	87,1 sc/ha	R\$ 28,14	R\$ 2.528,17	R\$ 175,89	-R\$ 644,89	7%
		Pessimista	R\$ 2.352,28	72,6 sc/ha	R\$ 24,01	R\$ 1.898,25	-R\$ 454,03	-R\$ 1.274,81	-24%
		Dados Reais	R\$ 2.352,28	87,4 sc/ha	R\$ 31,38	R\$ 2.741,92	R\$ 389,64	-R\$ 431,14	14%
	Seguro ProAgro e Barter	Otimista	R\$ 2.352,28	102 sc/ha	R\$ 30,42	R\$ 3.103,05	R\$ 750,77	-R\$ 70,01	24%
		Realista	R\$ 2.352,28	87,1 sc/ha	R\$ 29,25	R\$ 2.624,72	R\$ 272,44	-R\$ 548,34	10%
		Pessimista	R\$ 2.352,28	72,2 sc/ha	R\$ 28,07	R\$ 2.181,35	-R\$ 170,93	-R\$ 991,71	-8%
		Dados Reais	R\$ 2.352,28	87,4 sc/ha	R\$ 29,71	R\$ 2.595,79	R\$ 243,51	-R\$ 577,27	9%

Safra	Operações Ger. de Risco	Cenário	Custo Op.	Produtividade	Preço	Receita Bruta	Lucro Op.	Lucro Eco.	Margem Lucro Op.
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.352,28	101,6 sc/ha	R\$ 32,27	R\$ 3.277,89	R\$ 925,61	R\$ 104,83	28%
		Realista	R\$ 2.352,28	87,1 sc/ha	R\$ 28,14	R\$ 2.450,28	R\$ 98,00	-R\$ 722,78	4%
		Pessimista	R\$ 2.352,28	72,6 sc/ha	R\$ 24,01	R\$ 1.742,48	-R\$ 609,80	-R\$ 1.430,58	-35%
		Dados Reais	R\$ 2.352,28	87,4 sc/ha	R\$ 29,69	R\$ 2.594,05	R\$ 241,77	-R\$ 579,01	9%
2017	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.270,95	99,5 sc/ha	R\$ 27,95	R\$ 2.781,58	R\$ 510,63	-R\$ 234,44	18%
		Realista	R\$ 2.270,95	82,2 sc/ha	R\$ 24,13	R\$ 2.115,70	-R\$ 155,25	-R\$ 900,32	-7%
		Pessimista	R\$ 2.270,95	64,8 sc/ha	R\$ 20,30	R\$ 1.582,57	-R\$ 688,38	-R\$ 1.433,45	-43%
		Dados Reais	R\$ 2.270,95	85,9 sc/ha	R\$ 20,50	R\$ 1.761,82	-R\$ 509,13	-R\$ 1.254,20	-29%
	Seguro ProAgro e Barter	Otimista	R\$ 2.270,95	100,2 sc/ha	R\$ 23,56	R\$ 2.360,07	R\$ 89,12	-R\$ 655,95	4%
		Realista	R\$ 2.270,95	82,2 sc/ha	R\$ 23,21	R\$ 2.040,58	-R\$ 230,37	-R\$ 975,44	-11%
		Pessimista	R\$ 2.270,95	64,1 sc/ha	R\$ 22,87	R\$ 1.733,49	-R\$ 537,46	-R\$ 1.282,53	-31%
		Dados Reais	R\$ 2.270,95	85,9 sc/ha	R\$ 22,61	R\$ 1.942,80	-R\$ 328,15	-R\$ 1.073,22	-17%
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.270,95	99,5 sc/ha	R\$ 27,95	R\$ 2.781,68	R\$ 510,73	-R\$ 234,34	18%
		Realista	R\$ 2.270,95	82,2 sc/ha	R\$ 24,13	R\$ 1.982,11	-R\$ 288,84	-R\$ 1.033,91	-15%
		Pessimista	R\$ 2.270,95	64,8 sc/ha	R\$ 20,30	R\$ 1.315,37	-R\$ 955,58	-R\$ 1.700,65	-73%
		Dados Reais	R\$ 2.270,95	85,9 sc/ha	R\$ 18,09	R\$ 1.554,73	-R\$ 716,22	-R\$ 1.461,29	-46%
2016	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.320,21	99,3 sc/ha	R\$ 39,31	R\$ 3.903,51	R\$ 1.583,30	R\$ 844,74	41%
		Realista	R\$ 2.320,21	82 sc/ha	R\$ 33,97	R\$ 2.919,76	R\$ 599,55	-R\$ 139,01	21%
		Pessimista	R\$ 2.320,21	64,7 sc/ha	R\$ 28,64	R\$ 2.120,86	-R\$ 199,35	-R\$ 937,91	-9%
		Dados Reais	R\$ 2.320,21	92,7 sc/ha	R\$ 35,70	R\$ 3.310,33	R\$ 990,12	R\$ 251,56	30%
	Seguro ProAgro e Barter	Otimista	R\$ 2.320,21	99,8 sc/ha	R\$ 36,06	R\$ 3.600,19	R\$ 1.279,98	R\$ 541,42	36%
		Realista	R\$ 2.320,21	82 sc/ha	R\$ 34,15	R\$ 2.934,39	R\$ 614,18	-R\$ 124,38	21%
		Pessimista	R\$ 2.320,21	64,1 sc/ha	R\$ 32,24	R\$ 2.336,73	R\$ 16,52	-R\$ 722,04	1%
		Dados Reais	R\$ 2.320,21	92,7 sc/ha	R\$ 34,42	R\$ 3.192,05	R\$ 871,84	R\$ 133,28	27%

Safra	Operações Ger. de Risco	Cenário	Custo Op.	Produtividade	Preço	Receita Bruta	Lucro Op.	Lucro Eco.	Margem Lucro Op.
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.320,21	99,3 sc/ha	R\$ 39,31	R\$ 3.903,51	R\$ 1.583,30	R\$ 844,74	41%
		Realista	R\$ 2.320,21	82 sc/ha	R\$ 33,97	R\$ 2.785,14	R\$ 464,93	-R\$ 273,63	17%
		Pessimista	R\$ 2.320,21	64,7 sc/ha	R\$ 28,64	R\$ 1.851,63	-R\$ 468,58	-R\$ 1.207,14	-25%
		Dados Reais	R\$ 2.320,21	92,7 sc/ha	R\$ 34,69	R\$ 3.216,53	R\$ 896,32	R\$ 157,76	28%
2015	Seguro ProAgro e Venda Ant. PreFixada	Otimista	R\$ 2.014,90	88,8 sc/ha	R\$ 26,30	R\$ 2.337,04	R\$ 322,14	-R\$ 278,38	14%
		Realista	R\$ 2.014,90	73,7 sc/ha	R\$ 22,83	R\$ 1.795,81	-R\$ 219,09	-R\$ 819,61	-12%
		Pessimista	R\$ 2.014,90	58,6 sc/ha	R\$ 19,36	R\$ 1.359,53	-R\$ 655,37	-R\$ 1.255,89	-48%
		Dados Reais	R\$ 2.014,90	114,8 sc/ha	R\$ 20,74	R\$ 2.380,59	R\$ 365,69	-R\$ 234,83	15%
	Seguro ProAgro e Barter	Otimista	R\$ 2.014,90	89,5 sc/ha	R\$ 21,52	R\$ 1.928,23	-R\$ 86,67	-R\$ 687,19	-4%
		Realista	R\$ 2.014,90	73,7 sc/ha	R\$ 21,40	R\$ 1.690,34	-R\$ 324,56	-R\$ 925,08	-19%
		Pessimista	R\$ 2.014,90	57,9 sc/ha	R\$ 21,28	R\$ 1.456,24	-R\$ 558,66	-R\$ 1.159,18	-38%
		Dados Reais	R\$ 2.014,90	114,8 sc/ha	R\$ 21,32	R\$ 2.446,70	R\$ 431,80	-R\$ 168,72	18%
	Sem Operações de Gerenciamento Risco	Otimista	R\$ 2.014,90	88,9 sc/ha	R\$ 26,30	R\$ 2.337,30	R\$ 322,40	-R\$ 278,12	14%
		Realista	R\$ 2.014,90	73,7 sc/ha	R\$ 22,83	R\$ 1.682,83	-R\$ 332,07	-R\$ 932,59	-20%
		Pessimista	R\$ 2.014,90	58,5 sc/ha	R\$ 19,36	R\$ 1.133,54	-R\$ 881,36	-R\$ 1.481,88	-78%
		Dados Reais	R\$ 2.014,90	114,8 sc/ha	R\$ 20,73	R\$ 2.379,98	R\$ 365,08	-R\$ 235,44	15%