UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ZOOTECNIA E ENGENHARIA DE ALIMENTOS

LUCIENE ROSE LEMES

**Modelo de avaliação de risco para predição de preços de carne
bovina utilizando inteligência computacional**

Pirassununga
2014

LUCIENE ROSE LEMES

**Modelo de avaliação de risco para predição de preços de carne bovina utilizando
inteligência computacional**

Versão Corrigida

Tese apresentada à Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Doutor em Ciências, na Área de Concentração em Ciências da Engenharia de Alimentos.

Área de Concentração: Processos Biotecnológicos e Microbiologia Aplicados a Indústria de Alimentos

Orientador: Prof. Dr. Ernane José Xavier Costa

Pirassununga
2014

Dados Internacionais de Catalogação na Publicação

Serviço de Biblioteca e Informação da Faculdade de Zootecnia e Engenharia de Alimentos da
Universidade de São Paulo

L551m	<p>Lemes, Luciene Rose</p> <p>Modelo de avaliação de risco para predição de preços de carne bovina utilizando inteligência computacional / Luciene Rose Lemes. -- Pirassununga, 2014. 129 f.</p> <p>Tese (Doutorado) -- Faculdade de Zootecnia e Engenharia de Alimentos - Universidade de São Paulo. Departamento de Ciências Básicas.</p> <p>Área de Concentração: Processos Biotecnológicos e Microbiologia Aplicados a Indústria de Alimentos.</p> <p>Orientador: Prof. Dr. Ernane José Xavier Costa.</p> <p>1. Preço 2. Risco 3. Carne bovina 4. Redes neurais 5. Inteligência computacional. I. Título.</p>
-------	--

Dedico esta tese de Doutorado aos meus Pais ***Jácomo Lemes e Marlene de Almeida Lemes***, pelos 51 anos de casamento em dezembro de 2013, pelos ensinamentos e exemplo de vida.

“As palavras movem, os exemplos arrastam”

Agradecimentos

Agradeço a Deus pelas oportunidades que me foram concedidas.

Ao meu orientador *Prof. Dr. Ernane José Xavier Costa*, minha gratidão pela paciência e compromisso que foi o elo para tornar palpável o que parecia intangível.

Ao meu colega *Prof. Dr. Paulo Eduardo F. de Mendonça*, sem sua ajuda, competência e generosidade este trabalho não seria possível.

Ao amigo *Prof. Dr. Adriano Bruno Rogério Tech*, pela imensa amizade e pela indicação ao LAFAC, sua amizade proporcionou a realização de um sonho que parecia muito distante.

À minha “*Grande Família*”, numerosa, sempre muito barulhenta, mas sempre juntos e que representa meu porto seguro, meu alicerce onde sempre recupero minha essência: meus irmãos: Carlos, Regina, Kelem, Júnior e Marlene; meus sobrinhos: Gabriela, Karoline, Gabriel, Kaio, Guilherme, Gustavo e Matheus; e agregados!

Ao amigo e Professor de Inglês *Cleber da Silveira Lima*, esta amizade é uma daquelas coincidências que acontecem em nossas vidas e que, sem querer, se tornam eternas, verdadeiras. Sem sua ajuda e paciência não teria alcançado este objetivo, entrar no Doutorado.

Aos amigos da pós *Luciana Piza, Carolina Melleiro Gimenez e Gustavo Voltani Von Atzingem*, pelo constante apoio nas horas difíceis, mas também pelas alegrias, no dia-a-dia, nas reuniões semanais e até mesmo nos encontros de “gordices”. Obrigada pela força de sempre.

À Profa. *Dra. Ana Carolina de Sousa Silva* e ao amigo *Prof. Dr. André Bufon*, pelas correções e sugestões ao longo do trabalho e pelo constante incentivo.

Aos amigos do LAFAC que estão sempre prontos para ajudar: Aldo, Fernando, Rogério, Naty, Janaina, Monize, Marcela, Mariana e Mica.

Ao querido amigo *Francisco Thomaz* que, mesmo distante, sempre atende aos meus chamados e está sempre pronto para uma palavra amiga, para uma palavra de incentivo e de apoio. Pela amizade sincera que resiste ao tempo e à distância.

Ao *Prof. Dr. Rubens Nunes* e *Prof. Dr. Luis Sérgio Paço Lopes* pelas contribuições no exame de qualificação e que se fizeram presentes neste trabalho.

Aos amigos da jornada de disciplinas: *Karen, Tiara, Bárbara e Volnei* e muitos ainda que neste momento falha a memória mas que foram importantes à minha adaptação, à convivência saudável na FZEA.

À *Academia da Força Aérea* pelo incentivo à minha formação intelectual e à carreira do magistério.

Aos meus alunos e orientandos que nesta jornada foram compreensivos e pacientes com minhas cobranças, com meu humor e com a falta de atenção merecida mas que neste momento agradeço por fazerem com que a juventude me fuja mais devagar.

Aos colegas da Academia da Força Aérea pelo apoio, incentivo e até mesmo por algum reforço negativo que contribuíram para que este trabalho se tornasse real: Prof. Hirata, Prof. Edmundo (que estendo a gratidão à família Elaine Gregóris e Lara), Prof. Marco Aurélio, Prof. Carlos Bispo, Prof. Gualazzi, Profa. Emília e aqueles que, de coração, torceram pelo meu sucesso. Ao Prof. M.Sc. Daniel Mateus O'Connell pela contribuição valiosa e pela amizade.

Ao amigo e *personal Breno Nascimento* pelo constante apoio e cuidado com minha saúde física, principalmente nos momentos de stress extremo. Meu muito obrigado!!!

Dentre tantas leituras encontrei uma frase que me parece justa neste momento e que infelizmente perdi a autoria, "*When one is blessed with too many people to thank, one should thank God*". Assim, o faço!

Acredito que, se pararmos para refletir e quisermos ser justos, teremos que agradecer a todos que cruzam nosso caminho, pois há um propósito maior em tudo, mesmo que, de imediato, não o reconheçamos. E assim, agradeço a todos que de alguma forma nos encontramos nesta jornada!

“Aprender é a única coisa de que a mente nunca se cansa, nunca tem medo e nunca se arrepende”.

Leonardo Da Vinci

“Não tenha medo de dar grande passos. Não se pode atravessar um abismo com dois pulinhos”.

David Lloyd George

RESUMO

LEMES, Luciene Rose. **Modelo de Avaliação de Risco para Predição de Preços de Carne Bovina Utilizando Inteligência Computacional**. 2014. 129 f. Tese (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2014.

A relação entre o preço futuro e o preço a vista é um fator que requer muita atenção e planejamento das atividades de comercialização agropecuária. As previsões de preços permitem fornecer a redução das incertezas dentro do mercado de carne bovina auxiliando na determinação da quantidade a ser produzida bem como no estabelecimento de políticas governamentais apropriadas e sustentáveis. Este trabalho tem como objetivo definir um modelo matemático capaz de prever os preços de carne bovina usando inteligência computacional a partir da análise do ARIMA, Análise de Risco e Redes Neurais Artificiais, identificando aspectos quantitativos relacionados à lógica da decisão na formação do preço de venda, utilizando-se de séries temporais, a fim de explorar as correlações que impactam com maior frequência no preço de venda de carne bovina, por entender que este conhecimento pode aperfeiçoar os instrumentos de avaliação no processo de tomada decisão. A pesquisa caracteriza-se como descritiva, explicativa e quantitativa pois busca-se identificar fatores determinantes para a ocorrência dos fenômenos observados nas séries temporais de preço do boi gordo, traduzindo-se em números as informações classificadas e analisadas com o uso de técnicas estatísticas. Neste estudo foi utilizado a metodologia de séries temporais, aplicada à série histórica de preços do Boi Gordo no período de 23 de julho de 1997 a 18 de fevereiro de 2013, obtida junto ao Centro de Estudos Avançados em Economia Aplicada (CEPEA) da ESALQ/USP/Piracicaba. Estes dados representam o indicador de preço do Boi Gordo ESALQ/BM&F/BOVESPA utilizado como referencial para as negociações de compra e venda de contratos futuros. Os resultados demonstram a eficiência dos modelos propostos para a simulação e instrumentalização, ou seja, permitem avaliar o comportamento linear e não linear do modelo como ferramenta para a geração de informações e redução dos riscos que contribuirá para reduzir a subjetividade no processo de tomada de decisão.

Palavras-chave: preço, risco, carne bovina, redes neurais, inteligência computacional.

ABSTRACT

LEMES, Luciene Rose. **Model of Evaluation of Risk for Prediction of Prices in the Beef Chain by Using Computational Intelligence**. 2012. 129 f. Thesis (Dissertation) – School of Zootechny and Food Engineering, São Paulo University, Pirassununga, 2014.

The relationship between the future price and the cash down price of beef is a factor that requires much attention and planning in agricultural market activities. Price previews help to reduce uncertainties in the beef market and to assist in the determination of the quantity of beef to be produced as well as in the establishment of proper and sustainable governmental policies. This work aims to establish a mathematical model capable of predicting the price of beef using computational intelligence from the ARIMA analysis, Risk Analysis and Artificial Neural Network, by identifying the quantitative aspects related to the logic of decision in the formation of selling prices. This is done by using temporal series in order to explore the correlations that impact with greater frequency on the selling price of beef meat. Knowledge thus produced could improve the assessment instruments in the process of decision making. This research is characterized as descriptive, explanatory and quantitative because it intends to identify the determining factors for the occurrence of the observed phenomena in the time series of livestock prices where the classified and analyzed data result in numbers by the use of statistical techniques. The time series methodology was used. The historical series of livestock prices in the period from July 23rd 1997 to February 18th 2013 was obtained in the Center for Advanced Studies in Applied Economics (CEPEA) from ESALQ/USP/Piracicaba. This represents the livestock price indicator ESALQ/BM&F/BOVESPA that is used as a reference for the negotiations of purchase and sale in future contracts. The results show the effectiveness of the proposed models for simulation and orchestration, that is, they allow assessment of linear and non-linear behavior of the model as a tool for the generation of data and risk reductions that will contribute to less subjectivity in the decision-making process.

Key words: price, risk, beef, neural network, computational intelligence.

LISTA DE FIGURAS

Figura 1 - Arquitetura de uma rede neural multilayer percetron com duas camadas escondidas	42
Figura 2 - Modelo de um neurônio artificial.....	47
Figura 3 - Modelo ARIMA e as etapas de implementação	55
Figura 4 - Etapa de identificação do Modelo ARIMA	58
Figura 5 - Etapa de Estimação do Modelo ARIMA.....	59
Figura 6 - Etapa Verificação e Previsão do Modelo ARIMA.....	59
Figura 7 - Arquitetura da Rede Neural Auto Regressiva Integrada de Média Móvel.....	65
Figura 8 - Série de preço à vista do Boi Gordo (Série Original)	67
Figura 9 - Série de preço do Boi Gordo diferenciada	69
Figura 10 - Série de preço do Boi Gordo - Função de Autocorrelação.....	70
Figura 11 - Série de preço do Boi Gordo - Função de Autocorrelação Parcial	70
Figura 12 - Matriz RMSE para simulação (90:10)	72
Figura 13 - Modelo de previsão de preços (de R\$ 85,00 a R\$ 110,00) do boi gordo para simulação 90:10.....	74
Figura 14 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 90:10.....	75
Figura 15 - Matriz RMSE para simulação (80:20)	76
Figura 16 - Modelo de previsão de preços (de R\$ 70,00 a R\$ 115,00) do boi gordo para simulação 80:20.....	77
Figura 17 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 80:20.....	78
Figura 18 - Matriz RMSE para simulação (70:30)	79
Figura 19 - Modelo de previsão de preços (de R\$ 70,00 a R\$ 115,00) do boi grodo para simulação 70:30.....	80
Figura 20 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 70:30.....	81
Figura 21 - Matriz RMSE para simulação (60:40)	82

Figura 22 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 60:40.....	83
Figura 23 - Análise de Risco para Simulação 90:10 para períodos de 30 dias úteis.....	86
Figura 24 - Análise de Risco para Simulação 90:10 para períodos de 5 dias úteis.....	87
Figura 25 - Análise de Risco para Simulação 90:10 com variação entre o preço real e o preço previsto	88
Figura 26 - Análise de Risco para Simulação 90:10 com sobreposição dos preços real e previsto (a).....	89
Figura 27 - Análise de Risco para Simulação 90:10 com sobreposição dos preços real e previsto (b)	89
Figura 28 - Análise de Risco para Simulação 80:20 para períodos de 30 dias úteis.....	90
Figura 29 - Análise de Risco para Simulação 80:20 para períodos de 5 dias úteis.....	91
Figura 30 - Análise de Risco para Simulação 80:20 com variação entre o preço real e o preço previsto (a).....	92
Figura 31 - Análise de Risco para Simulação 80:20 com variação entre o preço real e o preço previsto (b)	93
Figura 32 - Análise de Risco para Simulação 80:20 com sobreposição de preços real e previsto (a).....	94
Figura 33 - Análise de Risco para Simulação 80:20 com sobreposição de preços real e previsto (b)	94
Figura 34 - Análise de Risco para Simulação 70:30 para períodos de 30 dias úteis.....	95
Figura 35 - Análise de Risco para Simulação 70:30 para períodos de 5 dias úteis.....	96
Figura 36 - Análise de Risco para Simulação 70:30 com variação entre o preço real e o preço previsto	97
Figura 37 - Análise de Risco para Simulação 70:30 com sobreposição dos preços real e previsto (a).....	98
Figura 38 - Análise de Risco para Simulação 70:30 com sobreposição dos preços real e previsto (b)	99
Figura 39 - Análise de Risco para Simulação 60:40 para períodos de 30 dias úteis.....	100
Figura 40 - Análise de Risco para Simulação 60:40 para períodos de 5 dias úteis.....	100
Figura 41 - Análise de Risco para Simulação 60:40 com variação entre o preço real e o preço previsto (a).....	102

Figura 42 - Análise de Risco para Simulação 60:40 com variação entre o preço real e o preço previsto (b)	103
Figura 43 - Análise de Risco para Simulação 60:40 com sobreposição dos preços real e previsto (a).....	104
Figura 44 - Análise de Risco para Simulação 60:40 com sobreposição dos preços real e previsto (b)	104
Figura 45 - Rede neural artificial com simulação de 50:50.	108
Figura 46 – Análise de Risco para o Mês de Março de 2004.....	127
Figura 47 – Análise de Risco para o Mês de Abril de 2004.....	128
Figura 48 – Análise de Risco para o Mês de Maio de 2004.....	129
Figura 49 – Análise de Risco para o Mês de Junho de 2004.....	129
Figura 50 – Análise de Risco para o Mês de Março de 2005.....	130
Figura 51 – Análise de Risco para o Mês de Abril de 2005.....	131

LISTA DE TABELAS

Tabela 1 - Exemplos de pesquisas que utilizaram ARIMA para previsões	33
Tabela 2 - Exemplos de pesquisas que utilizaram séries temporais para previsões.....	35
Tabela 3 - Pesquisas que utilizaram séries temporais para previsões	36
Tabela 4 - Trabalhos realizados com commodities agrícolas	50
Tabela 5 - Teste de Raiz Unitária de Dickey-Fuller	68
Tabela 6 - Medida de Erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)	73
Tabela 7 - Modelo ARIMA - Comparação com resultados estatísticos	73
Tabela 8 - Medida de erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)	76
Tabela 9 - Modelo ARIMA - comparação com resultados estatísticos.....	77
Tabela 10 - Medida de erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)	79
Tabela 11 - Modelo ARIMA - comparações com resultados estatísticos	79
Tabela 12 – Medida de erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)	82
Tabela 13 - Modelo ARIMA (1,1,1); ARIMA (3,1,3) resultados estatísticos.....	82

SUMÁRIO

RESUMO.....	7
ABSTRACT	8
LISTA DE FIGURAS.....	9
LISTA DE TABELAS	12
SUMÁRIO	13
1 INTRODUÇÃO.....	16
2 REVISÃO BIBLIOGRÁFICA	19
2.1 Risco e Retorno.....	19
2.2 Análise de Risco	21
2.3 Risco em Alimentos	23
2.4 Análise de Séries Temporais.....	25
2.4.1 Série Temporal – Definição	26
2.4.2 Objetivo da Análise de Séries Temporais	26
2.4.3 Previsão de Séries Temporais – Definição.....	27
2.4.4 Métodos de Previsão de Séries Temporais	28
2.4.5 Estudos realizados com ARIMA	32
2.4.6 Modelos ARCH e GARCH	37
2.5 Redes Neurais Artificiais na Análise de Séries Temporais.....	40
2.5.1 Histórico das Redes Neurais Artificiais	43

2.5.2 Características das Redes Neurais Artificiais	44
2.5.3 Estudos realizados com redes neurais artificiais (RNA)	48
3 OBJETIVOS	51
3.1 Objetivo Geral.....	51
3.2 Objetivos Específicos	51
4 MATERIAL E MÉTODOS.....	52
4.1 Caracterização da Pesquisa	52
4.2 Técnica de Coleta de Dados.....	53
4.3 Composição e Tratamento de Dados da Pesquisa	53
4.4 Metodologia ARIMA	54
4.5 Medidas de Risco.....	61
4.6 Redes Neurais Artificiais	63
5 RESULTADOS E DISCUSSÃO	66
5.1 Resultados e Discussão da Pesquisa - ARIMA	66
5.1.1 A Série Temporal do BOI GORDO	66
5.1.2 Simulação e Análise com 90% da série histórica para treinamento	71
5.1.3 Simulação e Análise com 80% da série histórica para treinamento	75
5.1.4 Simulação e Análise com 70% da série histórica para treinamento	78
5.1.5 Simulação e Análise com 60% da série histórica para treinamento	81
5.1.6 Algumas Considerações.....	83

5.2 Resultados e Discussão da Pesquisa - RISCO	85
5.2.1 Análise de Risco com 90% da série para Treinamento.....	85
5.2.2 Análise de Risco com 80% da série para Treinamento.....	90
5.2.3 Análise de Risco com 70% da série para Treinamento.....	95
5.2.4 Análise de Risco com 60% da série para Treinamento.....	99
5.2.5 Algumas considerações	105
5.3 Resultados e Discussão da Pesquisa - RNA.....	106
5.3.1 Simulação e Análise da Rede Neural Artificial.....	106
5.3.2 Algumas considerações	109
5.4 Contribuições Futuras.....	110
6 CONCLUSÃO.....	112
REFERÊNCIAS BIBLIOGRÁFICAS	114
ANEXO 01 – VALORES CRÍTICOS TESTE T DE DICKEY-FULLER.....	125
APÊNDICE 01 – RESULTADOS OBTIDOS NO EXAME DE QUALIFICAÇÃO	126

1 INTRODUÇÃO

No mundo globalizado o simples ato de ingerir um alimento remete à complexa cadeia de processo onde o alimento foi produzido. Não basta ser só um alimento que será ingerido, há que se conhecer sua origem, dados de sua qualidade e informações sobre responsabilidade social e ambiental na produção de tal alimento e, todos estes fatores implicam em custos.

O gerenciamento dos custos passou a ser considerado a motivação que, a partir da concorrência e competição no mercado globalizado levou as empresas a buscar novos formatos organizacionais mais flexíveis e descentralizados, bem como incentivando a busca de conhecimento científico e tecnológico como uma vantagem competitiva. Além da adequação técnica e produtiva é preciso desenvolver avaliações que auxiliem a tomada de decisão sobre bases de racionalidade, de forma a estimular a manutenção das decisões e estratégias de longo prazo reduzindo assim, o nível de incerteza do negócio (SHIMIZU, 2001).

A busca por vantagens competitivas tem guiado as empresas a desenvolverem estratégias para melhor se posicionarem frente aos seus concorrentes. Porter (1985) utiliza a liderança em custos e a diferenciação como estratégia para a obtenção de duas vantagens competitivas que as empresas podem desenvolver. No primeiro caso, liderança em custos, as empresas têm competências e condições de competir por preço, seja pelo acesso à matéria-prima, escala de produção, tecnologias ou competências no processo produtivo. Já no segundo caso, competir por meio da diferenciação significa agregar valor ao produto ou serviço, o que implica oferecer ao mercado algo mais pelo que ele esteja disposto a pagar.

Devido à complexidade que envolve o processo de tomada de decisão de preços de *commodities*, as ferramentas de análise quantitativa são fundamentais para conhecer o comportamento dos preços exercidos ao longo do tempo, considerando o ambiente de “mercado competitivo”, que envolve as variáveis inerentes ao processo de produção e venda da *commodity* Boi Gordo. Conhecer, analisar e avaliar a correlação existente dentro deste processo na formação de preço da carne bovina apresenta-se como parte integrante do processo de tomada de decisão.

As previsões de preços podem fornecer uma redução das incertezas dentro do mercado de carne bovina, auxiliar na determinação da quantidade a ser produzida e no estabelecimento de políticas governamentais apropriadas e sustentáveis. A previsão de séries temporais, como o preço de uma *commodity*, é parte importante dentro da área de previsão. Tal importância está assentada na capacidade de estimar, mediante dados de algumas variáveis, como por exemplo o preço do período anterior e o erro aleatório, um modelo que explique o comportamento desse conjunto de observações. Atualmente, o método mais utilizado e conhecido é o Autoregressivo Integrado de Médias Móveis (ARIMA) de Box e Jenkins (1976).

A precificação de carne bovina utilizando técnicas de análise de risco e redes neurais artificiais – RNA's é um tema ainda pouco debatido empiricamente e teoricamente. Este trabalho acrescenta evidências na utilização destas técnicas mediante aplicação detalhada e bem sucedida de previsão de preços de *commodities* como o Boi Gordo.

A avaliação, desta forma, dos vários caminhos apresentados no processo de tomada de decisão deve ser estudada e, a abordagem de séries temporais, análise de risco e redes neurais artificiais apresentam-se como ferramentas para a construção de um modelo capaz de prever cenários possíveis.

O estudo da previsão de preços da carne bovina por meio de um modelo adequado, proporciona melhorias na elaboração de planos e metas orçamentárias e, consequentemente, no processo de tomada de decisão para atividade agropecuária.

Desta forma, o trabalho foi desenvolvido utilizando-se séries históricas de preços do Boi Gordo, compreendendo o período de 23 de julho de 1997 a 18 de fevereiro de 2013, obtidos no Centro de Estudos Avançados em Economia Aplicada (CEPEA) da ESALQ/USP/Piracicaba. Estes dados representam o indicador de preço do Boi Gordo ESALQ/BM&F/BOVESPA, utilizado como referencial para as negociações de compra e venda de contratos futuros.

Por meio de técnicas estatísticas foi realizado estudo do comportamento dos preços ao longo do tempo. Utilizou-se o Modelo Autoregressivo Integrado de Médias Móveis – ARIMA,

de Box e Jenkins (1976) a fim de determinar valores futuros a partir dos valores passados dos preços do Boi Gordo, desenvolvidas no *Software MatLab*®.

Para isso utilizou-se a técnica de análise de risco com o uso do *Software Model Risk*® de Vose (2008), a fim de explorar as correlações que impactam, com maior frequência, na formação do preço de venda de carne bovina, já que essa técnica pode aperfeiçoar os instrumentos de avaliação e decisão. O conhecimento do comportamento de risco que afeta o preço, tem como objetivo avaliar a predição de preços por meio de um modelo matemático que contribua de forma eficiente no processo de tomada de decisão.

Por entender que o tema “formação de preços” é importante na avaliação e decisão de preços para o mercado, constituindo um alicerce para a competitividade das empresas, esta pesquisa visa avaliar a predição de preços com base no levantamento, utilização e análise dos aspectos quantitativos relacionados à decisão de preço da carne bovina, utilizando-se de séries temporais e inteligência computacional.

Sendo assim, o presente estudo foi desenvolvido na busca de um modelo estatístico-matemático que viabilizasse a análise da hipótese de que dada uma série temporal de preços de carne bovina é possível elaborar um modelo híbrido que permita a predição de preços do boi gordo no mercado futuro.

O trabalho está estruturado em seis (06) seções. A primeira seção trata da Introdução. A seção dois da revisão bibliográfica sobre risco, séries temporais e redes neurais. A terceira seção apresenta os objetivos da pesquisa. A quarta seção, os material e métodos. A quinta seção, os resultados e discussão. A sexta seção, a conclusão.

2 REVISÃO BIBLIOGRÁFICA

O delineamento teórico nesta sessão contempla o conhecimento de risco e retorno, avaliação de risco e inteligência computacional para análise e avaliação na predição de preços de carne bovina.

2.1 Risco e Retorno

Conforme Kaplan e Garrick (1981), o conceito de risco assume diferentes significados na literatura como, o risco do negócio, risco social, risco econômico, risco de segurança, risco de investimento, risco militar, risco político, etc. e, portanto, a tomada de decisão racional requer uma forma clara e quantitativa de expressar o risco de modo que possa ser adequadamente considerado com todos os outros custos e benefícios dentro do processo de decisão.

Uma reflexão sistemática e exata sobre a natureza do risco remete ao amadurecimento de posturas e estratégias que se adotam diante dos riscos inerentes ao preço de qualquer ativo real ou financeiro. O pensamento atual que define a fronteira entre os tempos modernos e o passado baseia-se no domínio do risco que remete à idéia de que a noção do futuro é mais que um capricho dos deuses e de que homens e mulheres não são passivos ante a natureza (BERNSTEIN, 1997).

Ainda segundo Bernstein (1997), uma análise histórica relembra que a definição moderna de risco teve suas raízes no sistema de numeração indo-arábico no Ocidente há cerca de setecentos a oitocentos anos atrás. Mas o estudo sobre o risco remonta à época do Renascimento, momento de turbulências religiosas, de capitalismo nascente e de valorização acentuada da ciência e do futuro.

A moderna teoria da probabilidade e, conseqüentemente, o conceito de risco, afloraram no século XVII a partir de uma singela aposta entre dois jogadores sobre como deveriam fazer para dividir o montante de uma partida inesperadamente interrompida. Tal enigma foi conhecido como o problema da divisão do monte proposto pelo cavaleiro de Méré a Pascal.

Pascal pediu ajuda a Pierre de Fermat, advogado que também era brilhante matemático. O resultado de sua colaboração foi pura dinamite intelectual. O que poderia parecer uma versão do século XVII do jogo da Busca Trivial levou à descoberta da teoria das probabilidades, o núcleo matemático do conceito de risco (BERNSTEIN, 1997, p.3).

Todas as ferramentas utilizadas na administração do risco e na análise das decisões e opções, da rigorosa racionalidade da teoria dos jogos aos desafios da teoria do caos, resultaram das evoluções ocorridas entre 1654 e 1760, com apenas duas exceções: a) em 1875 com Francis Galton, matemático amador que descobriu a regressão à média; e b) em 1952, com o ganhador do prêmio Nobel Harry Markowitz, cuja Teoria de Portfólio, demonstrou matematicamente que colocar todos os ovos na mesma cesta é uma estratégia arriscada, e que a diversificação é o melhor negócio para um investidor ou gerente de empresa (BERNSTEIN, 1997, p.6).

Considerando que a palavra “risco” caracteriza a chance de que ocorra um evento desfavorável, Brigham e Houston (1999, p. 452) avaliam o conceito de risco do negócio e risco financeiro. O risco do negócio é definido como o grau de incerteza inerente a projeções de retornos futuros que pode ser medido utilizando-se o indicador Retorno sobre o Ativo (ROA – *Return on Asset*); já o risco financeiro, é o risco adicional para os acionistas decorrentes da decisão de utilização de capital de terceiros, o que reflete no Retorno sobre o Patrimônio Líquido (ROE – *Return on Equity*). Os principais fatores caracterizados como risco do negócio são elencados pelos autores como: variabilidade da demanda (vendas em unidades); variabilidade do preço de venda; variabilidade dos preços dos insumos; capacidade de ajustar preços do produto de acordo com as variações nos preços dos insumos e; o montante de custos fixos que representa a alavancagem operacional.

A administração de risco corporativo, ou seja, administrar risco em empresas não-financeiras, implica o trabalho de identificar a que tipos de risco uma empresa está exposta (risco de negócio, eventos de mercado ou financeiros), além de mensurar o valor em risco envolvido e definir as estratégias adequadas de eliminação do risco, objetivando sempre criar valor à empresa e ao negócio. Rocha (2007), avalia que a gestão do risco em empresas

não-financeiras implica na manutenção ou aumento dos fluxos de caixa esperados e, conseqüente, nos lucros a serem obtidos.

A estratégia para gerenciar risco em empresas não financeiras, ainda de acordo com Rocha (2007, p.117), considera uma política de *hedge* (proteção ao risco) que visa equilibrar a relação risco-retorno do negócio. O autor avalia ainda que as empresas não-financeiras vêm passando por uma grande evolução no quesito gerenciamento de risco, implicando um planejamento adequado de todos os recursos necessários ao seu *Core Business* e na definição de quais riscos a empresa deve assumir, quais devem transferir ou segurar (*hedge*) e aqueles que a empresa deve evitar por não fazer parte de seu planejamento estratégico.

2.2 Análise de Risco

De acordo com Trucco e Cavallin (2006), na era atual dos mecanismos de mercado, a eficiência consiste em tornar a produção economicamente viável, o que representa economizar dinheiro e investimento, sempre, e para evitar exageros com medidas que apenas servem para proteger. Na década de 70, a metodologia analítica de avaliação de risco surgiu para o processo de instalações. Em sua forma final, tornou-se quantificado. Foi originalmente derivada para estudos de segurança nucleares e é conhecido nesse campo como *Probabilistic Safety Assessment* (PSA). A *Quantitative Risk Assessment* (QRA) desenvolveu-se rapidamente na década de 80, especificamente, o segmento de análise consequência.

Os benefícios potenciais da realização de estudos de avaliação de risco eficazes estão presentes na literatura de forma clara, já que a avaliação de riscos está se tornando uma ferramenta de apoio crucial para a decisão nos cuidados de reengenharia de processos, onde o uso generalizado das novas tecnologias pelos profissionais e as necessidades para aumentar a eficiência operacional não devem comprometer a qualidade da assistência prestada aos clientes. (TRUCCO; CAVALLIN, 2006; AVEN; ZIO, 2011).

A avaliação quantitativa de risco representa um passo muito importante para diversas áreas, frequentemente foi utilizada para analisar crescimento de microrganismos, porém, seu uso

tem crescido e se diversificado. Segundo Hartnett et al. (2002), a QRA foi uma ferramenta útil para avaliação do risco de sensibilização de um medicamento ou cosmético aplicado na pele. A sensibilização cutânea abordada pelo QRA pode ser usada para estimar os níveis seguros de exposição para ingredientes. Desta forma, pode ser usada como uma base para a gestão de riscos. Para os ingredientes perfumados, o QRA poderia ser utilizado tanto prospectivamente, quanto retrospectivamente. O uso prospectivo seria a abordagem na identificação dos níveis aceitáveis em produtos para os quais não existem normas. Por sua vez, o uso retrospectivo visa determinar a aceitabilidade ou rejeição de normas atuais.

O uso das ferramentas de avaliação de risco favorece a identificação de incertezas e a forma de combiná-las com os diversos cenários desfavoráveis que podem acontecer mesmo tendo um conhecimento incompleto das variáveis componentes do processo avaliado. A avaliação dos resultados implica uma administração do risco a partir do aumento da margem de segurança, melhoria da confiabilidade dos componentes críticos, modificação dos conceitos do projeto e redução das consequências inerentes às falhas, de forma a compartilhar o risco entre as partes interessadas, os chamados *“stakeholders”* (WOOLDRIDGE et al., 2006). Os autores defendem a idéia de que *“O que você não pode medir, você não pode controlar”*, e assim, o uso da ferramenta QRA contribui para a medição de risco para fins de gestão. No QRA o risco é avaliado por meio do exame específico de como os fatores inerentes à avaliação podem interagir, que cenários podem resultar e que danos podem causar.

Em outro contexto, o modelo QRA fez uma contribuição significativa para um novo sistema de segurança de baixo custo, reduzindo substancialmente o risco em uma plataforma. Este sistema melhorou o processo de reunir, por meio de um aviso afixado em local estratégico, bem como de luzes que são ativadas pelo fogo e detecção de gás, o que permitiu redirecionar o pessoal longe dos perigos potenciais e para botes salva-vidas em centrais nucleares. (ROSS et al., 1987).

A avaliação e análise de risco para empresas não financeiras foi estudado por Kimura (2002) com o objetivo de otimizar o uso de recursos para o portfólio de produtos de uma empresa e, conseqüentemente, de criar um valor, viabilizando as estratégias de investimento e financiamento. A partir do modelo de Markowitz (Teoria de Portfólio, 1952), incorporou-se o

conceito de *Value-at-Risk* (Valor do Risco) que possibilitou a identificação da sensibilidade do risco assumido pela empresa em função de pequenas alterações no nível de investimento em cada um dos produtos que compõem a carteira da empresa.

2.3 Risco em Alimentos

Na engenharia de alimentos, o uso de QRA como ferramenta capaz de prever risco tem-se mostrado crescente à medida que diversos autores obtiveram êxito ao demonstrar a eficácia do método, conforme apresentam os trabalhos descritos a seguir.

Técnicas de avaliação quantitativa de risco em alimentos a fim de reduzir o risco causado à saúde humana têm sido utilizadas com certa frequência (CASSIN et al., 1998; DUFFY et al., 2006; e TUOMINEM et al., 2007) e compreendem três elementos essenciais: avaliar o risco, comunicar o risco e gerenciar o risco. A avaliação do risco é considerada como a parte científica do processo em que são identificados os riscos, são apresentados os riscos (no caso de alimentos, os patógenos), e em seguida, são calculados os riscos. Os princípios considerados são: identificação do perigo, avaliação da exposição ao perigo, caracterização do perigo e caracterização do risco.

O estudo de contaminação de *Escherichia Coli* 0157:H7 em carne bovina foi estudado por Duffy et al. (2006). A cadeia de carne bovina compreendeu a produção primária por meio do abate, a transformação, a distribuição, o cozimento e preparação final. O objetivo foi utilizar a técnica de avaliação quantitativa de risco (QRA) para gerenciar o risco de contaminação e infecção de *E.Coli* no consumo de carne bovina. Foi possível avaliar o impacto dos fatores de risco na cadeia de carne bovina e a probabilidade de ocorrência de doenças em humanos.

Cassin et al. (1998) aplicou o QRA na segurança alimentar microbiana e avaliou que a metodologia pode ajudar a identificar os estágios de fabricação, manipulação e consumo de alimentos que contribuem para o aumento do risco de doenças transmitidas por alimentos e, também, ajuda a concentrar tanto recursos como esforços para uma estratégia eficiente na redução do risco de patógenos de origem alimentar.

Wooldridge et al. (2006) analisou o risco de contaminação por Febre Aftosa (FMD – *Foot and Mouth Disease*), Febre Suína Africana (ASF – *African Swine Fever*), Peste Suína (CSF – *Classical Swine Fever*) e Doença Vesicular do Suíno (SVD – *Swine Vesicular Disease*), de carne e produtos derivados de carne de animais infectados na Grã-Bretanha (GB), principalmente de carne importada ilegalmente. Utilizou-se o método de avaliação quantitativa de risco (QRA) para identificar os principais contribuintes de risco, a complexidade de informações necessárias e, também, a importância dos gestores neste processo de avaliação.

Kreuz e Souza (2006) estudaram a percepção do risco associado ao aumento de produtividade e rentabilidade na cultura de alho no Rio Grande do Sul/SC. As variáveis utilizadas no trabalho foram: investimentos no processo de produção, custos de produção, escala de produção e preço de mercado. Neste estudo foi utilizado o Método Delphi para inferir o risco de gestão e risco de negócio. O trabalho avaliou a capacidade de geração de retorno em diferentes níveis de produção com a absorção de um nível mínimo de risco no negócio.

O risco de negócio, analisado por Kreuz e Souza (2006), está associado a fatores não controláveis que afetam o agronegócio, tais como o surgimento de barreiras alfandegárias, aspectos fitossanitários, variações além dos limites nas condições climáticas na época do plantio e colheita e, principalmente, preços de mercado não competitivos em função da superoferta ou falta de qualidade do produto.

Roque-Specht (2007) utilizou a ferramenta QRA para avaliação da segurança microbiológica de alimentos. O estudo ofereceu subsídios para os gestores de risco na determinação das prioridades nas ações (tomada de decisão) e no processamento de alimentos de acordo com a classificação de microrganismos encontrados e avaliados pela análise quantitativa de riscos.

A necessidade de um fornecimento adequado e seguro de alimentos para a saúde do consumidor foi avaliada em Chassy (2010) a partir dos estudos de alimentos transgênicos como forma de diminuir o risco para a saúde. O tema segurança na cadeia alimentar tem sido a força motriz para a inovação na agricultura e para a indústria de alimentos.

Doménech et al. (2010), estudaram o uso da ferramenta QRA para avaliar o resultado (lucro ou prejuízo) diante da ocorrência de falhas na qualidade do alimento. Estes autores observaram que as primeiras aplicações do QRA surgiram em grandes indústrias, tradicionalmente para avaliação quantitativa de risco microbiológico para a saúde dos clientes. Posteriormente foi aplicada na área de segurança alimentar e sua relação com a rentabilidade das empresas. Além disso, defenderam que o uso das informações de risco contribui para uma melhor tomada de decisão em processos de qualidade e segurança alimentar e ainda, auxilia na identificação de falhas e perigos para a saúde de clientes e, principalmente, para o retorno das empresas.

A combinação de três técnicas: a análise de árvore de eventos (ETA – *event tree analysis*), a análise de árvore de falhas (FTA – *fault tree analysis*) e a modelagem preditiva (*predictive modelling*) são utilizadas por Doménech et al. (2010). O método Monte Carlo é utilizado para as simulações probabilísticas e, assim, garantir qualidade e eficiência produtiva do alimento com a adoção de políticas e a tomada de decisões sobre bases de informações de risco.

Papadimitriou et al. (2012), examinaram a distribuição de bioacumulação de microcistinas nos principais componentes da cadeia alimentar de organismos aquáticos e avaliaram a ameaça potencial da contaminação destes organismos para a saúde humana. Utilizou-se o modelo linear geral a fim de examinar as diferenças significativas entre os animais, tecidos e períodos de amostragem em relação à concentração de microcistina. Neste estudo foi realizado análise de variância (ANOVA) utilizando o pacote SPSS 19,0 para Windows.

2.4 Análise de Séries Temporais

Os estudos de séries temporais e sua aplicação na previsão de valores futuros são elaborados após a classificação e descrição de um conjunto de métodos de previsão. Estes estudos, em geral, apresentam uma discussão acerca da utilização de modelos e seus resultados práticos.

2.4.1 Série Temporal – Definição

Uma série temporal representa uma classe de fenômenos cujo processo observacional e consequente quantificação numérica gera uma sequência de dados distribuídos no tempo (SOUZA, 1989).

A natureza de uma série temporal e a estrutura de seu mecanismo gerador estão relacionadas com o intervalo de ocorrência das observações no tempo. Quando as observações da série podem ser feitas a qualquer momento do tempo, a série temporal é definida como *contínua*, sendo denotada por $X(t)$. Entretanto, de acordo com Granger e Newbold (1977) e Nelson (1973), na maioria das séries, as observações são tomadas em intervalos de tempo discretos e equidistantes.

De acordo com Souza (1989), *“Uma série temporal discreta pode ser representada por $X_t = (X_1, X_2, \dots, X_t)$ sendo que cada observação discreta X_t está associada a um instante de tempo distinto, existindo uma relação de dependência serial entre essas observações”*.

2.4.2 Objetivo da Análise de Séries Temporais

Segundo Granger e Newbold (1977) o objetivo inicial da análise de séries temporais é a realização de inferências sobre as propriedades ou características básicas do mecanismo gerador do processo estocástico das observações da série. Assim, a partir da abstração de regularidades contidas nos fenômenos observáveis de uma série temporal existe a possibilidade de se construir um modelo matemático como uma representação simplificada da realidade (BARBANCHO, 1970).

Após a formulação do modelo matemático, obtido pela seleção entre as alternativas de classes de modelos identificadas como apropriadas para essa representação e subsequente estimação de seus parâmetros, é possível utilizá-lo para testar alguma hipótese ou teoria a respeito do mecanismo gerador do processo estocástico e realizar a previsão de valores futuros da série temporal (GRANGER; NEWBOLD, 1977; NELSON, 1973).

2.4.3 Previsão de Séries Temporais – Definição

Segundo Barbancho (1970), uma previsão é uma manifestação relativa a sucessos desconhecidos em um futuro determinado. A previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma consequente tomada de decisão, visando atingir determinados objetivos (MORETTIN; TOLOI, 2004).

Dependendo do valor assumido pelo horizonte de previsão, (SOUZA, 1989; WHEELWRIGTH; MAKRIDAKIS, 1985) classificam as previsões dos valores futuros de uma série temporal como de curto, médio ou longo prazo. Desse modo, diante da possibilidade de existência de diferentes horizontes de previsão, Refenes et al. (1993) especifica técnicas distintas para prognosticar os valores futuros de uma série temporal:

- ✓ **Previsão múltiplos passos:** esta abordagem, adotada para longos horizontes de previsão, procura identificar as tendências gerais e os pontos de inflexão mais relevantes na série temporal. Na previsão múltiplos passos, o conjunto de valores correntes é empregado na realização da previsão para determinado instante; esta previsão é, então, introduzida entre as observações passadas, compondo, desta forma, um novo conjunto de dados, sobre o qual será obtida a previsão do tempo subsequente.
- ✓ **Previsão simples passo:** nesta técnica não há incorporação de previsões aos dados utilizados para encontrar a próxima previsão, sendo esta, independente dos valores anteriormente previstos. A previsão é feita apenas para o período de tempo imediatamente posterior ao atual, a partir das observações da série temporal.

Para se confirmar a habilidade do modelo matemático em descrever a estrutura definida pelos dados da série temporal em análise faz-se necessária a investigação do poder preditivo do modelo especificado como o mais adequado para explicar o mecanismo gerador das observações considerando-o um processo empírico de verificação e comparações entre as previsões e as observações. É importante salientar que o caráter previsional de um determinado modelo, segundo Barbancho (1970), não pode ser sustentado quando forem

identificadas mudanças estruturais nas observações obtidas a partir da origem, em relação àquelas utilizadas para a elaboração do modelo.

2.4.4 Métodos de Previsão de Séries Temporais

De acordo com Morettin e Toloi (2004), a maioria dos métodos de previsão de séries temporais se baseia na suposição de que observações passadas contêm todas as informações sobre o padrão de comportamento da série temporal e esse padrão é recorrente no tempo. O propósito dos métodos de previsão consiste em distinguir o padrão de qualquer ruído que possa estar contido nas observações e então usar esse padrão para prever os valores futuros da série temporal. Assim, pela identificação desse componente, a previsão para períodos de tempo subsequentes ao observado pode ser desenvolvida.

Apesar de quase a totalidade dos métodos de previsão de séries temporais estar fundamentada apenas na análise das observações da série de interesse para a especificação de algum modelo que descreva essas observações, alguns procedimentos de previsão tentam explicar o comportamento de uma série temporal pela evolução dos fenômenos observacionais de outras séries. Desta forma, dependendo do número de séries temporais envolvidas na modelagem, Souza (1989) classifica os métodos de previsão em univariados, funções de transferência e multivariados.

Os métodos univariados, que compreendem a maior parte dos métodos de previsão de séries temporais, consideram somente uma única série para a realização dos prognósticos. As previsões decorrentes da aplicação de métodos univariados podem estar relacionadas apenas com as informações contidas na série histórica de interesse (métodos baseados na estatística clássica) ou também, além de incorporarem essas informações, consideram outras supostamente relevantes e que não estão contidas na série analisada (métodos baseados na estatística bayesiana).

Aquelas metodologias nas quais a série de interesse é explicada não só pelo seu passado histórico, como também por outras séries temporais não-correlatas entre si, são conhecidas

como funções de transferência. Esta classe de métodos de previsão envolve, portanto, mais de uma série temporal, com a ressalva de que a relação de causalidade entre estas séries é perfeitamente conhecida.

Os métodos multivariados abrangem os procedimentos de previsão que associam mais de uma série temporal na efetivação de prognósticos sem, no entanto, qualquer imposição com relação à causalidade entre essas séries.

Diante disso, há uma variedade enorme de métodos de previsão de séries temporais, cada qual com suas capacidades e limitações (WHEELWRIGTH; MAKRIDAKIS, 1985). Qualquer que seja a classificação desses métodos é possível utilizar um número muito grande de métodos diferentes para descrever o comportamento de uma série particular. A seleção do método de previsão adequado depende de vários fatores, tais como o comportamento do fenômeno observável ou o conhecimento *a priori* que se tenha sobre a sua natureza e sobre o objetivo da análise.

Souza (1989), Wheelwrigth e Makridakis (1985) classificam os métodos de previsão baseados exclusivamente em uma única série histórica de dados em métodos de decomposição, métodos simples de previsão e métodos avançados de previsão de séries temporais.

Os métodos de decomposição assumem que uma série temporal é constituída por um conjunto de componentes não-observáveis (SOUZA, 1989). Dessa forma, pela identificação das componentes individuais presentes no padrão básico da série histórica de dados (tendência, ciclo, sazonalidade e aleatoriedade), a extrapolação para o futuro pode ser realizada (WHEELWRIGTH; MAKRIDAKIS, 1985).

Segundo Morettin e Tolo (2004), a componente **sazonal** representa as flutuações da série de acordo com algum fator de sazonalidade. O **ciclo** apresenta um comportamento similar à componente sazonal, embora tenha normalmente comprimento maior que aquela. Justamente pelo fato de não apresentar duração uniforme, a identificação da componente ciclo é mais problemática. A **tendência** representa o aumento ou declínio gradual nos valores das observações de uma série temporal. Com a remoção dos componentes de

sazonalidade, ciclo e tendência, a componente **aleatória** fica determinada (WHEELWRIGTH; MAKRIDAKIS, 1985).

Wheelwright e Makridakis (1985) argumentam que vários procedimentos para a decomposição de séries temporais foram desenvolvidos, cada qual tentando isolar os componentes não-observáveis da série o mais acuradamente possível. O objetivo desses procedimentos consiste em remover cada um dos componentes, permitindo que o comportamento da série temporal seja mais bem compreendido e, conseqüentemente, prognosticar valores futuros mais apropriados.

Já os métodos simples de previsão de séries temporais são assim classificados por que efetuam a previsão do valor futuro da série temporal pelo alisamento das observações passadas da série de interesse (WHEELWRIGTH; MAKRIDAKIS, 1985). Assumindo que os valores extremos da série representam flutuações aleatórias (MORETTIN; TOLOI, 2004) avaliam que o propósito desses métodos consiste em identificar o padrão básico presente nos dados históricos e, então, usar esse padrão para prever valores futuros.

Morettin e Toloi (2004) associam a grande popularidade desses métodos à simplicidade, à eficiência computacional e à razoável previsão obtida. Entre os métodos simples de previsão destacam-se o da Média Móvel, o Alisamento Exponencial Simples, o Alisamento Exponencial Linear e o Alisamento Exponencial Sazonal e Linear de Winter (WHEELWRIGTH; MAKRIDAKIS, 1985).

No universo dos métodos de previsão de séries temporais mais complexos encontram-se os modelos Autoregressivo e Médias Móveis (AR, MA e ARMA), modelos Autoregressivo Integrado de Médias Móveis (ARIMA), Filtros de Kalman e AEP, modelos ARARMA de Parzen, modelos ARMA Multivariáveis (MARMA), entre outros (WHEELWRIGTH; MAKRIDAKIS, 1985). Os métodos assim classificados obtêm a previsão de algum valor futuro da série temporal pela combinação dos valores reais passados e/ou dos erros ocorridos.

Dentre os modelos de previsão de séries temporais mais complexos e mais comumente utilizados encontra-se o modelo ARIMA (*AutoRegressive Integrate Moving Average*). O

destaque do modelo foi atribuído ao modelo de George Box e Gwilyn Jenkins (BOX; JENKINS, 1976), que também foi incluído como modelo complexo de análise de séries temporais principalmente pela sua fundamentação teórica, sendo a princípio capaz de manipular séries temporais de qualquer natureza.

O método de Box e Jenkins (1976) consiste na busca de um modelo ARIMA (*AutoRegressive Integrate Moving Average*) que represente o processo estocástico gerador da série temporal, a partir de um modelo ARMA (Autoregressivo e de Médias Móveis) aplicável na descrição de séries temporais estacionárias, estendendo esse conceito para séries temporais não-estacionárias (NELSON, 1973).

Um processo ARIMA (p,d,q) pode ser representado pela equação abaixo.

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1)$$

Sendo $\nabla X_t = X_t - X_{t-d}$,

Onde os componentes da equação são representados por:

φ_p e θ_q = representam os parâmetros dos processos Autoregressivo e de Média Móvel de ordem p e q (ARMA p,q);

ε_t = corresponde ao erro de eventos aleatórios que não podem ser explicados pelo modelo; e

d = equivale ao grau de homogeneidade não-estacionária.

Wheelwright e Makridakis (1985) investigaram o poder preditivo de vários métodos comumente utilizados na previsão de séries temporais. Pela comparação dos resultados alcançados, identificaram situações nas quais esses métodos apresentam melhor desempenho e definiram alguns critérios para a seleção dos procedimentos de previsão, pela confrontação dos objetivos a atingir.

O estudo desenvolvido por tais pesquisadores constatou que o incremento da complexidade e da sofisticação estatística dos métodos de previsão de séries temporais não implica, necessariamente, em uma melhora na acuidade da previsão. "*Métodos simples de previsão podem apresentar desempenho extremamente satisfatório sob certas condições*" (WHEELWRIGTH; MAKRIDAKIS, 1985). Além disso, métodos de previsão menos complexos normalmente permitem alcançar total compreensão de suas suposições e limitações, e de interpretação de seus resultados. Assim, antes de se adotar um método de previsão mais complexo é necessário avaliar os benefícios que um método dessa natureza pode gerar em relação ao custo de sua aplicação.

2.4.5 Estudos realizados com ARIMA

Em 1970, Box e Jenkins apresentaram o método ARIMA, para análise de séries temporais, no livro *Time Series Analysis, Forecasting and Control*. O método supõe que os valores futuros de uma variável possam ser combinações lineares de seus valores e erros passados (ZOU et al., 2007). Este método é eficientemente utilizado para previsão de variáveis econômicas, mercadológicas e sociais. Entretanto, sua utilização fica restrita à quantidade de dados. Tseng e Tzeng (2002) argumentam que o modelo requer no mínimo 50 e preferencialmente 100 ou mais observações. Na tabela 1 são apresentados alguns trabalhos com o uso da modelagem ARIMA evidenciando a possibilidade de construir modelos que descrevam com precisão o processo gerador da série temporal proporcionando previsões acuradas quanto aos valores futuros.

Tabela 1 - Exemplos de pesquisas que utilizaram ARIMA para previsões

ANO	Pesquisadores	Objeto de Estudo
1998	Ho e Xie	Previsão de falhas em sistemas mecânicos
2001	Junttilla	Previsão da taxa de inflação futura na Finlândia
2001	Tseng et al.	Previsão da taxa de câmbio entre a moeda norte-americana e a de Taiwan
2002	Tseng e Tzeng	Previsão da produção de máquinas e bebidas fortes em Taiwan
2007	Ediger, Akar e Urgulu	Previsão das quantidades produzidas de combustível fóssil
2007	Erdogdu	Previsão da demanda de eletricidade na Turquia
2007	Zou et al.	Previsão do preço do trigo na China

Fonte: Sobreiro, V. A. et al. Precificação do etanol utilizando técnicas de redes neurais. Revista de Administração. São Paulo, v.44, n.1, p.46-58, jan/fev/mar 2009.

Sobreiro et al. (2009) examinaram o desempenho do modelo de Redes Neurais Artificiais – RNAs comparado com o modelo estatístico ARIMA para previsão do preço do etanol combustível no mercado brasileiro. Os resultados obtidos demonstraram que o modelo de RNAs é consideravelmente mais acurado do que o modelo ARIMA, tradicionalmente utilizado como ponto de referência. Ainda, avaliaram que o modelo pode ser utilizado para auxiliar os comerciantes a restringirem seus riscos com relação às oscilações do preço do etanol combustível, além de facilitar o processo de tomada de decisão.

O uso da modelagem ARIMA para o preço do boi gordo foi abordado em diversos trabalhos com resultados que contribuem para uma análise crítica do assunto. Medeiros et al. (2006) utilizaram a modelagem ARIMA para previsão do preço da arroba do boi gordo para o período de janeiro de 1995 a junho de 2005. Os resultados encontrados avaliaram que 95,72% da variação do preço recebido pela arroba do boi gordo são explicados pelo modelo ARIMA. Os autores avaliaram que

O uso da modelagem ARIMA na previsão de preços, a) sob o ponto de vista teórico, o modelo apresenta coeficientes estatisticamente significantes, com indicadores de erros pequenos e com boa explicação da variação dos dados originais; b) sob o ponto de vista prático, revela um processo de previsão acurado, produzindo resultados significativos e próximos aos valores de mercado (MEDEIROS et al. , 2006).

Bressan (2001) utilizou o Modelo ARIMA, o Modelo de Redes Neurais, o Modelo Bayesiano e Modelos Estruturais para previsão de preços aplicados em contratos futuros agropecuários. A aplicabilidade dos modelos de previsão é confirmada a partir da sua utilização como ferramenta de decisão de compra e venda de contratos futuros da BM&F, em datas próximas ao vencimento, em contratos do Boi Gordo, Café e Soja. Os resultados apresentaram potencial de uso destes modelos com destaque para o modelo ARIMA e o modelo Estrutural. Bressan (2001) ainda conclui que os modelos de previsão captam, de forma coerente, o padrão de comportamento dos preços analisados e ainda, os retornos financeiros se mostraram positivos para a maioria dos contratos.

No estudo realizado por Bressan (2004), os modelos de previsão de séries temporais utilizando-se de séries de *commodities* resumem-se aos apresentados na tabela 2. Este autor busca construir previsões das cotações do mercado físico que pudessem sinalizar posições de compra e venda no mercado futuro. Além disso, comparou os retornos médios de cada modelo em operações de compra e venda no mercado futuro das commodities de boi gordo, café e soja na BM&F/BOVESPA/SP. Para tanto, utilizou uma medida clássica de retorno-risco, o Índice Sharpe (IS), que considera o desvio padrão como uma medida de risco.

Tabela 2 - Exemplos de pesquisas que utilizaram séries temporais para previsões

ANO	Pesquisadores	Objeto de Estudo
1974	Leuthold	Previsão de preços no mercado futuro de Boi Gordo nos EUA por meio de séries temporais
1979	Leuthold e Hartman	Previsão de preços no mercado futuro de Boi Gordo nos EUA por meio de modelos econométricos e passeio aleatório
1981	Just e Rausser	Comparação do preço no Mercado Real/Futuro para trigo, soja, algodão, boi gordo e suíno nos EUA
1988	Garcia et al.	Previsão de preços no mercado futuro de boi gordo dos EUA por meio de modelos econométricos e modelo ARIMA
1988	Taylor	Interpretações de tendências de mercado e Modelo ARIMA para negociação em mercados futuros de TBond's, nos EUA
1993	Grudnitski e Osburn	Precisões de preço no mercado futuro de ouro e preços de ações da S&P500, nos EUA, utilizando redes neurais artificiais
1993	Kenyon et al.	Previsões de preços no mercado futuro de milho e soja nos EUA utilizando regressão de variâncias
1996	Silva	Previsão para maximização de ganhos em diversos contratos futuros no Brasil utilizando análise técnica
1998	Ntungo e Boyd	Previsão de preços no mercado futuro de milho, prata e marco alemão na Alemanha por meio de modelos ARIMA e Redes Neurais

Fonte: Adaptado de BRESSAN, A.A. Tomada de Decisão em Futuros Agropecuários com Modelos de Previsão de Séries Temporais. RAE Eletrônica. Revista de Administração de Empresas FGV/EASP/SP, v.3, n.1, artigo 9, Jan-Jun/2004.

A fim de detectar o estado da arte na utilização de séries temporais para predição, além dos trabalhos mencionados até o momento, a tabela 3 procurou sintetizar e sinalizar o potencial de aplicação dos modelos ARIMA para o processo de tomada de decisão e ainda, na manutenção e continuidade de negócios em diversas áreas incluindo *commodities*.

Tabela 3 - Pesquisas que utilizaram séries temporais para previsões

ANO	Pesquisadores	Objeto de Estudo
1983	Armstrong e Lusk	Análise da competição (M-Competiton) organizada por Makridakis (1982) com base em análise de 1001 séries temporais com diferentes métodos de previsão.
1998	Ho e Xie	Analizou a confiabilidade em sistemas de falhas mecânicas com base no ARIMA.
2003	Passos et al.	Utilizou a modelagem ARIMA para previsão da arrecadação de ICMS do Estado do Pará com séries de dados mensais/padrão sazonal.
2007	Duarte	Analizou o mercado de soja em grão no período de 2001 a 2007 sobre o complexo agroindustrial da soja. Utilizaram-se dados diários de 1997 a 2007 por meio do ARIMA.
2007	Gaio et al.	Analizou o mercado de boi gordo na BM&F no período de agosto de 1997 a maio de 2005 utilizando redes neurais artificiais e modelo AR-GARCH.
2007	Abitante	Modelou séries de concessão de crédito bancário para pessoas físicas, jurídicas e para financiamento de atividades rurais incluindo carne bovina.
2007	Ediger e Akar	Utilizou ARIMA e SARIMA para estimar demanda futura de energia primária na Turquia no período de 2005 a 2020.
2010	Martins e Martinelli	Analizou indicadores antecedentes da commodity açúcar como uma ferramenta para prever comportamento dos ciclos de crescimento e retração de uma commodity, no período de 1960 a 2008.
2013	Padilha Jr. et al.	Aplicou modelo ARIMA para série temporal estacionária do indicador de preços do boi gordo para o Estado do Paraná.

Fonte: elaborado pela autora

Araújo et al. (2012) avaliou a eficácia dos modelos de séries temporais utilizando-se o ARIMA e SARIMA (modelos sazonal) na previsão de preços do boi gordo em Campos dos Goytacazes/RJ, no período de 01/2005 a 12/2009. Como medida de desempenho estes autores adotaram o Erro Quadrático Médio de Previsões (EQMP) e concluíram que os modelos são eficazes instrumentos na previsão dos preços do boi gordo, especialmente o SARIMA.

Dos trabalhos pesquisados a metodologia ARIMA mostrou-se mais eficiente e previsões baseadas nestes modelos estão aptas a auxiliar os “players” do mercado em suas

negociações relacionadas ao mercado futuro de *commodities*. Os resultados obtidos por esses autores ainda não são conclusivos visto que a comparação do desempenho preditivo dos modelos propostos foi pouco explorada por agentes econômicos e, sendo assim, há ainda um campo vasto para estudos com o objetivo de avaliar ganhos ou perdas e ainda, o risco associado com as decisões baseadas nestes modelos.

2.4.6 Modelos ARCH e GARCH

Ainda que não sejam objetos deste trabalho é importante observar que, similarmente ao modelo ARIMA, há outro grupo de modelagem para previsão conhecidos como modelo ARCH e GARCH que operam com a variância condicional.

O modelo ARCH (*Autoregressive Conditional Heteroscedasticity*), ou seja, modelo autoregressivo com heteroscedasticidade condicional foi proposto inicialmente por Engle (1982). Desde então, têm surgido inúmeros estudos com refinamentos e modificações do modelo ARCH básico e também com aplicações empíricas em taxa de câmbio, mercado de ações e muitos outros tipos de ativos (BOLLERSLEV; ENGLE; NELSON, 1994).

A variância condicional é um processo autorregressivo (AR), o que resulta em erros condicionalmente heteroscedásticos. Dada a importância das previsões de variância condicional, métodos estatísticos começaram a ser propostos com essa finalidade. O pioneiro nesse campo foi Engle (1982), que, com o objetivo de estimar a variância da inflação, propôs o modelo ARCH (*Autoregressive Conditional Heteroscedasticity*). Esse modelo é baseado num processo autorregressivo na variância com o objetivo de prever a variância condicional no próximo período. Um processo autorregressivo pode ser definido como um processo estocástico em que uma variável aleatória estabelece uma relação de dependência com seus valores passados e com erros aleatórios.

Assim, um modelo ARCH (p) pode ser definido como:

$$r_t = \sqrt{\sigma_t^2} \varepsilon_t \quad (2)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \alpha_i r_{t-p}^2 \quad (3)$$

Sendo, ε_t a sequência de variáveis aleatórias independentes e identicamente distribuídas com média zero e variância unitária, $\alpha_0 > 0$; $\alpha_1 \geq 0, i > 0$, σ_t^2 representa a variância e r_t representa o retorno de um ativo financeiro qualquer no instante t , no qual é calculado por uma simples relação com o preço do ativo, P_t , em questão em determinado instante t ,

$$r_t = \ln \frac{P_t}{P_{t-1}} = \ln P_t - \ln P_{t-1} \quad (4)$$

As séries financeiras se enquadram a esses modelos, pois apresentam a variância condicional evoluindo com o tempo.

Uma generalização do modelo ARCH foi proposta por (BOLLERSLEV, 1986), denominado GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*). Trata-se de uma técnica de séries temporais, na qual as variâncias observadas no passado servem para explicar a variância no futuro, ou uma técnica de séries temporais que permite modelar a dependência serial da variância. O modelo GARCH pode ser usado para descrever a volatilidade com menos parâmetros que um modelo ARCH. Esses tipos de modelos, entretanto, são não-lineares no que se refere à variância. Um modelo GARCH (p, q) pode ser representado como

$$r_t = \sqrt{\sigma_t^2} \varepsilon_t \quad (5)$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i r_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (6)$$

onde ε_t com média 0 e variância 1.0, $\alpha_0 > 0, \alpha_1 \geq 0, \beta_j \geq 0$ (condições de não negatividade da variância condicional), e

$$\sum_{i=1}^m (\alpha_i + \beta_i) < 1, m = \max(p, q) \quad (7)$$

A expressão que relaciona σ_t^2 , expressa a volatilidade, ou seja, como a variância σ^2 , se comporta de acordo com o retorno dos períodos passados, r_{t-1}^2 , e a própria variância passada σ_{t-1}^2 (BOLLERSLEV et al., 1992). Assim, no modelo ARCH, a variância do retorno em determinado período depende dos retornos dos períodos passados. No modelo GARCH, essa

variância depende dos retornos mas também das variâncias passadas (BOLLERSLEV, 1986; ENGLE, 1982). Assim como nos modelos ARCH, quando se têm volatilidades altas, estas são precedidas de retornos ou volatilidades grandes (MORETTIN; TOLOI, 2004).

Um modelo GARCH (p, q) apresenta a seguinte variância não-condicional

$$Var(r_t) = \frac{\alpha_0}{1 - \sum_{i=1}^q - \sum_{j=1}^p \beta_i} \quad (8)$$

Se essa variância não for constante, trata-se de um processo não estacionário. Contudo não se pode dizer a mesma coisa da variância condicional, pois a observação de heterocedasticidade condicional não é motivo para não estacionariedade.

Ao se trabalhar com séries financeiras, o modelo usado com maior frequência é o modelo GARCH (1,1), sendo o mais utilizado pelos agentes de mercado (SOUZA, 1989). Esse modelo, comumente usado na prática, pode ser representado como

$$r_t = \sqrt{\sigma^2} + \varepsilon_t \quad (9)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \beta_1 \alpha_{t-1}^2 \quad (10)$$

com $\alpha_1 \geq 0, \beta_1 < 1, \alpha_1 + \beta_1 < 1$ (condição para a estacionariedade do modelo).

A utilização de modelos GARCH, contudo, implica algumas ressalvas. Apesar da eficiência do modelo, ao se avaliarem os riscos de ativos negociados no mercado financeiro, os resultados obtidos funcionam apenas como parte para um conjunto de soluções com relação à alocação financeira, dado que as decisões nesse campo são tomadas com base em inúmeros outros fatores, devido à incerteza desses mercados (NELSON, 1991). Além disso, o modelo GARCH apresenta melhor desempenho em condições de mercado com relativa estabilidade. Embora modele a variância condicional, esse modelo não consegue capturar flutuações elevadas nos mercados, como *crashes*, que são capazes de levar a resultados qualitativamente distintos, como mudanças estruturais (ENDERS, 1995; MELLAGI FILHO,

2000). Nas séries financeiras as “caudas pesadas” não são capturadas pelos modelos GARCH, entretanto, a heteroscedasticidade consegue explicar essa ocorrência em partes, por isso distribuições do tipo *t-Student* são frequentemente utilizadas na modelagem GARCH (ANDERS, 2006).

2.5 Redes Neurais Artificiais na Análise de Séries Temporais

Nas últimas décadas, com o aumento do poder da computação a um custo reduzido, houve significativo aumento do uso de inteligência computacional na área econômica. Dentre as diversas metodologias da inteligência computacional, a de redes neurais artificiais é a que se inspira na forma complexa de processamento baseada em neurônios. Como sistemas biológicos que possuem neurônios são capazes de prever ações, a escolha de um modelo inspirado nesta biologia para predição é naturalmente o de redes neurais artificiais (VEMURI; ROGERS, 1994).

Na predição de comportamento futuro, de natureza indutiva, as redes neurais artificiais têm recebido atenção especial a partir da década de 1990 (STEINER; WITTKEMPER, 1996; HUANG; YU, 2006) e têm demonstrado eficiência quanto ao seu potencial preditivo e na manipulação das variáveis utilizadas nas séries temporais.

O objetivo das redes neurais artificiais consiste em capturar os princípios básicos de manipulação de informação do cérebro humano e aplicar esse conhecimento na resolução de problemas que exigem aprendizado a partir da experiência, ou seja, se fundamentam nos estudos sobre a estrutura do cérebro humano para tentar emular sua forma inteligente de processar informações (BEALE; JACKSON, 1990). Apesar de se desconhecer a maneira pela qual o cérebro manipula informações complexas, sabe-se que a modelagem do conhecimento contido em um problema específico pode ser representada por meio de interconexões entre células nervosas. Estruturalmente, a rede neural artificial, também conhecida por modelo conexionista de computação, se assemelha à rede neural biológica pela composição de seus neurônios e pela conexão entre eles (WASSERMAN, 1989).

"Um modelo conexionista é uma estrutura de processamento de informações distribuída e paralela. Ela é formada por unidades de

processamento, comumente chamadas de nós, neurônios ou células, interconectadas por arcos unidirecionais, também chamados de ligações, conexões ou sinapses. Os nós possuem memória local e podem realizar operações de processamento de informação localizada. Cada célula possui uma única saída (axônio), a qual pode se ramificar em muitas ligações colaterais (cada ramificação possuindo o mesmo sinal de saída do neurônio). Todo o processamento que se realiza em cada unidade deve ser completamente local, isto é, deve depender apenas dos valores correntes dos sinais de entrada que chegam dos neurônios através das conexões. Estes valores atuam sobre os valores armazenados na memória local da célula" (HECHT-NIELSEN, 1988).

No atual estágio da tecnologia é possível realizar estudos de forma eficiente e rápida utilizando-se de redes neurais previamente treinadas. Estes estudos podem ser realizados nos mais diferentes segmentos da economia e não apenas no agronegócio, obtendo-se precisão e segurança no processo de tomada de decisão. Alguns estudos na área financeira avaliam a eficiência do uso de redes neurais artificiais para previsões (ORMONEIT, 1999; THAWORNWONG; ENKE, 2004 e HUARNING; YU, 2006).

Para o treinamento da rede neural artificial com o objetivo de predição de preços de carne bovina pode-se utilizar a rede do tipo *Multilayer Perceptron* – MLP. Uma rede do tipo MLP – *Multilayer Perceptron* é constituída por um conjunto de nós fonte, os quais formam a camada de entrada da rede (*input layer*), uma ou mais camadas escondidas (*hidden layers*) e uma camada de saída (*output layer*). Cabral Jr (1999) salienta que, para o projeto de uma rede MLP, faz-se necessário considerar três elementos: 1. A determinação do número de camadas escondidas; 2. A determinação do número de neurônios em cada uma das camadas escondidas e; 3. A especificação dos pesos sinápticos que interconectam os neurônios nas diferentes camadas da rede. Com referência aos pesos sinápticos, estes envolvem a utilização de algoritmos de treino supervisionados e, conforme afirma Cabral Jr (1999), as redes neurais MLP têm sido aplicadas na solução de vários problemas a partir da utilização de tais algoritmos. O algoritmo de treino universalmente utilizado para redes do tipo MLP é o algoritmo de retro-propagação do erro, conhecido como *Backpropagation Algorithm* (HAYKIN, 1999). Uma rede do tipo MPL apresenta a arquitetura demonstrada na figura 1.

Figura 1 - Arquitetura de uma rede neural multilayer perceptron com duas camadas escondidas

Fonte: HAYKIN, Simon S. Redes Neurais: princípios e práticas. Bookman: Porto Alegre/RS, 1999. p.186.

Haykin (1999) avalia que o algoritmo *Backpropagation* baseia-se na heurística do aprendizado por correção de erro, onde o erro é retro-propagado da camada de saída para as camadas intermediárias da rede neural artificial. O algoritmo *Backpropagation* consiste de dois passos através das diferentes camadas do MLP: um passo caracterizado como direto e outro passo caracterizado como reverso. Na caracterização do passo direto, um padrão de atividade do processo a ser aprendido (ou vetor de entrada) é aplicado aos nós de entrada do MLP e seu efeito se propaga através da rede camada por camada, produzindo na camada de saída a resposta do MLP à excitação aplicada (vetor de saída). Durante o passo direto os pesos sinápticos são todos fixos (HAYKIN, 1999).

Durante o passo reverso os pesos sinápticos são todos ajustados de acordo com a regra de aprendizagem por correção de erro. Especificamente, a resposta do MLP à excitação é subtraída de um padrão de resposta desejado para aquela excitação aplicada, de forma a produzir um sinal de erro, semelhante ao algoritmo *Least Mean Square* (LMS) desenvolvido por Bernard Widrow. Este sinal de erro é, então, propagado de volta pelos mesmos neurônios utilizados no passo direto, mas no caminho contrário do fluxo de sinal nas conexões sinápticas. Os pesos sinápticos são, então, ajustados de forma que a resposta obtida do MLP aproxime-se mais do padrão de resposta desejado (HAYKIN, 1999).

2.5.1 Histórico das Redes Neurais Artificiais

Conforme Másson e Wang (1990), o primeiro modelo formalizado de redes neurais artificiais foi proposto por McCulloch e Pitts, em 1943. Essa estrutura abstraía a complexidade da atividade neural em sistemas neurais reais, assim como complicadas características encontradas no corpo de neurônios biológicos, formando a base para a maioria dos modelos conexionistas desenvolvidos posteriormente.

Em 1949 Hebb publica *The Organization of Behavior*, assumindo que a aprendizagem do conhecimento representado em uma rede neural é alcançada pelo fortalecimento das conexões entre neurônios adjacentes sempre que esses estiverem excitados (HEBB, 1949).

Em 1958, Frank Rosenblatt criou o *perceptron*, um modelo cognitivo que consistia de unidades sensoriais conectadas a uma única camada de neurônios de McCulloch e Pitts, capaz de aprender tudo o que pudesse representar. Rosenblatt demonstrou que, se fossem acrescidas sinapses ajustáveis, as redes neurais de McCulloch e Pitts poderiam ser treinadas para classificar padrões em classes linearmente separáveis, convergindo em um número limitado de passos (MÁSSON; WANG, 1990).

No início da década de 60, Widrow e Hoff publicam um artigo no qual especificaram um neurônio artificial baseado no modelo de McCulloch e Pitts, denominado *adaline*. Conforme Másson e Wang (1990), a importância desse modelo estava associada à regra de aprendizagem proposta, a regra Delta.

A publicação de *Perceptrons* de Minsky e Papert, em 1969, expôs as limitações do modelo de Rosenblatt, provando que tais redes não eram capazes de resolver uma ampla classe de problemas devido às restrições de representação (MÁSSON; WANG, 1990; WASSERMAN, 1989). O impacto desta publicação foi devastador, praticamente desaparecendo o interesse em redes neurais artificiais nos anos seguintes. Somente poucos pesquisadores como Malsburg, Grossberg, Kohonen e Anderson permaneceram concentrando suas atividades na abordagem conexionista.

A partir dos anos 80, com o avanço da tecnologia e o fracasso da escola simbolista na solução de determinados tipos de problemas, as redes neurais artificiais passaram a atrair substancial atenção novamente (WASSERMAN, 1989).

Em 1982, a introdução do modelo conexionista conhecido pelo nome de seu idealizador, John Hopfield, permitiu esclarecer, pelas suas características computacionais e estabilidade, boa parte das dúvidas até então existentes em relação ao processo dinâmico executado por determinadas redes neurais. No mesmo ano, Kohonen publicou um artigo descrevendo uma rede neural artificial baseada em auto-organização e nas características de aprendizado adaptativo do cérebro humano (MÁSSON; WANG, 1990).

Hinton e Seynowsky, em 1983, estenderam o modelo de Hopfield com a incorporação de dinâmica estocástica. Este modelo de rede neural passou a ser conhecido como Máquina de Boltzmann (WASSERMAN, 1989).

Cerca de dois anos mais tarde, Rumelhart, Hinton e Williams aperfeiçoaram a idéia de perceptron, criando o algoritmo *Backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986), levando a uma explosão de interesse em redes neurais. Este algoritmo foi aplicado em uma grande variedade de problemas, como na identificação da estrutura de proteínas, hifenização de palavras em inglês, reconhecimento da fala, compressão de imagens e previsão de séries temporais (MÁSSON; WANG, 1990). O sucesso deste algoritmo estimulou o desenvolvimento de muitas pesquisas em redes neurais artificiais e de uma variedade de modelos cognitivos.

2.5.2 Características das Redes Neurais Artificiais

Wasserman (1989) argumenta que as redes neurais artificiais, por serem baseadas nas redes neurais biológicas, apresentam um surpreendente número de características observadas no processo cognitivo humano, como o aprendizado pela experiência, a generalização a partir de exemplos e a abstração de características essenciais de informações que contém fatos irrelevantes.

O conceito de aprendizado como a habilidade de realizar tarefas novas que não podiam ser realizadas anteriormente foi definida por Carbonell (1989), ou seja, buscou-se melhorar a realização de tarefas antigas como resultado de mudanças produzidas pelo processo de aprendizado.

As redes neurais artificiais podem modificar seu comportamento em resposta aos estímulos produzidos pelo ambiente, regulando a força da conexão entre unidades de processamento adjacentes pela adaptação dos pesos sinápticos, reconhecendo as informações apresentadas às suas unidades visíveis (WASSERMAN, 1989).

Ainda segundo Wasserman (1989), um modelo conexionista é sensível às variações que podem ocorrer em informações procedentes de suas unidades de entrada, reconhecendo ruído e distorção. A capacidade da rede em se adaptar às novas situações, gerando valores de saída consistentes com os esperados, é vital para a aplicabilidade do modelo em um ambiente do mundo real.

Refenes et al. (1993) avalia que, embora a maioria das pesquisas em redes neurais artificiais tenham concentrado seus esforços na redução dos tempos de aprendizagem, a característica mais importante de um modelo conexionista é a habilidade em generalizar sobre o domínio do problema.

O bom desempenho da generalização depende, dentre outros fatores, do número de parâmetros livres da rede neural artificial (LE CUN, 1989). É desejável diminuir o tamanho das conexões sem, entretanto, reduzir o tamanho da rede ao ponto onde não se possa computar a função desejada.

Alguns modelos de redes neurais artificiais são capazes de abstrair a essência do conjunto de dados a elas apresentados, permitindo, dessa forma, a classificação ou reconhecimento de padrões incompletos. Dentre todas as características das redes neurais artificiais, nenhuma desperta tanto interesse quanto a sua habilidade em realizar o aprendizado (WASSERMAN, 1989).

Conforme Másson e Wang (1990), o aprendizado em um modelo de redes neurais artificiais é decorrente do treinamento da rede por meio da apresentação de padrões às suas unidades visíveis.

O objetivo do treinamento consiste em atribuir os pesos sinápticos com valores apropriados, de modo a produzir o conjunto de saídas desejadas, ou ao menos consistentes, com um intervalo de erro estabelecido (FREEMAN; SKAPURA, 1992). Desta forma, o processo de aprendizado subsiste na busca de um espaço de pesos pela aplicação de alguma regra que defina esta aprendizagem (MÁSSON; WANG, 1990).

Em geral, as regras de aprendizado podem ser consideradas variantes da Regra de Hebb (HEBB, 1949). Na essência, Hebb propõe que a sinapse conectando dois neurônios seja reforçada sempre que ambos os neurônios estiverem ativos.

Uma rede neural artificial que tenha a regra de Hebb como regra de aprendizado modifica os pesos sinápticos entre as conexões das unidades de processamento w_i e w_j proporcionalmente ao produto dos níveis de excitação desses neurônios, conforme eq. (11).

$$\Delta w_{ij} = \eta x_i x_j \quad (11)$$

Onde Δw_{ij} corresponde à alteração no valor do peso do neurônio w_{ij} , η corresponde a taxa de aprendizagem (sendo que $0 < \eta < 1$), x_i e x_j a atividade pré e pós sináptica.

Como uma adaptação à regra de Hebb, a regra Delta modifica os pesos de acordo com a variação entre a saída desejada e a observada no treinamento (MÁSSON; WANG, 1990). A eq.(12) atualiza os pesos associados aos neurônios da rede neural artificial pela aplicação da regra Delta.

$$\Delta w_{ij} = \eta \delta x_i \quad (12)$$

Com $\delta x_i = (d_i - x_i)$, onde d_i representa a saída desejada para a unidade de processamento w_i

Na figura 2 está representada uma rede neural artificial. O modelo neural representado nesta figura apresenta:

- ✓ Um conjunto de sinapses ou elos de conexão, sendo que cada sinapse é caracterizada por um peso ou força própria. Especificamente, um sinal X_j na entrada da sinapse j conectada ao neurônio K é multiplicado pelo peso sináptico w_{kj} . É importante notar como são escritos os índices do peso sináptico w_{ki} . O primeiro índice se refere ao neurônio em questão e o segundo refere-se ao terminal de entrada da sinapse do peso;
- ✓ Um somador ou integrador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio; estas operações constituem-se num combinador linear; e,
- ✓ Uma função de ativação para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito.

Figura 2 - Modelo de um neurônio artificial

Fonte: Haykin, 1999.

2.5.3 Estudos realizados com redes neurais artificiais (RNA)

O uso da tecnologia de redes neurais artificiais tem sido avaliado em algumas áreas como apoio ao processo de tomada de decisão. Diversos trabalhos foram avaliados com o intuito de realizar previsões. O uso de redes neurais artificiais em diversos setores da economia foi estudado por Widrow, Rumelhart e Lehr (1994) mostrando a superioridade da RNA para predição de indicadores da economia e de setores individuais. Steiner e Wittkemper (1996) discutiram diferentes métodos de previsão de risco sistemático no mercado de ações alemão. Estes autores utilizaram 67 Demonstrações Financeiras de empresas na Alemanha no período de 1967 a 1986 e concluíram que as previsões mais precisas foram obtidas por redes neurais artificiais sendo otimizadas por um algoritmo genético. Deco, Neuneier e Schurmann (1997) selecionaram séries de dados do índice da bolsa de valores de Frankfurt (DAX) para avaliar dados não-paramétricos para aprendizagem de redes neurais. Estes autores utilizaram 30 empresas que formam o índice da bolsa de valores de Frankfurt e que representavam 70% da movimentação do respectivo índice.

No mercado financeiro há vários estudos com o uso de redes neurais com o objetivo de realizar previsões. Ormoneit (1999) usou redes neurais artificiais para fixação de preços de derivativos financeiros com Filtro de Kalman e concluiu que a rede neural supera os modelos de referência no mercado.

Thawornwog e Enke (2004) utilizaram variáveis econômicas e financeiras para previsão de retorno de ações do portfólio de ações da S&P 500 (*Standart and Poor 500*). Estes autores avaliaram a eficácia da RNA com o indicador RMSE e a tecnologia apresentou-se eficiente com indicativo de menor erro de previsão. Da mesma forma, Huarng e Yu (2006) utilizaram o índice de ações de Taiwan no período de 1991 a 2003 com o treinamento de uma RNA para padrões conhecidos de dados e uma RNA para padrões desconhecidos. A medida de desempenho do modelo foi o indicador RMSE e o modelo híbrido com padrões conhecidos e padrões desconhecidos superaram o modelo básico de redes neurais artificiais.

Malik e Nasereddin (2006) utilizaram redes neurais artificiais para previsão do preço do barril de petróleo. Da mesma forma, Hassan, Nath e Kirley (2007) compararam os modelos HMM (Hidden Markov Model), ANN (Artificial Neural Networks) e GA (Genetic Algorithms) para a série de dados do setor de TI das empresas Apple, IBM e Dell. A medida de acurácia foi a medida de erro MAPE e os resultados apresentaram superioridade da RNA.

Sobreiro et al. (2009) compararam o uso de redes neurais artificiais (RNAs) usando a arquitetura *Perceptron Multicamadas* com o método ARIMA para previsões de preços futuros do Etanol Combustível. Os autores avaliaram, a partir das medidas de erro agregado em previsões, que o uso de redes neurais para predição de preços é eficiente e pode ser utilizada como método alternativo para predição de preços do etanol combustível por gerentes financeiros e empresários.

A pesquisa por metodologias que contribuam para o processo decisório no agronegócio foi estudada por Ferreira et al. (2011) que objetivavam avaliar estratégias de previsão de preços no contexto do agronegócio de quatro *commodities* específicas: soja, boi gordo, milho e trigo. O uso de redes neurais artificiais como um método eficaz para produzir informações ao agronegócio foi avaliado por diversos pesquisadores e resumido na tabela 4 abaixo.

Tabela 4 - Trabalhos realizados com commodities agrícolas

Autores	Método	<i>Commodities</i> ou segmento do estudo
Yonenaga e Figueiredo (1998)	Redes neurais	Soja
Lima et al. (2007)	Arima	Açúcar, café, milho, soja e boi gordo
Melo e Nascimento (2007)	Redes neurais	Açúcar
Corsine e Ribeiro	Filtro de Kalman	Açúcar
Sobreiro et al. (2008)	Redes neurais	Açúcar
Eddy et al. (2008)	Redes neurais	Agricultura de precisão
Sobreiro et al. (2009)	Redes neurais	Etanol
Ribeiro et al. (2010)	Redes neurais, média móvel e suavização exponencial	Açúcar, etanol, café e soja
Ceretta et al. (2010)	Arima e redes neurais	Soja
Zou et al. (2010)	Redes neurais	Análise de solo
Kankal et al. (2011)	Redes neurais e modelos de regressão	Consumo de energia
Singhal e Swarup (2011)	Redes neurais	Preço de energia
Gomes et al. (2011), Chen (2011), Khashei e Bijari (2011) e Wong et al. (2011)	Redes neurais	Séries financeiras

Fonte: Ferreira, L. et al. Utilização de Redes Neurais Artificiais como Estratégica de Previsão de Preços no Contexto de Agronegócio. RAI – Revista de Administração e Inovação. v. 8, n. 4, p. 6-26, out/dez. 2011.

3 OBJETIVOS

3.1 Objetivo Geral

O objetivo geral desta pesquisa é definir um modelo matemático capaz de prever os preços de carne bovina usando uma especificação do Modelo ARIMA, Análise de Risco e Redes Neurais Artificiais.

3.2 Objetivos Específicos

São objetivos específicos da pesquisa:

- Obter série temporal que represente a formação de preços de carne bovina – série de preços do Boi Gordo;
- Utilizar metodologia de modelos econométricos – ARIMA para realizar previsões de preços de carne bovina – Boi Gordo;
- Criar um modelo de análise de risco usando método de Monte Carlo implementado no Excel para gerar as distribuições dos preços;
- Usar as distribuições obtidas no modelo estatístico para treinar e testar uma rede neural artificial;
- Gerar previsões usando séries temporais conhecidas e analisar as distribuições previstas pela Rede Neural Artificial –RNA do tipo *Multilayer Perceptron* - MLP.

4 MATERIAL E MÉTODOS

4.1 Caracterização da Pesquisa

Quanto à área de estudo da ciência, a pesquisa é aplicada porque apresenta como motivação a necessidade de produzir conhecimento para a aplicação de seus resultados no mercado físico do Boi Gordo. Barros e Lehfeld (2000, p.78) salientam que a pesquisa aplicada tem como objetivo *“contribuir para fins práticos, visando à solução mais ou menos imediata do problema encontrado na realidade”*.

Quanto aos objetivos, a pesquisa é descritiva e explicativa por buscar características da gestão estratégica de preços de Boi Gordo. Segundo Cervo e Brevian (1996) a pesquisa descritiva observa, registra, analisa e correlaciona fatos ou fenômenos (variáveis) sem interferência do pesquisador, procurando descobrir, com determinada precisão, a frequência com que um fenômeno ocorre, sua relação e conexão com outros, sua natureza e características. A pesquisa explicativa busca identificar fatores determinantes para a ocorrência dos fenômenos observados.

Quanto à natureza a pesquisa é quantitativa, pois se busca traduzir em números as informações a serem classificadas e analisadas com o uso de técnicas estatísticas. Conforme Lakatos e Marconi (1991) a pesquisa quantitativa é considerada como uma investigação objetiva que se baseia em variáveis mensuráveis e proposições prováveis.

Quanto aos procedimentos técnicos, para alcançar o objetivo proposto foram realizadas modelagens e simulações em um conjunto de variáveis (preço) que variam ao longo de um tempo específico no setor de carne bovina tendo as relações quantitativas e causais entre as variáveis previamente definidas. A primeira fase do trabalho constitui-se no levantamento das variáveis quantitativas observadas a partir de séries temporais na busca de um melhor entendimento do comportamento dos preços relacionados ao passado e ao futuro.

A segunda fase constitui-se a partir da análise e correlação de variáveis relacionadas a preços, por meio da utilização da técnica de análise de séries temporais, Avaliação de Risco e

Redes Neurais Artificiais (RNA) com o objetivo de elaborar um modelo de predição de preços de carne bovina – boi gordo.

4.2 Técnica de Coleta de Dados

Na primeira fase do trabalho de campo o processo de coleta de dados consistiu-se no levantamento de séries históricas de preços do boi gordo. O período proposto compreendeu o período entre 23 de julho de 1997 e 18 de fevereiro de 2013, num total de 3.870 observações.

Os dados de preços do boi gordo foram obtidos no Centro de Estudos Avançados em Economia Aplicada (CEPEA), que é parte integrante do Departamento de Economia, Administração e Sociologia da Escola Superior de Agricultura Luiz de Queiroz, unidade da Universidade de São Paulo, em Piracicaba/SP.

4.3 Composição e Tratamento de Dados da Pesquisa

Os dados de preço da série histórica referentes ao BOI GORDO são expressos em reais (R\$) e por Arroba. (R\$/arroba). O indicador do Boi Gordo ESALQ/BM&FBOVESPA compreende bovino macho, castrado ou inteiro (animais inteiros são considerados desde 1º de agosto/2011), comum e rastreado com 16 arrobas líquidas ou mais de carcaça e idade máxima de 42 (quarenta e dois) meses, de acordo com as especificações do contrato futuro de boi gordo da BM&FBOVESPA. O cálculo representa a média diária ponderada de preços à vista do boi gordo no Estado de São Paulo. Os valores coletados no Estado de São Paulo (dividido em 4 regiões: Presidente Prudente, Araçatuba, Bauru e São José do Rio Preto) e, a participação de cada região é definida pela soma dos volumes de abate das unidades que possuem cadastro no Serviço de Inspeção Federal (SIF). Os negócios a prazo são transformados para a vista (valor presente) pela taxa CDI-DI.

Na segunda fase do trabalho, para obter os resultados da análise das variáveis quantitativas predominantes, foi utilizado o software *Model Risk® Standard Version 4.3.0.5*. (Vose Software, 2011), o software *Matlab®* para modelagem e simulações do modelo ARIMA e, a

rede MLP – *Multilayer Perceptron*, implementada no Laboratório de Física Aplicada e Computacional – LAFAC/FZEA/USP, a fim de testar a predição de preços com base em séries temporais e redes neurais.

No modelo inicial de análise dos dados das séries temporais obtidos para o Exame de Qualificação do Programa de Doutorado partiu-se da premissa de que os preços futuros são afetados pelo comportamento médio dos preços passados. Assim, utilizou-se a média aritmética dos últimos meses para a sequência de preços futuros. Porém, o estudo do comportamento dos preços passados demonstrou a necessidade de utilização de outras ferramentas para encontrar o modelo que represente melhor a realidade dado às características não lineares da série temporal estudada (Apêndice 1).

4.4 Metodologia ARIMA

Os métodos de previsão de séries temporais mais complexos são classificados como sendo os modelos Autoregressivos e Médias Móveis (AR, MA e ARMA), modelo Autoregressivo Integrado de Médias Móveis (ARIMA), dentre outros. O modelo ARIMA é considerado modelos univariados por envolver apenas uma série de tempo. Neste trabalho foi utilizado o modelo ARIMA por permitir realizar previsões de valores futuros de uma série tomando por base apenas seus valores passados e também choques ocorridos no presente e no passado, considerando a correlação existente entre os valores exibidos pela série (BOX; JENKINS, 1976). O procedimento para o desenvolvimento do modelo ARIMA consiste em três etapas representadas pela identificação dos parâmetros p e q e da ordem de integração, seguidos da etapa estimação e, na última etapa a verificação do modelo de previsão. O modelo ARIMA é descrito na figura 3.

Figura 3 - Modelo ARIMA e as etapas de implementação

O modelo ARIMA é formado por Componentes Autoregressivos (AR), por Filtro de Integração (I) e por Componentes Médias Móveis (MA).

Conforme Gujarati (2000), um processo Autoregressivo de ordem $p = AR(p)$ ocorre quando uma série temporal é descrita pelos seus valores passados e por um termo de erro ε_t que se comporta como um “ruído branco”. Pode ser descrita pela equação

$$X_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \varepsilon_t \quad (12)$$

Onde:

x_t corresponde à observação da série temporal no tempo t ;

φ_p corresponde ao parâmetro do modelo AR de ordem p ; e

ε_t representa o erro de eventos aleatórios que não podem ser explicados pelo modelo.

Um processo de Médias Móveis de ordem $q = MA(q)$ descreve um conjunto de dados como sendo resultado da combinação linear dos choques aleatórios que se comportam como ruído branco, ocorridos no período corrente e nos períodos passados. Pode ser descrita pela equação abaixo conforme Morettin e Toloi (2004),

$$X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (13)$$

Onde:

ε_t representa o erro de eventos aleatórios que não podem ser explicados pelo modelo; e

θ_q corresponde ao parâmetro do modelo MA de ordem q .

A combinação dos modelos AR e MA gera o modelo Autoregressivo e de Médias Móveis (ARMA) e pode ser descrito pela equação abaixo,

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (14)$$

Pela análise da equação descrita no modelo ARMA é possível verificar que o modelo relaciona os valores futuros com as observações passadas, assim como também com os erros passados apurados entre os valores reais e os previstos.

O filtro de Integração d consiste no número de diferenças necessárias para que o processo se torne estacionário. Um processo estacionário representa que as séries possuem média e variância constante no tempo e as autocovariâncias entre os valores da série não dependem do tempo, variando apenas em relação ao intervalo entre as duas observações consideradas. Se a série tiver sido diferenciada d vezes para tornar-se estacionária, o modelo formado por essa combinação é chamado de ARIMA (p,d,q). O número de diferenças, d , necessárias para que o processo se torne estacionário, é alcançado quando a Função de Autocorrelação Parcial – FAC amostral de $W_t = \Delta^d Z_t$ decresce rapidamente para zero. O coeficiente de correlação entre uma observação no período t e as observações em $t-1, t-2, \dots, t-k$ é representado por $P^* = \Delta P = (P_t - P_{t-1})$, onde P significa o preço.

O método ARIMA foi desenvolvido por Box e Jenkins (1976) e apresenta como proposta de análise encontrar um modelo que represente precisamente os padrões passados e futuros de séries temporais. O método de Box e Jenkins consiste na busca de um modelo ARIMA (*Auto Regressive Integrate Moving Average*) que represente o processo estocástico gerador da série temporal, a partir de um modelo ARMA aplicável na descrição de séries temporais

estacionárias, estendendo esse conceito para séries temporais não-estacionárias (NELSON, 1973).

Um processo ARIMA (p,d,q) pode ser representado pela equação:

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (15)$$

Sendo, $X_t = x_t - x_{t-d}$

Onde:

φ_p e θ_q são os parâmetros dos processos Autoregressivo e de Média Móvel de ordem p e q (ARMA(p,q));

ε_t corresponde ao erro de eventos aleatórios que não podem ser explicados pelo modelo; e

d equivale ao grau de homogeneidade não-estacionária.

Para o desenvolvimento e modelagem do processo de identificação do modelo ARIMA faz-se necessário realizar testes estatísticos para remover a estacionariedade da série bem como as Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP), descritas na figura 4.

Figura 4 - Etapa de identificação do Modelo ARIMA

Na descrição das etapas do processo para análise do modelo ARIMA tem-se a identificação. O objetivo da identificação é determinar os valores de p , d e q do modelo ARIMA (p,d,q) (WHEELWRIGHTH; MAKRIDAKIS, 1985). Inicialmente, a série temporal X_t é diferenciada para se obter uma série estacionária. Com isso, o processo fica reduzido a um modelo ARMA (p,q) . Em seguida, a ordem do processo ARMA é identificada pela análise dos coeficientes de autocorrelação (FAC) e autocorrelação parcial (FACP). Ainda nesta etapa são efetuadas estimativas preliminares dos parâmetros do modelo identificado. Para identificar o processo estocástico estacionário faz-se necessário testar estatisticamente por meio do teste de Dickey-Fuller, a série histórica em estudo.

A Função de Autocorrelação – FAC de ordem k mostra o coeficiente de correlação, representado por ρ_k entre uma observação no período t e as observações em $t-1, t-2, \dots, t-k$, sendo k um número inteiro maior ou igual a zero. A sequência de pares (k, ρ_k) representa a FAC. A FAC e FACP são utilizadas para verificar se o processo gerador de dados da série pode ser descrito por um processo AR, MA ou combinação de ambos.

A segunda etapa da modelagem ARIMA consiste em escolher os parâmetros do modelo que são descritos na figura 5.

Figura 5 - Etapa de Estimação do Modelo ARIMA

Após escolher os valores p, d, q devem ser estimados os p parâmetros autoregressivos (ϕ) e os q parâmetros de médias móveis (θ). A estimação tem por objetivo a obtenção de um conjunto de ϕ e θ que minimize a soma de quadrados dos erros.

A terceira e última etapa do modelo ARIMA consiste em realizar as previsões e acurácia do modelo e podem ser descritas na figura 6.

Figura 6 - Etapa Verificação e Previsão do Modelo ARIMA

A última etapa na construção do modelo ARIMA consiste na realização e verificação das previsões realizadas para a série y_t . Assim, após a estimativa do modelo, a verificação de sua habilidade em representar os fenômenos observáveis da série temporal é confirmada pela análise das medidas de erro agregado do modelo proposto. Caso a previsão mostre-se inadequada, o ciclo de identificação, estimação e verificação é novamente aplicado, até que a representação apropriada seja encontrada. Após a validação do modelo, a *previsão* dos valores futuros da série temporal modelada pode, enfim, ser obtida.

Para comparar o poder de predição dos modelos estimados usam-se medidas de erro agregado. Conforme Makridakis et al. (1982), a suposição básica de qualquer técnica de previsão de séries temporais é que o valor observado na série fica determinado por um padrão que se repete no tempo e por alguma influência aleatória. Isto significa dizer que mesmo quando o padrão exato que caracteriza o comportamento da série temporal tenha sido isolado, algum desvio ainda existirá entre os valores da previsão e os valores realmente observados. Essa aleatoriedade não pode ser prevista; entretanto, se isolada, sua magnitude pode ser estimada e usada para determinar a variação ou erro entre as observações e previsões realizadas.

A acuidade de um método de previsão pode ser mensurada por meio de muitas medidas de erro. Conforme Zhang, Patuwo e Hu (1998) os métodos quantitativos mais utilizados são a Soma dos Quadrados dos Erros (SSE), a Média das Diferenças Absoluta (MAD), o Erro Quadrático Médio (MSE), o Percentual de Erro Absoluto Médio (MAPE) e a Raiz do Erro Quadrático Médio (RMSE). Neste trabalho foi descartada a medida de erro agregado Percentual de Erro Absoluto Médio – MAPE por apresentar valores infinitos na análise dos dados da série temporal do preço do Boi Gordo.

As medidas de erro utilizadas neste trabalho foram: SSE, MAD, MSE e RMSE.

Soma dos Quadrados dos Erros:

$$SSE = \sum (\varepsilon_t)^2 \quad (16)$$

Média das Diferenças Absoluta:

$$MAD = \frac{\sum |\varepsilon_t|}{n} \quad (17)$$

Erro Quadrático Médio:

$$MSE = \frac{\sum (\varepsilon_t)^2}{n} \quad (18)$$

Percentual de Erro Absoluto Médio:

$$MAPE = \frac{1}{n} \sum \left| \frac{\varepsilon_t}{y_t} \right| \times 100 \quad (19)$$

Raiz do Erro Quadrático Médio: (RMSE)

$$RMSE = \sqrt{\sum \frac{(\varepsilon_t)^2}{n}} \quad (20)$$

A Raiz do Erro Quadrático Médio (RMSE), utilizada para a construção de uma matriz RMSE contribuiu para identificar os parâmetros p e q que melhor se ajustassem aos valores reais. Assim, procurou-se identificar a diferença entre os valores reais e os valores estimados do modelo. O propósito do ARIMA foi encontrar um modelo que representasse, precisamente, os padrões passados e futuros da série temporal de preços do Boi Gordo.

4.5 Medidas de Risco

Para medir o risco, considerado como a probabilidade de perdas, este trabalho utilizou-se de duas medidas:

1. Medida de Dispersão da área entre os valores reais e os valores previstos no modelo ARIMA;
2. Medida de Distribuição de Incertezas usando simulação de Monte Carlo.

Para a realização da análise de risco foi considerado o modelo ARIMA com menor erro de previsão. O modelo ARIMA (3,1,3) considerado o modelo que melhor se ajusta ao comportamento dos dados da série de preços do boi gordo foi utilizado para a simulação e quantificação do risco nos diferentes conjuntos de simulações.

Na primeira avaliação de risco o trabalho consistiu-se na Medida de Dispersão de Área que representou a medição do erro percentual (%) da área da diferença entre a curva real e a curva de previsão dividido pela área entre a curva real e o eixo x.

Utilizou-se o *Software Matlab*® para o modelo gerado para medir o erro percentual (risco%) da área entre os dados reais e os dados previstos no ARIMA (3,1,3), indicado na eq.(21), (22) e (23).

$$Area_{dif} = \int_{t_{ini}}^{t_{fim}} |P_r(t) - P_p(t)| dt \quad (21)$$

$$Area_{real} = \int_{t_{ini}}^{t_{fim}} P_r(t) dt \quad (22)$$

$$Risco \% = 100 * \frac{Area_{dif}}{Area_{real}} \quad (23)$$

Onde,

P_r = preço real

P_p = preço previsto

t_{ini} = período inicial

t_{fim} = período final

Na segunda avaliação utilizou-se o *Software Model Risk*®, de Vose (2008), a fim de explorar as correlações que impactam com maior frequência no preço de venda da arroba do boi gordo no mercado futuro de commodity.

Vose (2008) utiliza uma abordagem para a avaliação quantitativa de risco, conhecida como *Quantitative Risk Assessment* – QRA, que permite calcular o impacto combinado da incerteza nos parâmetros de um modelo a fim de determinar uma distribuição de incertezas do resultado possível do modelo.

O *Software Model Risk*[®] utiliza simulação de Monte Carlo para gerar cenários possíveis. Nesta simulação sabem-se cada valor possível que uma variável pode assumir e a probabilidade de ocorrência deste cenário. Assim, identificar o risco nestes cenários significa utilizar-se de instrumentos para o gerenciamento do risco de forma a atenuá-los.

As distribuições de probabilidades foram construídas de duas formas: a primeira construção avaliou a probabilidade de variação entre os preços reais e os preços previstos no intervalo de tempo analisado em cada simulação (90:10, 80:20, 70:30 e 60:40); a segunda construção avaliou a probabilidade ocorrência entre o preço real e o preço previsto com os valores do ARIMA (3,1,3) considerado o modelo que melhor se ajusta aos dados reais da série de preços do Boi Gordo.

4.6 Redes Neurais Artificiais

Dada a hipótese de evidências de não-linearidade dos preços da arroba do boi gordo, o uso de redes neurais artificiais – RNA propõe uma melhoria adicional para o modelo de previsão utilizado neste trabalho.

Costa (2000) desenvolveu a Arquitetura de uma Rede Neural Auto Regressiva Integrada de Média Móvel, conforme demonstrada na figura 7, considerando parâmetros lineares e não lineares na série de dados analisadas.

A arquitetura da rede neural autoregressiva integrada de média móvel desenvolvida na figura 7 foi composta por um modelo que introduz uma etapa integradora que transforma um sinal não estacionário em um sinal estacionário na camada de entrada da rede neural. Foi usada a rede neural artificial denominada *Multilayer Perceptrons* – MLP que consiste em uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. A

decisão pela rede MLP deve-se à sua capacidade de resolver problemas não lineares por meio do algoritmo de *backpropagation* que consiste na retropropagação do erro nas camadas de *perceptrons*. O algoritmo de retropropagação, conforme Costa (2000) consiste em dois passos: o “passo para frente” ou “*forward-step*” e o “passo para trás” ou “*backward-step*”.

No “*forward-step*” um padrão de entrada é apresentado à camada de entrada da rede e seu efeito é propagado camada por camada, até que atinja a última camada onde a saída da rede é calculada. Durante esta fase, os parâmetros da rede são fixos, diferentemente do que ocorre no “*backward-step*”, onde os pesos e demais parâmetros da rede são ajustados de acordo com uma regra baseada no erro cometido pela rede, medindo a diferença entre a saída da rede e o valor desejado – o “*target*” (COSTA, 2000, p.61).

Este algoritmo de aprendizagem ficou conhecido como algoritmo de “*backpropagation*” que faz o mapeamento entre a entrada e saída, minimizando uma “função de custo” definida a partir do erro associado à saída calculada e à saída desejada.

Para a análise do modelo de previsão de preços do boi gordo, avaliadas neste trabalho, foi utilizada a rede multicamadas recursiva para implementar o estimador de parâmetros lineares e não lineares dos modelos ARMA e ARIMA. Pode-se obter ainda, parâmetros lineares e não lineares usando a metodologia de Chon e Cohen (1997) por meio de funções polinomiais para representar a função de ativação dos neurônios na camada escondida. Os coeficientes NARMA podem ser obtidos desde que a rede seja devidamente treinada.

Figura 7 - Arquitetura da Rede Neural Auto Regressiva Integrada de Média Móvel

Fonte: Costa (2000), p.66

5 RESULTADOS E DISCUSSÃO

Este capítulo tem como objetivo apresentar a aplicabilidade dos modelos econométricos de previsão utilizando-se da metodologia de séries temporais, os resultados e as discussões obtidas com a aplicação do ARIMA (Modelo Autoregressivo Integrado de Médias Móveis), as medidas de dispersão de risco e o treinamento e implantação da Rede Neural Artificial para a série de preços do Boi Gordo.

5.1 Resultados e Discussão da Pesquisa - ARIMA

O método ARIMA, em sentido amplo, supõe que os valores futuros de uma variável possam ser combinações lineares de seus valores e erros passados (ZOU et al., 2007), o que contraria os modelos de regressão em que uma variável é explicada a partir de seus regressores. De acordo com Juntilla (2001), o grande mérito do modelo ARIMA foi reunir as técnicas até então existentes na literatura para construir modelos que descrevessem com precisão e de forma parcimoniosa o processo gerador da série temporal, proporcionando desta forma previsões mais acuradas quanto aos valores futuros.

5.1.1 A Série Temporal do BOI GORDO

Foi utilizada a série de preços do Boi Gordo obtida na Bolsa de Mercadorias & Futuros (BM&F), hoje BMF&F/BOVESPA que representa o indicador de preço do Boi Gordo ESALQ/BM&F e que serve como referencial para as negociações de compra e venda de contratos futuros. Os preços avaliados nesta análise representam o preço da carne bovina que é determinado por vários fatores que vão desde os relacionados à produção como clima e preço dos insumos até os relacionados à fase do consumo como o preço de produtos concorrentes e variáveis macroeconômicas como a inflação, taxa de juros, câmbio e PIB, que afetam diretamente a demanda do produto.

A série temporal referente ao preço do boi gordo utilizada neste trabalho foi diária, compreendendo o período de 23 de julho de 1997 a 18 de fevereiro de 2013, isto é, um total de $n = 3870$ observações, ilustrada na figura 8.

Os valores foram obtidos no Centro de Estudos Avançados em Economia Aplicada (CEPEA), que é parte integrante do Departamento de Economia, Administração e Sociologia da Escola Superior de Agricultura Luiz de Queiroz, unidade da Universidade de São Paulo.

Figura 8 - Série de preço à vista do Boi Gordo (Série Original)

Fonte: Dados de preços obtidos no CEPEA/USP/SP, disponível em <http://www.cepea.esalq.usp.br>, acesso em 06/06/2013.

Para a caracterização da série temporal algumas restrições devem ser impostas a fim de se obter um modelo com capacidade de captar as reais características dos dados e explicá-los. Estas restrições referem-se à transformação do processo estocástico não estacionário em um processo estocástico estacionário.

Com o objetivo de verificar a estacionariedade da série temporal, foi utilizado o teste de raiz unitária, com o auxílio da estatística Tau (τ) e dos valores críticos de Dickey-Fuller para os dados de preços do boi gordo.

Como resultado, ilustrado na tabela 5, identificou-se que a série temporal original não é estacionária, ou seja, não apresenta média e variância constantes. Assim, conforme indicado por Gujarati (2000), foi empregado o processo de diferenciação a fim de obter-se uma série estacionária, ilustrado na figura 9.

Tabela 5 - Teste de Raiz Unitária de Dickey-Fuller

n = 3870 (>500)		$\alpha = 5\%$		Valor Crítico = -1,9616	
Série original	Estatística $\tau = 3,3091$	$p = 0,999$	$H = 0$	Série não estacionária	
Série diferenciada	Estatística $\tau = -40,6090$	$p = 0,001$	$H = 1$	Série estacionária	

Com a primeira diferença obtida, a série apresentou-se estacionária visto que o valor obtido para τ foi de -40,6090, enquanto que considerando Dickey-Fuller, o valor crítico a 5% de significância é de -1,9616 para acima de 500 observações (Anexo 1).

O número de diferenças, d , necessárias para que o processo se torne estacionário, é alcançado quando a Função de Autocorrelação Parcial – FACP amostral de $W_t = \Delta^d Z_t$ decresce rapidamente para zero. Na figura 9 foi aplicado $d = 1$, ou seja, a série original foi diferenciada uma vez. Isto representa o coeficiente de correlação entre uma observação no período t e as observações em $t-1$, $t-2$, ... $t-k$, então, $P^* = \Delta P = (P_t - P_{t-1})$. A figura 9 representa a diferenciação de ordem 1 do preço à vista do boi gordo na série original.

Figura 9 - Série de preço do Boi Gordo diferenciada

A importância do processo de análise de séries históricas ser estacionária é a possibilidade de fixar parâmetros do modelo válidos para realizar a previsão do futuro a partir do passado. Assim, testar as hipóteses nula (H_0) e alternativa (H_1) é necessário quanto à significância estatística. Sendo, H_0 uma série não estacionária ($H_0: H \neq 0$) e H_1 uma série estacionária ($H_1: H = 0$), o p representa a probabilidade de rejeitar a hipótese nula quando ela é verdadeira (erro tipo I). Quando $H = 0$ indica aceitação da hipótese nula e quando $H = 1$ indica rejeitar a hipótese nula.

Com base em um teste de significância, o teste t indica a aceitação da hipótese nula H_0 , ou seja, os dados da série histórica apresentam não estacionariedade, justificando assim, a aplicação do processo de diferenciação a fim de torná-la estacionária.

Visando à identificação da série estacionária, foram elaborados os correlogramas de Função de Autocorrelação – FAC, representado pela figura 10 e, Função de Autocorrelação Parcial – FACP, representado pela figura 11, para a série temporal diferenciada de ordem 1.

As figuras 10 e 11 representam os valores das autocorrelações significativas decaindo rápido para valores próximos de zero, também conhecida como decaimento exponencial sem oscilações, utilizando-se a FAC e FACP.

Figura 10 - Série de preço do Boi Gordo - Função de Autocorrelação

Figura 11 - Série de preço do Boi Gordo - Função de Autocorrelação Parcial

O estudo dos correlogramas – FAC e FACP, indicados pelas figuras 10 e 11, ajuda a identificar a existência de autocorrelação na série histórica, além de indicar até qual defasagem esta correlação é significativa. Na análise da figura 10 nota-se que existe correlação significativa

até a 9 (nona) defasagem e, na figura 11 a correlação é significativa até a 4 (quarta) defasagem. Estes aspectos, observados nos correlogramas mostram a direção para a construção do modelo ARIMA, ou seja, existe na série avaliada a presença de termos autorregressivos (AR) e termos de médias móveis (MA). E, esta indicação representa que o modelo ARIMA pode utilizar como parâmetros de p e q até o nível de significância entre eles. Portanto, pela análise dos correlogramas poderia iniciar os testes de modelagem com ARIMA (9,1,4).

Uma vez utilizado o procedimento de diferenciação para obter uma série temporal estacionária foram modelados os valores referentes ao preço do boi gordo, ou seja, foi estimado o modelo ARIMA que melhor represente os dados coletados. Não há consenso na literatura quanto à quantidade de elementos que deverão ser utilizados para treinamento da série temporal. A maioria dos autores considera conveniente dividir a série *in-and-out-of-sample* em 70:30%, 80:20% ou 90:10% (ZOU et al., 2007). Neste trabalho utilizaram-se quatro simulações para treinamento e teste da série temporal, 90:10%, 80:20%, 70:30% e 60:40%.

5.1.2 Simulação e Análise com 90% da série histórica para treinamento

A acuidade de um método de previsão pode ser mensurada por meio de muitas medidas de erro. Foram utilizadas medidas de erro agregado em previsões. Os métodos quantitativos mais utilizados para a realização destas avaliações, conforme Zhang, Patuwo e Hu (1998), são a Soma dos Quadrados dos Erros (SSE), a Média das Diferenças Absoluta (MAD), o Erro Quadrático Médio (MSE), o Percentual de Erro Absoluto Médio (MAPE) e a Raiz do Erro Quadrático Médio (RMSE).

Neste trabalho foi descartada a medida de erro agregado MAPE – Percentual de Erro Absoluto Médio por apresentar valores infinitos na análise dos dados da série temporal do preço do Boi Gordo.

Tais medidas de erro são utilizadas para avaliar e comparar o desempenho das previsões. Visam ainda, identificar a diferença entre os valores reais e os estimados. O modelo com os

menores valores para SSE, MSE, MAD e RMSE é considerado o melhor quando comparado um com o outro.

Foi construída uma matriz de RMSE - Raiz do Erro Quadrático Médio, ilustrada na figura 12, a fim de contribuir na determinação dos parâmetros p e q do modelo ARIMA.

Na análise da figura 12, a matriz de RMSE indica que os melhores parâmetros para p e q na modelagem ARIMA é ARIMA (1,1,1) e ARIMA (3,1,3), também representados na tabela 6 por meio dos indicadores de erro agregado. Os parâmetros estabelecidos para ARIMA (1,1,1) significam que a análise da série temporal de preços do boi gordo apresenta 01 (um) termo autoregressivo (ou, um filtro autoregressivo com uma defasagem), a série foi diferenciada 01 (uma) vez para torná-la estacionária e, 01 (um) termo de médias móveis (ou, um processo de média móvel com uma defasagem em seu processo gerador de dados). Os parâmetros estabelecidos para ARIMA (3,1,3) significam que a análise da série temporal de preços do boi gordo apresenta 3 (três) termos autoregressivos, a série foi diferenciada 01 (uma) vez e, 03 (três) termos de médias móveis.

Figura 12 - Matriz RMSE para simulação (90:10)

Tabela 6 - Medida de Erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)

Cenário 80/20	ARIMA (1,1,1)	ARIMA (3,1,3)
RMSE	0,508	0,5062
MSE	0,258	0,2562
MAD	0,3557	0,3556
SSE	199,4557	198,0778

Fonte: elaborado pela autora.

Assim, conforme a tabela 6, considerando que a melhor modelagem é a que apresenta menores valores nas medidas de erro, a modelagem ARIMA (3,1,3) apresenta-se como melhor representação do comportamento dos preços na série analisada. Porém, o melhor modelo ou representação de séries históricas é aquele que utiliza a menor quantidade de termos para sua análise e previsão. Desta forma, o modelo ARIMA (3,1,3) para uma simulação com 90% da série analisada é o mais indicado para realizar as previsões dos 10% restantes da série, pois minimiza o RMSE, conforme ilustrado na tabela 7.

Tabela 7 - Modelo ARIMA - Comparação com resultados estatísticos

ARIMA	Termos	RMSE
Cenário 90/10		
ARIMA (1,1,1)	2	0,4269
ARIMA (2,1,2)	4	0,4248
ARIMA (3,1,3)	6	0,4244

A última fase do processo de modelagem ARIMA consiste na previsão propriamente dita. Considerando assim, na simulação com 90% da série, foi realizada a previsão de preços do boi gordo, conforme ilustrado na figura 13.

A figura 13 representa o confronto dos valores reais e dos valores previstos para 10% da série histórica em análise, utilizando a modelagem ARIMA. Os 10% da série histórica em análise compreende o período de 27 de Julho de 2011 a 18 de Fevereiro de 2013, representados no eixo x. Os preços do boi gordo no mesmo período são representados no eixo y. A linha vermelha representa o comportamento dos preços reais no período analisado. Foram projetadas três modelagens para o ARIMA, sendo, na linha verde o modelo

ARIMA (1,1,1); na linha azul o modelo ARIMA (2,1,2) e, na linha preta o modelo ARIMA (3,1,3).

Figura 13 - Modelo de previsão de preços (de R\$ 85,00 a R\$ 110,00) do boi gordo para simulação 90:10

Na análise da figura 13 foi possível identificar o tipo de modelo adequado para os dados utilizando a modelagem ARIMA. O modelo mais ajustado aos dados foi o ARIMA (3,1,3) porém, ressalta-se que este modelo utiliza 6 (seis) termos para a modelagem dos dados, o que contraria a lógica de que o melhor modelo é aquele que utiliza a menor quantidade de termos ajustados aos dados reais da série histórica. Percebe-se ainda que, os três modelos ARIMA avaliados conseguem representar a tendência dos dados históricos da série de preços do boi gordo.

Considerando as simulações realizadas com mesma escala para os dados da série histórica do boi gordo, a figura 14 apresenta a modelagem com ARIMA (3,1,3) mais ajustada aos dados reais em análise.

Figura 14 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 90:10

Assim, a modelagem dos dados da série de preços do boi gordo que melhor representa o comportamento dos preços é dada pela equação abaixo:

$$\begin{aligned}
 ARIMA(3,1,3) = & -0,7237x_{n-1} - 0,847x_{n-2} + 0,6704x_{n-3} \\
 & -0,2778\varepsilon_{n-1} - 0,7669\varepsilon_{n-2} + 0,3157\varepsilon_{n-3} + 1\varepsilon_n
 \end{aligned} \quad (22)$$

5.1.3 Simulação e Análise com 80% da série histórica para treinamento

Considerando o mesmo raciocínio e técnicas de modelagem utilizadas para o treinamento da série de preços do boi gordo, avaliadas anteriormente, foi elaborado a previsão com a modelagem ARIMA para as simulações que compreendem 80% de dados reais da amostra e 20% para realizar a previsão.

A fim de contribuir na determinação dos parâmetros p e q do modelo ARIMA foi construída uma matriz de RMSE - Raiz do Erro Quadrático Médio, ilustrada na figura 15 para 80% dos dados reais da série de preços do boi gordo.

Na análise da figura 15, a matriz de RMSE indica que os melhores parâmetros para p e q no modelo ARIMA é ARIMA (2,1,2) e ARIMA (3,1,3). Os parâmetros estabelecidos para ARIMA (2,1,2) significam que a análise da série temporal de preços do boi gordo apresenta 02 (dois) termos autoregressivos, a série foi diferenciada 01 (uma) vez para torná-la estacionária e, 02 (dois) termos de médias móveis. Os parâmetros estabelecidos para ARIMA (3,1,3) significam que a análise da série temporal de preços do boi gordo apresenta 3 (três) termos autoregressivos, a série foi diferenciada 01 (uma) vez e, 03 (três) termos de médias móveis.

Figura 15 - Matriz RMSE para simulação (80:20)

Na tabela 8 foram avaliadas as medidas de erro agregado para a modelagem ARIMA (1,1,1) e ARIMA (3,1,3). Os resultados estatísticos demonstram que o modelo ARIMA (3,1,3) é considerado o modelo que melhor se ajusta aos dados reais da série de preços do Boi Gordo. Porém, como se pode observar na tabela 9 o modelo ARIMA (3,1,3) considera o uso de seis termos composto por termos autoregressivos e termos de médias móveis.

Tabela 8 - Medida de erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)

Cenário 80/20	ARIMA (1,1,1)	ARIMA (3,1,3)
RMSE	0,508	0,5062
MSE	0,258	0,2562
MAD	0,3557	0,3556
SSE	199,4557	198,0778

Tabela 9 - Modelo ARIMA - comparação com resultados estatísticos

ARIMA	termos	RMSE
Cenário 80/20		
ARIMA (1,1,1)	2	0,5080
ARIMA (2,1,2)	4	0,5063
ARIMA (3,1,3)	6	0,5062

A última fase do processo de modelagem ARIMA consiste na previsão considerando as simulações 80:20. Foi realizada a previsão de preços do boi gordo, conforme ilustrado na figura 16.

Figura 16 - Modelo de previsão de preços (de R\$ 70,00 a R\$ 115,00) do boi gordo para simulação 80:20

Considerando as simulações realizadas com mesma escala para os dados da série histórica do boi gordo, a figura 17 apresenta a modelagem com ARIMA (3,1,3) mais ajustada aos dados reais em análise.

Figura 17 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 80:20

5.1.4 Simulação e Análise com 70% da série histórica para treinamento

A fim de contribuir na determinação dos parâmetros p e q do modelo ARIMA foi construída uma matriz de RMSE - Raiz do Erro Quadrático Médio, ilustrada na figura 18 para 70% dos dados reais da série de preços do boi gordo.

Na análise da figura 18 a matriz de RMSE indica que os melhores parâmetros para p e q no modelo ARIMA é ARIMA (1,1,1) e ARIMA (2,1,2). Os parâmetros estabelecidos para ARIMA (1,1,1) significam que a análise da série temporal de preços do boi gordo apresenta 01 (um) termo autoregressivo, a série foi diferenciada 01 (uma) vez para torná-la estacionária e, 01 (um) termo de médias móveis. Os parâmetros estabelecidos para ARIMA (2,1,2) significam que a análise da série temporal de preços do boi gordo apresenta 2 (dois) termos autoregressivos, a série foi diferenciada 01 (uma) vez e, 02 (dois) termos de médias móveis.

Figura 18 - Matriz RMSE para simulação (70:30)

Nas tabelas 10 e 11 as medidas de erro agregado foram aplicadas a fim de contribuir para a análise estatística e a avaliação do desempenho da previsão. Para a avaliação da simulação 70:30 nota-se que a modelagem ARIMA (1,1,1) responde aos menores erros agregados indicando que no período analisado existe a possibilidade de usar uma quantidade de dados menor para a previsão de preços do boi gordo.

Tabela 10 - Medida de erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)

Cenário 70/30	ARIMA (1,1,1)	ARIMA (3,1,3)
RMSE	0,466	0,4776
MSE	0,2171	0,2281
MAD	0,3253	0,3399
SSE	251,888	264,5888

Tabela 11 - Modelo ARIMA - comparações com resultados estatísticos

ARIMA	termos	RMSE
Cenário 70/30		
ARIMA (1,1,1)	2	0,4660
ARIMA (2,1,2)	4	0,4647
ARIMA (3,1,3)	6	0,4776

A última fase do processo de modelagem ARIMA consiste na previsão considerando as simulações 70:30. Foi realizada a previsão de preços do boi gordo, conforme ilustrado na figura 19.

Figura 19 - Modelo de previsão de preços (de R\$ 70,00 a R\$ 115,00) do boi gordo para simulação 70:30

Considerando as simulações realizadas com mesma escala para os dados da série histórica do boi gordo, a figura 20 apresenta a modelagem com ARIMA (3,1,3), (2,1,2) e (1,1,1) ajustadas aos dados reais em análise, indicando que as três modelagens propostas para esta simulação respondem à previsão realizada.

Figura 20 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 70:30

5.1.5 Simulação e Análise com 60% da série histórica para treinamento

A fim de contribuir na determinação dos parâmetros p e q do modelo ARIMA foi construída uma matriz de RMSE - Raiz do Erro Quadrático Médio, ilustrada na figura 21 para 70% dos dados reais da série de preços do boi gordo.

Na análise da figura 21, a matriz de RMSE indica que os melhores parâmetros para p e q no modelo ARIMA é ARIMA (1,1,1) e ARIMA (2,1,2). Os parâmetros estabelecidos para ARIMA (1,1,1) significam que a análise da série temporal de preços do boi gordo apresenta 01 (um) termo autoregressivo, a série foi diferenciada 01 (uma) vez para torná-la estacionária e, 01 (um) termo de médias móveis. Os parâmetros estabelecidos para ARIMA (2,1,2) significam que a análise da série temporal de preços do boi gordo apresenta 2 (dois) termos autoregressivos, a série foi diferenciada 01 (uma) vez e, 02 (dois) termos de médias móveis.

Figura 21 - Matriz RMSE para simulação (60:40)

Nas tabelas 12 e 13 as medidas de erro agregado foram aplicadas a fim de contribuir para a análise estatística e a avaliação do desempenho da previsão. Para a avaliação da simulação 60:40 nota-se que a modelagem ARIMA (3,1,3) responde aos menores erros agregados indicando que no período analisado existe a possibilidade de usar uma quantidade de dados menor para a previsão de preços do boi gordo.

Tabela 12 – Medida de erro agregado para ARIMA (1,1,1) e ARIMA (3,1,3)

Cenário 60/40	ARIMA (1,1,1)	ARIMA (3,1,3)
RMSE	0,4117	0,41
MSE	0,1695	0,1681
MAD	0,2731	0,2725
SSE	262,1502	260,0267

Tabela 13 - Modelo ARIMA (1,1,1); ARIMA (3,1,3) resultados estatísticos

ARIMA	termos	RMSE
Cenário 60/40		
ARIMA (1,1,1)	2	0,4117
ARIMA (2,1,2)	4	0,4097
ARIMA (3,1,3)	6	0,4100

A última fase do processo de modelagem ARIMA consiste na previsão considerando as simulações 60:40. Foi realizada a previsão de preços do boi gordo, conforme ilustrado na figura 22.

Figura 22 - Modelo de previsão de preços (de R\$ 50,00 a R\$ 120,00) do boi gordo para simulação 60:40

5.1.6 Algumas Considerações

Dentre os cenários avaliados para a realização da predição de preços do boi gordo a modelagem ARIMA (2,1,2) com 60% dos dados reais em treinamento foi o modelo que apresentou o menor erro de previsão medido pelo RMSE. Porém, nota-se que a modelagem que mais se ajustou os dados passados para predição de preços futuros foi a predição com simulação 90:10 que utilizou 90% da série histórica para treinamento e 10% para validação.

Em Araújo et al. (2012) o modelo ARIMA e SARIMA que mais se ajustaram aos dados de preços do boi gordo para um período avaliado de cinco anos foi ARIMA (10,1,0) e SARIMA (12,2,12)(0,1,1). Em Medeiros (2006) o modelo SARIMA (1,1,0)(2,0,1) na previsão de preço

da arroba do boi gordo explicou 95,72% da variação dos preços apresentando ainda um RMSE de 0,015622 para um período de análise de sete anos. Em Padilha Jr. et al (2013) o modelo ARIMA que melhor se ajustou aos indicadores de preço do boi gordo para o Estado do Paraná foi ARIMA (0,1,36) com previsão para 7 dias onde a diferença entre os valores reais observados e os valores estimados pelo modelo resultaram numa diferença média de 1,4%.

Na evolução dos trabalhos realizados para a previsão de preços do boi gordo destaca-se o uso de modelos de análise de série temporais como uma das formas de minimizar o risco, detectando assim o comportamento dos preços da arroba do boi gordo no momento da comercialização do produto. Nota-se que as técnicas de modelagem por meio do ARIMA apresentam-se como instrumento de gerenciamento para lidar com os riscos e atenuá-los.

Porém, algumas limitações devem ser impostas. As previsões de preços baseada em séries temporais pressupõe que os mesmos padrões dos dados analisados irão ocorrer no futuro. Mesmo que os valores previstos se ajustem estatisticamente de forma satisfatória aos padrões passados, não há garantia nenhuma de que estes padrões irão se repetir no futuro. Tomek (1997) faz uma análise crítica do papel dos preços futuros como sinalizadores dos preços no mercado físico. Apresenta como crítica que, em geral, os resultados obtidos em modelos quantitativos (econométricos e de séries temporais) podem refletir um amplo conjunto de informações, porém fornecem previsões pouco acuradas dos preços no mercado físico.

As críticas ao uso de modelagem de dados passados para previsões contribuem para o aperfeiçoamento e desenvolvimento de novas técnicas como o uso de redes neurais artificiais para a predição de preços. Bressan e Lima (2002) avaliam que a previsão de preços é uma importante ferramenta no planejamento, avaliação de políticas e minimização dos riscos na tomada de decisão dos produtores, compradores e investidores do agronegócio. Assim, a aplicabilidade de modelos de previsão de séries temporais em negociações de contratos futuros de boi gordo ou de qualquer outra *commodity* se mostra eficaz na identificação de tendências de preço em negociações num horizonte até mesmo de curto prazo.

Dos resultados desta pesquisa pode-se avaliar que, a partir da utilização da modelagem ARIMA há uma sinalização de possíveis tendências na evolução dos preços do boi gordo. Isto reforça a aplicabilidade dos modelos estatísticos e seu desempenho preditivo como potencial ferramenta no processo de tomada de decisão.

Com o objetivo ainda de avaliar o risco associado às decisões baseadas nos modelos econométricos, este trabalho desenvolve no próximo tópico, uma medida de risco a partir do modelo ARIMA que melhor se ajusta aos dados reais de preços do boi gordo e apresenta menor erro de predição.

5.2 Resultados e Discussão da Pesquisa - RISCO

Para a realização da análise de risco foi considerado o modelo ARIMA com menor erro de previsão. O modelo ARIMA (3,1,3) considerado o modelo que melhor se ajustou ao comportamento dos dados da série de preços do boi gordo foi utilizado para a simulação e quantificação do risco nos diferentes conjuntos de simulações.

Com o uso do *Software Matlab*® a primeira avaliação de risco consistiu na medição do erro percentual (%) da área da diferença entre a curva real e a curva de previsão dividido pela área entre a curva real e o eixo x.

Com o uso do *Software Model Risk*® a segunda avaliação de risco consistiu na distribuição de probabilidades considerando o método Monte Carlo entre os dados reais e os dados previstos no ARIMA (3,1,3).

Este tópico apresenta os resultados da avaliação de risco para as simulações com 90:10, 80:20, 70:30 e 60:40, respectivamente, da série em análise.

5.2.1 Análise de Risco com 90% da série para Treinamento

As figuras 23 e 24 apresentam o erro % (chamado neste trabalho de risco %) que foi medido utilizando-se os dados históricos da série de preços do boi gordo e a modelagem ARIMA

(3,1,3) que apresentou o menor erro de previsão. Os gráficos apresentam no eixo x o período, em dias, para a previsão com 90% da série em treinamento e 10% da série para validação. A figura 23 foi separada em períodos de 30 em 30 dias dentro dos 10% da série de dados utilizada para previsão, que compreendeu o período de 27/07/2011 a 18/02/2013. Os preços da série histórica do boi gordo são valores diários e somente dias úteis. A figura 24 foi separada em intervalos de tempo menores, períodos de 5 em 5 dias. Ao analisar em qual período ocorreu maior ou menor erro, ou seja, o risco do preço variar dentro do intervalo analisado foi detectado que houve um distanciamento nos meses de Julho e Agosto de 2012 representando um erro percentual, de aproximadamente, 4% entre o real e o previsto.

O distanciamento, de aproximadamente 4%, representa o espaço medido entre os valores reais e os valores previstos para a série de preços do boi gordo com o ARIMA (3,1,3). Nota-se que a modelagem ARIMA mostra-se eficiente na produção de informações relevantes ao processo decisório na predição de preço futuro. O foco em medir o risco em conjunto com a modelagem ARIMA representa a possibilidade de avaliar o impacto de variáveis “não esperadas” que afetam diretamente o preço de negociação da arroba do boi gordo.

Figura 23 - Análise de Risco para Simulação 90:10 para períodos de 30 dias úteis

Figura 24 - Análise de Risco para Simulação 90:10 para períodos de 5 dias úteis

Para avaliar o comportamento de preços a fim de determinar uma distribuição de incertezas do resultado possível entre o preço real e o preço previsto na simulação de preços para a previsão com 90% da série em treinamento e 10% da série para validação, utilizou-se o *Software Model Risk® Standard Version 4.3.0.5*. E, subsequentemente, o mesmo procedimento para as simulações com 80:20, 70:30 e 60:40. Utilizou-se uma distribuição triangular em que o intervalo mínimo e máximo e o valor mais provável dentro do intervalo, a média, podem ser estimados. O processo se dá por meio de simulações usando o Método Monte Carlo com 10.000 iterações.

As figuras 25, 26 e 27 apresentam os resultados da distribuição de probabilidades para a simulação com 90% da série em treinamento e 10% da série para validação. Considerou-se ainda os valores previstos com a modelagem ARIMA (3,1,3) que apresentou o menor erro de predição.

A figura 25 apresenta, no eixo X, os valores referentes às diferenças entre o preço real e os preços previstos na modelagem ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência

do modelo previsto. As distribuições mostradas por barras representam as distribuições variando entre R\$ -15,00 a R\$12,00. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e considerando o intervalo entre R\$ -6,00 e R\$ 6,00, a probabilidade representa 80,25% de certeza quando comparados com os dados reais. Isto significa que existem 80,25% de chance do preço da arroba do boi gordo se comportar conforme previsto na modelagem ARIMA (3,1,3).

Figura 25 - Análise de Risco para Simulação 90:10 com variação entre o preço real e o preço previsto

As figuras 26 e 27 representam, no eixo X, o comportamento mínimo, médio e máximo dos preços reais e previstos na modelagem 90:10 com o ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência do modelo proposto. As distribuições mostradas por barras representam as distribuições reais e previstas no modelo de preços do boi gordo. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e os intervalos são representações da comparação com os dados reais. Na figura 26 a sobreposição entre os preços reais e os preços previstos valida o modelo com 84,84% de probabilidade de que os preços se comportem como previstos. A figura 27, visualizado em

forma de linha para os preços reais e com novas iterações, o modelo valida 84,60%, o que indica a eficácia do modelo de previsão.

Figura 26 - Análise de Risco para Simulação 90:10 com sobreposição dos preços real e previsto (a)

Figura 27 - Análise de Risco para Simulação 90:10 com sobreposição dos preços real e previsto (b)

5.2.2 Análise de Risco com 80% da série para Treinamento

Nas figuras 28 e 29 o risco percentual (%) foi medido para a simulação com 80% da série histórica para treinamento e 20% para a validação do modelo. As previsões geradas para a análise de 20% da série foram modeladas pelo ARIMA (3,1,3). A figura 28 foi separada em períodos de 30 em 30 dias dentro dos 20% da série de dados utilizada para previsão, que compreendeu o período de 08/01/2010 a 18/02/2013. Os preços da série histórica do boi gordo são valores diários e somente dias úteis. A figura 29 foi separada em intervalos de tempo menores, períodos de 5 em 5 dias. Ao analisar um período maior para previsão ocorreu maior erro, ou seja, o risco do preço variar dentro do intervalo analisado foi detectado o que representou um erro percentual, de aproximadamente, 11% entre o real e o previsto.

Figura 28 - Análise de Risco para Simulação 80:20 para períodos de 30 dias úteis

Figura 29 - Análise de Risco para Simulação 80:20 para períodos de 5 dias úteis

O distanciamento, de aproximadamente 11%, representa o espaço medido entre os valores reais e os valores previstos para a série de preços do boi gordo com o ARIMA (3,1,3). Nota-se que a modelagem ARIMA mostra-se eficiente na produção de informações relevantes ao processo decisório na predição de preço futuro, porém a avaliação realizada demonstra que o aumento do tempo para predição, aumenta o risco de flutuações e/ou variações no preço. O foco em medir o risco em conjunto com a modelagem ARIMA representa a possibilidade de amenizar o impacto de variáveis “não esperadas” que afetam diretamente o preço de negociação da arroba do boi gordo.

Os resultados para esta simulação com 80% da série reforçam o fundamento de que uma previsão representa melhor o comportamento dos dados passados quando se utiliza de maior quantidade de dados para a análise.

As figuras 30, 31 e 32 apresentam os resultados da distribuição de probabilidades para a simulação com 80% da série em treinamento e 20% da série para validação, utilizando-se o

Software Model Risk®. Considerou-se ainda os valores previstos com a modelagem ARIMA (3,1,3) que apresentou o menor erro de predição.

A figura 30 representa, no eixo X, os valores referentes às diferenças entre o preço real e os preços previstos na modelagem ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência do modelo previsto. As distribuições mostradas por barras representam as distribuições variando entre R\$ -24,00 a R\$ 36,00. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e considerando o intervalo entre R\$ -6,00 e R\$ 6,00, a probabilidade representa 37,30% de certeza de variação entre estes valores quando comparados com os dados reais. Isto significa que a chance do preço da arroba do boi gordo se comportar conforme previsto na modelagem ARIMA (3,1,3) para a simulação 80:20 é representada por um intervalo maior de preços.

Figura 30 - Análise de Risco para Simulação 80:20 com variação entre o preço real e o preço previsto (a)

Ao avaliar a necessidade de analisar um intervalo maior de preços para este cenário, a figura 31 apresenta uma probabilidade de 76,61% dos preços ficarem entre R\$ -6,00 e R\$ 18,00.

Nota-se um distanciamento maior em relação à simulação 90:10, o que indica que para um período menor de decisão, ou seja, para o curto prazo este cenário não responde à uma otimização de preços da arroba do boi gordo.

Figura 31 - Análise de Risco para Simulação 80:20 com variação entre o preço real e o preço previsto (b)

As figuras 32 e 33 representam, no eixo X, o comportamento mínimo, médio e máximo dos preços reais e previstos na modelagem 80:20 com o ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência do modelo proposto. As distribuições mostradas por barras representam as distribuições reais e previstas no modelo de preços do boi gordo. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e os intervalos são representações da comparação com os dados reais. Na figura 32 a sobreposição entre os preços reais e os preços previstos valida o modelo com 83,59% de probabilidade de que os preços se comportem como previstos. A figura 33, visualizado em forma de linha para os preços reais e com novas iterações, o modelo continua validando 83,59%, o que indica a eficácia do modelo de previsão.

Figura 32 - Análise de Risco para Simulação 80:20 com sobreposição de preços real e previsto (a)

Figura 33 - Análise de Risco para Simulação 80:20 com sobreposição de preços real e previsto (b)

5.2.3 Análise de Risco com 70% da série para Treinamento

Nas figuras 34 e 35 o risco percentual (%) foi medido para a simulação com 70% da série histórica para treinamento e 30% para a validação do modelo. As previsões geradas para a análise de 30% da série foram modeladas pelo ARIMA (3,1,3). A figura 34 foi separada em períodos de 30 em 30 dias dentro dos 30% da série de dados utilizada para previsão, que compreendeu o período de 18/06/2008 a 18/02/2013. Os preços da série histórica do boi gordo são valores diários e somente dias úteis. A figura 35 foi separada em intervalos de tempo menores, períodos de 5 em 5 dias. Ao analisar um período maior para previsão ocorreu menor erro, ou seja, o risco do preço variar dentro do intervalo analisado foi detectado, o que representou um erro percentual, de aproximadamente, 7% entre o real e o previsto.

Figura 34 - Análise de Risco para Simulação 70:30 para períodos de 30 dias úteis

Figura 35 - Análise de Risco para Simulação 70:30 para períodos de 5 dias úteis

O distanciamento, de aproximadamente 7%, representa o espaço medido entre os valores reais e os valores previstos para a série de preços do boi gordo com o ARIMA (3,1,3). Nota-se que a modelagem ARIMA mostra-se eficiente para detectar períodos com maiores oscilações de preço e que tem relação direta com eventos econômicos e políticos no Brasil como crise no mercado financeiro global e instabilidade econômica mundial. O foco em medir o risco em conjunto com a modelagem ARIMA representa a possibilidade de amenizar o impacto de variáveis “não esperadas” que afetam diretamente o preço de negociação da arroba do boi gordo.

Os resultados para esta simulação com 70% da série continuam a reforçar o fundamento de que uma previsão representa melhor o comportamento dos dados passados quando se utiliza de maior quantidade de dados para a análise. Porém, com algumas características que merecem atenção, como por exemplo, dentro da mesma simulação foi possível detectar um período de estabilidade e de instabilidade de preços. Isto representa possibilidade de melhorar a modelagem para uso em previsões de preços.

As figuras 36, 37 e 38 apresentam os resultados da distribuição de probabilidades para a simulação com 70% da série em treinamento e 30% da série para validação, utilizando-se o *Software Model Risk*®. Considerou-se ainda os valores previstos com a modelagem ARIMA (3,1,3) que apresentou o menor erro de predição.

A figura 36 representa, no eixo X, os valores referentes às diferenças entre o preço real e os preços previstos na modelagem ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência do modelo previsto. As distribuições mostradas por barras representam as distribuições variando entre R\$ -35,00 a R\$ 36,00 do preço do boi gordo. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e considerando o intervalo entre R\$ -14,00 e R\$ 14,00, a probabilidade representa 79,21% de certeza de variação entre estes valores quando comparados com os dados reais. Isto significa que a chance do preço da arroba do boi gordo se comportar conforme previsto na modelagem ARIMA (3,1,3) para a simulação 70:30 é representada por um intervalo maior de preços.

Figura 36 - Análise de Risco para Simulação 70:30 com variação entre o preço real e o preço previsto

As figuras 37 e 38 representam, no eixo X, o comportamento mínimo, médio e máximo dos preços reais e previstos na modelagem 70:30 com o ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência do modelo proposto. As distribuições mostradas por barras representam as distribuições reais e previstas no modelo de preços do boi gordo. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e os intervalos são representações da comparação com os dados reais. Na figura 37 e 38 a sobreposição entre os preços reais e os preços previstos valida o modelo com 93,66% de probabilidade de que os preços se comportem como previstos para um conjunto de 10.000 iterações, o que indica a eficácia do modelo de previsão. Na figura 37 a sobreposição entre os preços reais e os preços previstos valida o modelo com 93,66% de probabilidade de que os preços se comportem como previstos. A figura 38, visualizado em forma de linha para os preços reais e com novas iterações, o modelo valida 93,91%, o que indica a eficácia do modelo de previsão.

Figura 37 - Análise de Risco para Simulação 70:30 com sobreposição dos preços real e previsto (a)

Figura 38 - Análise de Risco para Simulação 70:30 com sobreposição dos preços real e previsto (b)

5.2.4 Análise de Risco com 60% da série para Treinamento

Nas figuras 39 e 40 o risco percentual (%) foi medido para a simulação com 60% da série histórica para treinamento e 40% para a validação do modelo. As previsões geradas para a análise de 40% da série foram modeladas pelo ARIMA (3,1,3). A figura 39 foi separada em períodos de 30 em 30 dias dentro dos 40% da série de dados utilizada para previsão, que compreendeu o período de 22/11/2006 a 18/02/2013. Os preços da série histórica do boi gordo são valores diários e somente dias úteis. A figura 40 foi separada em intervalos de tempo menores, períodos de 5 em 5 dias. Ao analisar um período maior para previsão ocorreu maior erro, ou seja, o risco do preço variar dentro do intervalo analisado foi detectado, o que representou um erro percentual, de aproximadamente, 18% entre o real e o previsto.

Figura 39 - Análise de Risco para Simulação 60:40 para períodos de 30 dias úteis

Figura 40 - Análise de Risco para Simulação 60:40 para períodos de 5 dias úteis

O distanciamento, de aproximadamente 18%, representa o espaço medido entre os valores reais e os valores previstos para a série de preços do boi gordo com o ARIMA (3,1,3). Nota-se que a modelagem ARIMA consegue detectar períodos com maiores oscilações de preço e que tem relação direta com eventos econômicos e políticos no Brasil como crise no mercado financeiro global e instabilidade econômica mundial. Porém, quando o distanciamento entre o real e o previsto aumenta, nota-se perda de qualidade na previsão dos preços.

Os resultados para esta simulação com 60% da série continuam a reforçar o fundamento de que uma previsão representa melhor o comportamento dos dados passados quando se utiliza de maior quantidade de dados para a análise.

As figuras 41, 42 e 43 apresentam os resultados da distribuição de probabilidades para a simulação com 60% da série em treinamento e 40% da série para validação, utilizando-se o *Software Model Risk*®. Considerou-se ainda os valores previstos com a modelagem ARIMA (3,1,3) que apresentou o menor erro de predição.

A figura 41 representa, no eixo X, os valores referentes às diferenças entre o preço real e os preços previstos na modelagem ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência do modelo previsto. As distribuições mostradas por barras representam as distribuições variando entre R\$ -40,00 a R\$ 60,00 do preço do boi gordo. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e considerando o intervalo entre R\$ -7,00 e R\$ 28,00, a probabilidade representa 72,59% de certeza de variação entre estes valores quando comparados com os dados reais. Isto significa que a chance do preço da arroba do boi gordo se comportar conforme previsto na modelagem ARIMA (3,1,3) para a simulação 60:40 é representada por um intervalo maior de preços.

Figura 41 - Análise de Risco para Simulação 60:40 com variação entre o preço real e o preço previsto (a)

Ao considerar uma série com 60% dos dados para treinamento e 40% para validação, nota-se que há perda de qualidade para a previsão. A variação entre os preços reais e os preços previstos na modelagem ARIMA (3,1,3) mostra-se ineficiente devido à variação flutuar entre valores muito distantes. Se, ao contrário, a avaliação fosse realizada entre intervalos de preços reais e previstos menores, por exemplo, entre R\$ -10,00 e R\$ 10,00, a eficiência da modelagem seria de apenas 39,76% de probabilidade de acerto dos preços, conforme demonstrado na figura 42.

Figura 42 - Análise de Risco para Simulação 60:40 com variação entre o preço real e o preço previsto (b)

As figuras 43 e 44 representam, no eixo X, o comportamento mínimo, médio e máximo dos preços reais e previstos na modelagem 60:40 com o ARIMA (3,1,3) e, no eixo Y, as probabilidades de ocorrência do modelo proposto. As distribuições mostradas por barras representam as distribuições reais e previstas no modelo de preços do boi gordo. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e os intervalos são representações da comparação com os dados reais. Na figura 43 a sobreposição entre os preços reais e os preços previstos valida o modelo com 80,89% de probabilidade de que os preços se comportem como previstos para um conjunto de 10.000 iterações, o que indica a eficácia do modelo de previsão. A figura 44, visualizado em forma de linha para os preços reais e com novas iterações, o modelo valida 81,50%, o que indica a eficácia do modelo de previsão.

Figura 43 - Análise de Risco para Simulação 60:40 com sobreposição dos preços real e previsto (a)

Figura 44 - Análise de Risco para Simulação 60:40 com sobreposição dos preços real e previsto (b)

5.2.5 Algumas considerações

Considerando o risco como uma medida do grau de incerteza quanto ao retorno esperado ou a probabilidade de ocorrência de perdas indesejadas (financeiras ou não), a análise dos riscos relevantes para a atividade agrícola bem como o uso de ferramentas para gerenciar estes riscos visam amenizar os efeitos decorrentes da oferta e demanda no mercado. Barros (1999) avalia que o agronegócio, bem como vários setores da economia, depende de três fatores que afetam diretamente o desempenho de suas atividades. São eles: a rentabilidade, o gerenciamento de riscos e o financiamento. Desta forma, para o autor um dos riscos mais significativos está associado às variações não antecipadas de preços, considerada como risco de mercado.

Avaliar o risco associado às decisões baseadas em modelos de previsões, como neste trabalho, mostrou-se eficiente. A análise do risco a partir da modelagem ARIMA apresentou resultados significativos que contribuem, de forma efetiva, para o processo de tomada de decisão.

Na análise de risco um princípio se faz fundamental, que é estabelecer medidas preditivas para gerenciar os riscos. Neste trabalho, o risco foi avaliado considerando o distanciamento dos preços entre os valores reais observados e os valores previstos na modelagem ARIMA. A avaliação para quatro cenários distintos fez-se necessária tendo em vista a necessidade de estabelecer uma quantidade de parâmetros “ótimos” para se realizar previsões de preços do boi gordo.

Nas simulações com 90%, 80%, 70% e 60%, respectivamente, da série histórica de preços da arroba do boi gordo, a avaliação dos riscos inerentes às flutuações de preços mostrou que, apesar da simulação com 70% da série apresentar, aproximadamente 94,0%, de probabilidade dos preços se comportarem conforme a previsão do ARIMA (3,1,3), ao longo do período analisado (2008 a 2013) tem-se um distanciamento maior entre os valores reais e os valores previstos no início da análise conforme visualizado na figura 34 e 35.

5.3 Resultados e Discussão da Pesquisa - RNA

Na hipótese de evidências de não-linearidade dos preços da arroba do boi gordo, o uso de redes neurais artificiais – RNA propõe uma melhoria adicional para o modelo de previsão utilizado neste trabalho.

Os resultados foram obtidos usando-se os coeficientes NARIMA da série de preços do boi gordo com objetivo de previsão de preços no mercado futuro.

5.3.1 Simulação e Análise da Rede Neural Artificial

Para o treinamento da rede neural foi utilizado 90% da série histórica do preço do boi gordo que compreende o período entre 23 de julho de 1997 a 26 de julho de 2011.

O modelo gerado pela rede neural é dado pela eq. (23) que apresenta 03 (três) termos autoregressivos, AR= 3; 03 (três) termos de média móvel, MA= 3; 01 (um) termo não linear autoregressivo, NAR = 1; 01 (um) termo não linear de média móvel, NMA = 1; 01 (um) não linear cruzado, CR = 1; e uma perturbação ruidosa.

Após treinamento da rede o seguinte modelo foi obtido com um erro percentual de 0.01% na saída da RNA.

A rede neural permite calcular os termos não lineares de ordem n ($n=1$) que implica considerar um termo autoregressivo quadrático de ordem 1 ou $NAR = y(n-1)^2$, um termo de média móvel quadrático de ordem 1 ou $NMA = u(n-1)^2$ e um termo não linear cruzado de ordem 1 ou $CR = y(n-1)^2 * u(n-1)^2$. A eq. (23) foi obtida com a rede neural treinada com 90% da série histórica e a eq. (24) obtida com 50% da série histórica de preços sendo ambas com ordem não linear igual a 1 para os termos NAR, NMA e CR.

$$NARIMA = 0,58y_{n-1} + 0,04y_{n-2} + 0,577y_{n-3} + 0,13u_{n-1} + 0,47u_{n-2} - 1,31u_{n-3} + 0,03u_n + 0,21y_{(n-1)^2} + 0,02u_{(n-1)^2} + 0,00001u_{(n-1)} \cdot y_{(n-1)} \quad (23)$$

$$\begin{aligned}
NARIMA = & 0,55y_{n-1} + 0,025y_{n-2} + 0,462y_{n-3} + 0,12u_{n-1} + 0,43u_{n-2} - \\
& 1,22u_{n-3} + 0,03u_n - 0,28y_{(n-1)^2} - 0,001u_{(n-1)^2} - 0,015u_{(n-2)^2} + \\
& 0,0000023u_{(n-1)} \cdot y_{(n-1)}
\end{aligned} \tag{24}$$

No treinamento da rede neural com os termos não lineares de ordem $n=1$ e com menor quantidade de dados (50% da série histórica), os coeficientes gerados possuem a mesma ordem de grandeza quando comparados ao modelo com ordem não linear $n=1$ com 90% da série histórica. Isto permite inferir que a rede neural não necessita de maior quantidade de dados para realizar o treinamento e a predição de preços.

Na avaliação do modelo NARIMA com 90% da série histórica, comparativamente ao modelo gerado com 50% da série histórica, nota-se a não dependência de termos de média móvel no modelo de preços do boi gordo. Logo, o modelo pode assumir uma não linearidade de ordem 1 no termo autoregressivo.

Na análise dos coeficientes foi possível avaliar que estes modelam satisfatoriamente, considerando o erro, o comportamento da série de preços do boi gordo. Nota-se que, no modelo com o uso de três termos para realizar a predição de preços, ou seja, o uso dos preços de três dias anteriores, o terceiro preço e o último preço influenciam com maior frequência no preço futuro, considerando a amplitude de seus coeficientes.

Na figura 45 foram gerados 100 pontos (preços) a partir do treinamento com 50% da série histórica e comparado com os valores reais. Na série histórica de $n = 3.870$ preços foram selecionados 50% dos dados que compreendeu o período de 23/07/1997 a 05/05/2005. Para os 100 pontos à frente, no eixo x estão representados os dias que compreendeu o período entre 06/05/2005 a 29/09/2005. No eixo y os preços no período em análise. A linha vermelha representa os valores reais da série histórica de preços do boi gordo. Na linha azul os valores previstos pela rede neural.

Figura 45 - Rede neural artificial com simulação de 50:50.

O resultado da previsão da RNA ilustrada na figura 45 deixa claro que, considerando um período de 100 dias adiante, a série treinada com 50% dos dados foi suficiente para que a previsão da RNA apresente o mesmo comportamento da série histórica real. Este resultado está de acordo com Leuthold (1974), Chon e Cohen (1997), Ntungo e Boyd (1998), Bressan (2004), Gaio et al. (2007); Zou et al. (2007), Sobreiro et al. (2009), dentre outros, que evidenciaram que o uso de redes neurais melhora a previsão de séries históricas quando comparada com os métodos padrões.

Além disso, a RNA permitiu avaliar o comportamento de termos não lineares presentes no modelo o que não ocorre com o modelo ARIMA padrão, já que neste caso, o modelo considerado é linear. Diversos autores discutem esta questão da linearidade de séries históricas nos modelos ARMA e ARIMA. Segundo Gaia et al. (2007), a importância destes resultados também fica evidenciada para a série histórica de boi gordo sobre o qual, atualmente, há poucas discussões na literatura quanto à linearidade do modelo. Exemplo disso é o trabalho de Ferreira et al. (2013) que, utilizando série de preços de boi gordo consideraram o comportamento linear e não linear apenas para termos autoregressivos e em períodos de maior sazonalidade econômica mas não discutem, por exemplo, os termos

quadráticos conforme aqueles mostrados na equação 23 e 24 , e nem evidenciam em gráficos a previsão, discutindo apenas em termos do erro do modelo por eles proposto.

5.3.2 Algumas considerações

Dos trabalhos analisados para a discussão do uso de redes neurais para predição de preços do boi gordo destacam-se os citados anteriormente e que estão diretamente relacionados com os resultados obtidos na figura 45. Acrescenta-se ainda, os resultados de Gaio, Castro Júnior e Oliveira (2007); Ferreira et al. (2011) e Ferreira et al. (2013).

Em Gaio, Castro Júnior e Oliveira (2007), a evolução dos preços de *commodities* no futuro continuam sujeitas a um grau de erro razoavelmente elevado. Os autores estudaram a previsão do preço futuro do boi gordo na Bolsa de Mercadorias e Futuros – BM&F utilizando-se de redes neurais artificiais e ferramentas estatísticas de modelagem de séries heteroscedásticas (AR-EGARCH) para um período de 01 de agosto de 1997 a 27 de maior de 2005. Os melhores resultados foram obtidos a partir da utilização das redes neurais artificiais quando avaliados pelo menor erro de previsão do Erro Quadrático Médio e Raiz do Erro Quadrático Médio.

Ferreira et al. (2011) avaliaram o uso de redes neurais artificiais como estratégia de previsão de preços no agronegócio para as *commodities*: soja, boi gordo, milho e trigo, no período de 1992 a 2006 com o banco de dados da EMATER/RS. Os autores utilizaram-se do modelo de rede neural *perceptron* e os trabalhos evidenciaram a possibilidade do uso de redes neurais artificiais como uma estratégia de precificação de preços de *commodities* agrícolas no mercado futuro.

Ferreira et al. (2013) avaliaram o desempenho dos modelos NARMAX (*Nonlinear Autoregressive Moving Average with Exogenous Variables*) na previsão do preço do contrato futuro do boi gordo em dois cenários distintos da economia brasileira com o objetivo de fornecer uma ferramenta de gerenciamento dos riscos de preços para a atividade pecuária. Estes autores concluíram que nos períodos de instabilidade econômica os modelos não

lineares apontam melhor capacidade preditiva; já nos períodos de estabilidade econômica os modelos lineares contêm as informações adequadas para uma previsão de preços.

5.4 Contribuições Futuras

Com a realização da pesquisa buscou-se identificar empiricamente o processo de tomada de decisão na formação do preço de venda futuro da arroba do boi gordo, considerando os aspectos quantitativos e de risco com foco no resultado econômico que permitiu a criação de uma metodologia de predição de preços da carne bovina e que proporcionou, além da rapidez no processo de tomada de decisão, uma redução de custos e consequentemente, aumento do retorno ou rentabilidade do negócio.

A relevância da pesquisa está em ressaltar a utilização de inteligência computacional na predição de preços de carne bovina, como vantagem competitiva sustentável e o reflexo ou sua influência no processo de planejamento empresarial a curto e longo prazo. Com a avaliação na predição de preços, utilizando-se de inteligência computacional e fundamentado em aspectos quantitativos de risco, espera-se tornar mais robustos os processos de decisão e formação de preços de carne bovina. Isto poderá explicar melhor as decisões dos gestores, bem como servir de guia para orientar as organizações em suas estratégias de investimento.

As contribuições da pesquisa foram:

- ✓ Contribuiu teoricamente sobre gestão estratégica de preços futuros de carne bovina;
- ✓ Identificou variáveis quantitativas de risco que compõem o processo de tomada de decisão e a absorção destas na formação do preço de venda e;
- ✓ Validou a “Predição de Preços” utilizando-se de inteligência computacional por meio das técnicas estatísticas ARIMA, análise de risco e redes neurais artificiais;
- ✓ Contribuiu teórica e praticamente na gestão estratégica de preços de carne bovina como elemento essencial para a fixação de estratégias de atuação no agronegócio.

Espera-se que em pesquisas futuras a sustentação desta metodologia proporcione o aperfeiçoamento do modelo que contribuirá para o processo de decisão de preços da carne bovina ao mercado físico e às negociações no mercado futuro. Ainda, espera-se a incorporação das medidas de risco ao sistema de previsão de preços a fim de contribuir para a minimização de erros no processo de planejamento e decisão no agronegócio.

Nos modelos de previsão espera-se, para próximos trabalhos, a comparação dos modelos de redes neurais artificiais com o próprio mercado de futuros, avaliando os preços negociados para a primeira posição em várias datas diferentes e comparar com a previsão da RNA feita na data de fechamento para a data de liquidação. Espera-se ainda, avaliar a hipótese de eficiência na previsão entre a RNA – rede neural artificial e a RNN – rede neural natural considerada como o próprio mercado.

6 CONCLUSÃO

O objetivo da pesquisa foi alcançado, ou seja, foi possível definir um modelo matemático capaz de prever preços de carne bovina usando o Modelo Autoregressivo Integrado de Médias Móveis – ARIMA, linear e não linear bem como a Análise de Risco.

Com a obtenção de uma série temporal dos preços do boi gordo, junto ao CEPEA/USP, que representa o indicador de preço do Boi Gordo ESALQ/BM&F e que serve como referencial para as negociações de compra e venda de contratos futuros na Bolsa de Mercadorias & Futuros de São Paulo (BM&FBovespa), foi possível utilizar a metodologia ARIMA para identificar padrões por meio de um modelo matemático que realizasse previsões de preço usando o *Software Matlab*®.

Com o uso do *Software Matlab*® foi possível medir o distanciamento da área entre os valores reais e os valores previstos pelo modelo ARIMA que apresentou menor erro de previsão. A análise demonstrou que o uso de amostra com 90% da série histórica é melhor comparativamente às simulações com 80%, 70% e 60% da série avaliada.

Por meio do *Softawre Model Risk*® foi possível testar um modelo usando simulações de Monte Carlo, implementado no Excel para gerar as distribuições dos preços comparativamente ao modelo de previsão gerados no modelo ARIMA.

Para gerar previsões usando séries temporais conhecidas foi treinada uma rede neural do tipo *Multilayer Perceptron* – MLP com base na metodologia desenvolvida por Chon e Cohen (1997) e Costa (2000) cuja arquitetura da rede incorpora parâmetros lineares e não lineares. E pode-se concluir que a rede foi capaz de explicitar o peso dos coeficientes não lineares do modelo NARIMA de ordem não linear igual a 1.

Na avaliação das metodologias de previsão foi possível concluir que estas metodologias se apresentam de forma ampla, flexível e muitas vezes subjetiva, mas, também é uma importante ferramenta de gestão que pode auxiliar o processo de tomada de decisão e planejamento futuro. Entretanto, o ponto fundamental para um mercado competitivo como o da pecuária de corte é o de que uma antecipação de preços gera uma série de benefícios a todos os interessados neste agronegócio.

Desta forma, os resultados demonstraram a eficiência dos modelos propostos para a simulação e instrumentalização, ou seja, permitiram avaliar o comportamento linear e não linear do modelo como ferramenta para a geração de informações e redução dos riscos que contribuirá para reduzir a subjetividade no processo de tomada de decisão.

REFERÊNCIAS BIBLIOGRÁFICAS

ABITANTE, K. G. **Modelos de Séries Temporais Aplicados à Análise Prospectiva de Concessão de Crédito Bancário**. Dissertação de Mestrado. Escola Superior de Agricultura “Luiz de Queiroz”- ESALQ/USP, 2007, p.253.

ANDERS, W. **Garch forecasting performance under different distribution assumptions**. Journal of Forecasting, v. 25, n. 5, p. 561-578, 2006.

ARAÚJO, S. J.; AREDES, A. F.; SANTOS, V. F. **Previsão de Preços do Boi Gordo com Modelos ARIMA e SARIMA**. Revista Eletrônica de Economia da Universidade Estadual de Goiás – UEG, Revista de Economia, Anápolis, v. 8,, n. 2, 2012, p.27-44.

ARMSTRONG, J. S.; LUSK, E. J. **The accuracy of alternative extrapolation models: analysis of a forecasting competitions through open peer review**. Journal of Forecasting, v. 2, n.3, 1983, p.259-311.

ASSAF NETO, A. **Finanças Corporativas e Valor**. 4º Ed. São Paulo: Atlas, 2009. 706 p.

AVEN, T.; ZIO, E.. **Some Considerations on the Treatment of Uncertainties in Risk Assessment for Practical Decision Making**. Reliability Engineering and System Safety 96, 2011. p.64-74.

BADARÓ, G. S. C.; CASTRO Jr., L. G.; FONTES, R. E. **Análise da Utilização de Mecanismos de Controle de Risco de Mercado para Compra de Insumos e Venda do Boi Gordo na Pecuária de Corte**. 2º Conferência em Gestão de Risco e Comercialização de Commodities, BM&FBOVESPA, 2013.

BARBANCHO, A. G. **Fundamentos e Possibilidades da Econometria**. Rio de Janeiro: Fórum Editora, 1970. p. 18 - 32.

BARROS, A. J. S.; LEHFELD, N. A. de S. **Fundamentos da Metodologia Científica**. 2º Ed., São Paulo: Makron Books, 2000.

BARROS, G. S. C. **Novas Estratégias de Gerenciamento de Riscos e Financiamento do Agronegócio**. Preços Agrícolas, v. 14, n. 152, 1999, p.9-10.

BEALE, R; JACKSON, T. **Neural Computing: an Introduction**. Bristol: Adam Hilger, 1990.

BERNSTEIN, P. L. **Desafio aos Deuses: a fascinante história do risco**. Rio de Janeiro: Campus, 1997, 389 p.

BOER, F. P. **The Valuation of Technology: business and financial issues in R&D**. New York: John Wiley & Sons, 1999. 403 p.

BOLLERSLEV, T. R. **Generalized Autoregressive Conditional Heteroskedasticity**. Journal of Econometrics, v. 31, n.51, p. 307-327, 1986.

BOLLERSLEV, T. R.; CHOU, R. Y.; KRONER, K. F. **ARCH Modeling in Finance: A Review of the Theory and Empirical Evidence**. Journal of Econometrics, n.52, p.5-59, 1992.

BOLLERSLEV, T. R.; ENGLE, R. I.; NELSON, D. B. **Arch Models**. Handbook of Econometrics, n.63, p.37-60, 1994.

BOLLERSLEV, T.; WOOLDRIDGE, J. M. **Quasi-maximum likelihood estimation and inference in dynamic models with time-varying covariances**. Econometric Reviews, v. 11, n. 2, p. 143-172, 1992.

BOX, G.E.P.; JENKINS, G.M. **Time Series Analysis: Forecasting and Control**. Prentice Hall, Englewood Cliffs, New Jersey, 1976. p 575.

BRESSAN, A. A. **Tomada de Decisão em Futuros Agropecuários com Modelos de Previsão de Séries Temporais**. RAE Eletrônica. Revista de Administração de Empresas FGV/EASP/SP, v.3, n.1, artigo 9, Jan-Jun/2004.

BRESSAN, A. A.; LIMA, J. E. **Modelos de Previsão de Preços Aplicados aos Contratos Futuros de Boi Gordo na BM&F**. Nova Economia, v. 12, 2002, p.117-140.

BRESSAN, A.A. **Modelos de Previsão de Preços Aplicados aos Contratos Futuros Agropecuários**. Tese de Doutorado. Universidade Federal de Viçosa/MG, 2001. 163p.

BRIGHAM, E. F.; HOUSTON, J. F. **Fundamentos da Moderna Administração Financeira**. Rio de Janeiro: Campus, 1999. 713 p.

BURGO, M. N. **Caracterização Espacial de Riscos na Agricultura e Implicações para o Desenvolvimento de Instrumentos para seu Gerenciamento**. Dissertação de Mestrado, Escola Superior de Agricultura “Luiz de Queiroz”, ESALQ/USP, 2005.

CABRAL JR, E. F. **Redes Neurais Artificiais: um curso teórico e prático para engenheiros e cientistas**. São Paulo: E. F. Cabral Junior, 1999. 323 p.

CARBONELL, J. G. **Introduction: Paradigms for Machine Learning**. v. 40, 1989, p. 1 - 9.

CASSIN, M.H. et al. **Quantitative Risk Assessment for Escherichia coli O157:H7 in Ground Beef Hamburgers**. International Journal of Food Microbiology 41, 1998. p. 21-44.

CASTRO, H. O. P. de. **Introdução ao Mercado de Capitais**. 10. ed. Rio de Janeiro: Instituto Brasileiro de Mercado de Capitais - IBMEC, 1979.

CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA CEPEA/ESALQ/USP. ESCOLA SUPERIOR DE AGRICULTURA “LUIZ DE QUEIROZ”, disponível em: <http://www.cepea.esalq.usp.br/>, acesso em 25/07/2012.

CERVO, A. L.; BERVIAN, P. A. **Metodologia Científica**. 4ª ed. São Paulo: Makron Books, 1996. 209 p.

CHASSY, B. M. **Food Safety Risks and Consumer Health**. New Biotechnology. v. 27, n.5, 2010, p. 534-544.

CHON, K. H.; YCOHEN, R. J. **Linear and Nonlinear ARMA Model Parameter Estimation Using an Artificial Neural Network**. IEEE Transactions on Biomedical Engineering, v. 44, n.3, March 1997, p.168-174.

COPELAND, T.; KOLLER, T.; MURRIN, J. **Valuation: measuring and managing the values of companies**. New York: John Wiley and Sons, 1994.

COSTA, E. J. X. **Interface Cérebro-Computador usando Redes Neurais Artificiais e Técnicas Avançadas de Processamento Digitais de Sinais**. Tese de Doutorado. Escola Politécnica da Universidade de São Paulo/USP, 2000. 217p.

DAMODARAN, A. **A Face Oculta da Avaliação: avaliação de empresas da velha tecnologia, da nova tecnologia e da nova economia**. São Paulo: Makron Books, 2002. 466 p.

DAMODARAN, A. **Avaliação de Investimentos: ferramentas e técnicas para a determinação do valor de qualquer ativo**. Rio de Janeiro: Qualitymark, 1997. 630 p.

DECO, G.; NEUNEIER, R.; SCHURMANN, B. **Non-parametric Data Selection for Neural Learning in Non-stationary Time Series**. Neural Networks, v. 10, n. 3, 1997, p.401-407.

DOMÉNECH, E.; ESCRICHE, I.; MARTORELL, S. **Quantification of Risk to Company's Incomes due to Failures in Food Quality**. Reliability Engineering and System Safety 95, 2010, p. 1324-1334.

DUARTE, M. T. **Um Estudo sobre Modelos de Previsão de Preços no Mercado de Grão de Soja**. Dissertação de Mestrado. Universidade Federal de Uberlândia, 2007, p.136.

DUFFY, G. et al. **A Review of Quantitative Microbial Risk Assessment in the Management of Escherichia coli O157:H7 on Beef**. Meat Science 74, 2006. p. 76-88.

EDIGER, V. S.; AKAR, S. **ARIMA forecasting of primary energy demand by fuel in Turkey**. Energy Policy 35, 2007, p.1701-1708.

ENDERS, W. **Applied Econometric Time Series**. 2. ed. Nova Iorque: Wiley & Sons, 1995, p.149.

ENGLE, R. F. **Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation**. Econometrica, v. 50, n. 50, 1982, p. 987-1008.

FEDERAÇÃO DA AGRICULTURA E PECUÁRIA DE MATO GROSSO DO SUL - FAMASUL, disponível em: <http://www.famasul.com.br/>, acesso em 25/07/2012.

FERREIRA, D. M.; PEREIRA, E. B.; MATTOS, L. B. **Previsão de Preços dos Contratos Futuros de Boi Gordo – uma aplicação dos Modelos NARMAX**. 2ª Conferência em Gestão de Risco e Comercialização de Commodities. BM&FBOVESPA, 2013.

FERREIRA, L.; MOURA, G. L. de; BORENSTEIN, D.; FISCHMANN, A. A. **Utilização de Redes Neurais Artificiais como Estratégia de Previsão de Preços no Contexto de Agronegócio**. RAI – Revista de Administração e Inovação/SP. V. 8, n.4, p.6-26, out/dez. 2011.

FREEMAN, J. A; SKAPURA, D. M. **Neural Networks Algorithms, Applications and Programming Techniques**. [S.L.]: Addelfon-Wefley, 1992. p. 89 - 106.

GAIO, L. E.; CASTRO JR., L. G. de; OLIVEIRA, A. R. de. **Previsão de Preço Futuro do Boi Gordo na BM&F: uma comparação entre modelos de séries temporais e redes neurais**. Organizações Rurais & Agroindustriais, vol.9, n. 2, p.272-287, Universidade Federal de Lavras/MG, 2007.

GRANGER, C. W. J.; NEWBOLD, P. **Forecasting Economic Time Series**. New York: Academic Press, 1977.

GUJARATI, D. N. **Econometria Básica**. 3ª Edição. São Paulo: Makron Books, 2000, p.846.

HARTNETT, E.; KELLY, L. A.; GETTINBY, G.; WOOLDRIDGE, M. **A Quantitative Risk Assessment for Campylobacters in Broilers: work in progress**. International Biodeterioration & Biodegradation 50, 2002. p. 161-165.

HASSAN, M. R.; NATH, B.; KIRLEY, M. **A Fusion Model of HMM, ANN and GA for Stock Market Forecasting**. Expert Systems with Applications, v. 33, n. 1, 2007, p.171-180.

HAYKIN, S. S. **Redes Neurais: princípios e práticas**. 2ª Edição. Porto Alegre: Artmed Editora/Bookman, 1999. 893 p.

HEBB, D. O. **The Organization of Behavior**. New York: John-Wiley & Sons Inc, 1949.

HECHT-NIELSEN, R. **Applications of Counterpropagation Networks**. Neural Networks Journal, 1988. p. 131-140.

HO, S. L.; XIE, M. **The use of ARIMA models for reliability forecasting and analysis.** Computers and Engennering, v.35, n.1-2, 1998, p.213-216.

HOFFMANN, R. **Estatística para Economistas.** 2. ed. São Paulo: Livraria Pioneira Editora, 1991.

HOHZADI, N. BOYD, M. S.; KERMANSHAHI, B.; KAASTRA, I. **A Comparison of Artificial Neural Networks and Time Series Models for Forecasting Commodity Price.** Neurocomputing, v. 10, n. 2, 1996, p.169-181.

HUARNG, K.; YU, T. H. **The Application of Neural Networks to Forecast Fuzzy Time Series.** Physica A: Statistical Mechanics and its Applications, v. 363, n. 2, 2006, p.481-491.

HULL, J. **Introdução aos Mercados Futuros e de Opções.** 2ª Edição, São Paulo: Bolsa de Mercadorias & Futuros e Cultura Editores Associados, 1996, p.448.

JUNTILA, J. **Strutural breaks, ARIMA model e Finnish inflation forecast.** International Journal of Forecasting, v.17, n. 2, 2001, p.203-230.

KAPLAN, S.; GARRICK, B. J.. **On the Quantitative Definition of Risk.** Risk Analysis. New York, v. 1, n. 1, 1981, p. 11-27.

KIMURA, H. **Ferramentas de Análise de Risco em Estratégias Empresariais.** RAE-eletrônica, Volume 1, Número 2, Jul-dez/2002, 14 p.

KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações.** São Paulo: Editora Acadêmica, 1996.

KREUZ, C. L.; SOUZA, A. **Custos de Produção, Expectativas de Retorno e de Risco do Agronegócio do Alho no Sul do País.** ABCustos. Associação Brasileira de Custos, Vol. 1, nº1, Set/Dez, 2006, 19 p.

LAKATOS, E. M.; MARCONI, M. A. **Fundamentos de Metodologia Científica.** 3ª Ed., São Paulo: Atlas, 1991. 270 p.

LE CUN, Y. **Generalisation and Network Design Strategies**. Technical Report CRG-TR-89-4, Department of Computer Science, University of Toronto, 1989.

LEUTHOLD, R. M. **The price Performance of the Futures Market of a Nonstorable Commodity: live beef cattle**. American Journal of Agricultural Economics, v. 56, n.2, p.64-78, 1974.

MAKRIDAKIS, S.; ANDERSEN, A.; CARBONE, R.; FILDES, R.; HIBON, M.; LEWANDOWSKI, R. NEWTON, J.; PARZEN, E.; WINKLER, R. **The Accuracy of Extrapolation (time series) Methods: results of a forecasting competition**. Journal of Forecasting. v.1, n.1, p 111-153, 1982.

MAKRIDAKIS, S.; G. S.; WHEELRIGHT, S. C.; HYNDMAN, R. J., **Forecasting: Methods and Applications**, New Jersey: John Wiley and Sons, 1998.

MAKRIDAKIS, S.; HIBON, M.; MOSER, C. **Accuracy of Forecasting: an Empirical Investigation**. Journal of Royal Statistical Society. Serie A (General), vol. 142, n. 2, 1979, pp 97-145.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYDMAN R. J. (1998). **Forecasting methods and applications**. 3th edition. New Jersey: John Wiley & Sons. 642p.

MAKRIDAKIS, S.; WINKLER, R., **Average forecasts: some empirical results**. Management Science, v. 29, p. 987-996, 1989.

MALIK, F.; NASEREDDIN, M. **Forecasting Output Using Oil Prices: a cascaded artificial neural networks approach**. Journal of Economics and Business, v. 58, n. 2, 2006, p.168-180.

MARTINS, T. M.; MARTINELLI, D. P. **Ciclos e Previsão Cíclica dos Preços das Commodities: um modelo de indicador antecedente para a commodity açúcar**. Revista de Administração, Contabilidade e Economia da FUNDACE – RACEF. Edição 02. Dez/2010.

MÁSSON, E.; WANG, Y. **Introduction to Computation and Learning in Artificial Neural Networks**. European Journal of Operational Research, North-Holand, 47, 1990. p. 1 - 28.

MEDEIROS, A.L.; MONTEVECHI, J.A.B.; REZENDE, M.L.; REIS, R.P. **Modelagem ARIMA na Previsão do Preço da Arroba do Boi Gordo**. XLIV Congresso da SOBER – Sociedade Brasileira de Economia e Sociologia Rural. Fortaleza, Julho, 2006.

MEDEIROS, A. L. **Regressão Múltipla e o Modelo ARIMA na Previsão do Preço da Arroba do Boi Gordo**. Dissertação de Mestrado. Universidade Federal de Itajubá. 2006, p.124.

MELLAGI FILHO, A.; ISHIKAWA, S. **Mercado Financeiro e de Capitais**. São Paulo: Atlas, 2000, p.335.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Edgard Blucher, 2004. p. 535.

MUELLER, A. **Uma Aplicação de Redes Neurais Artificiais na Previsão do Mercado Acionário**. Dissertação de Mestrado da Universidade Federal de Santa Catarina, Departamento de Engenharia de Produção, 1996.

NELSON, C. R. **Applied Time Series Analysis**. San Francisco: Holden-Day, 1973.

NELSON, D. B. **Conditional Heteroskedasticity in Asset Pricing: A New Approach**. *Econometrica*, v. 59, n. 2, p. 347-370, 1991.

NTUNGO, C.; BOYD, M. **Commodity futures trading performance using neural network models versus ARIMA models**. *Journal of Futures Markets*. V.18, n.8, p.965-983, 1998.

OLIVEIRA, M. A. de. **Aplicação de Redes Neurais Artificiais na Análise de Séries Temporais Econômico-Financeiras**. Tese de Doutorado, Faculdade de Economia, Administração e Contabilidade FEA/USP/SP, 2007.

ORMONEIT, D. **A Regularization Approach to Continuous Learning with Application to Financial Derivatives Pricing**. *Neural Networks* 12, 1999. p. 1405-1412.

PADILHA Jr., J. B. et al. **Modelagem Box-Jenkins (ARIMA) para Gestão de Risco de Preço na Pecuária de Corte do Estado do Paraná**. X Congresso Virtual Brasileiro de Administração – CONVIBRA, 2013, p.12.

PAPADIMITRIOU, THEODOTI; et al. **Assessment of Microcystin Distribution and Biomagnification in Tissues of Aquatic Food Web Compartments from a Shallow Lake and Evaluation of Potential Risks to Public Health**. *Ecotoxicology*, 2012, p. 1155-1166.

PASSOS, J. J.; RAMOS, E. M. L. S.; ALMEIDA, S. S. **Utilização de Modelos ARIMA para Previsão da Arrecadação de ICMS do Estado do Pará.** In: Um Modelo de Previsão para Arrecadação do ICMS no Estado do Pará. Tese (Trabalho de Conclusão de Curso). Departamento de Estatística, UFPA, Belém, 2003.

PINATTI, E. **Carne Bovina: comportamento dos preços em 2010.** São Paulo: Análises e Indicadores do Agronegócio. v. 6, n.04, abril 2011. Disponível em <http://www.iea.sp.gov.br/out/LerTexto.php?codTexto=12100>. Acesso em 17 de Julho de 2012.

PORTER, M. E. **Vantagem Competitiva.** Rio de Janeiro: Campus, 1985.

REFENES, A. N. et al. **Financial Modelling using Neural Networks.** London: Department of Computer Sciences, University College London, 1993. p. 1 - 31.

REFENES, A. N. et al. **Stock Performance Modeling using Neural Networks: A comparative study with regression models.** London: Department of Computer Sciences, University College London, 1993. p. 1 - 18.

REFENES, A. N. et al. **Currency Exchange Rate Prediction and Neural Network Design Strategies.** Neural Computing and Applications Journal, London, 1993. p. 46 - 58.

ROCHA, R. H. **A Política de Hedge e o Tratamento do Risco nas Empresas não-financeiras.** Tese de Doutorado. Faculdade de Economia, Administração e Contabilidade de São Paulo. 2007, 144 p.

ROQUE-SPECHT, V. F. **Avaliação de Risco Quantitativa como Ferramenta para a Caracterização da Segurança Microbiológica de Alimento.** GEPROS. Gestão da Produção, Operações e Sistemas. Ano 2, vol.4, jul-set/2007. p.37-48.

ROSS, D. F.; ERNST, M.; MURPHY, J. **Current Perspectives on Nuclear Power Plant Risks and the Use of Risk-Based Information in Regulation.** Nuclear Engineering and Design 103, p. 1987. 43-53.

ROSS, S.A.; WESTERFIELD, R.W.; JAFFE, J. F. **Administração Financeira: corporate finance.** São Paulo: Atlas, 1995. 698 p.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning Internal Representations by Error Propagation**. In: Parallel Distributed Processing: exploration in the microstructure of cognition. Cambridge: MIT Press, 1986.

SHIMIZU, T. **Decisão nas Organizações: introdução aos problemas de decisão encontrados nas organizações e nos sistemas de apoio à decisão**. São Paulo: Atlas, 2001. 319 p.

SOBREIRO, V. A.; ARAÚJO, P. H. S. L.; NAGANO, M. S. **Precificação do Etanol Utilizando Técnicas de Redes Neurais Artificiais**. Revista de Administração da USP, São Paulo, v.44, n.1, p.46-58, jan/fev/mar. 2009.

SOUZA, R. C. **Modelos Estruturais para Previsão de Séries Temporais: Abordagens Clássica e Bayesiana**. In: 17º Colóquio Brasileiro de Matemática. Rio de Janeiro, 1989.

STEINER, M.; WITTKEMPER, H. G. **Using Neural Networks to Forecast the Systematic Risk of Stock**. European Journal of Operational Research, v. 90, n. 3, p.577-588, 1996.

THAWORNWONG, S.; ENKE, D. **The adaptive Selection of Financial and Economic Variables for Use with Artificial Neural Networks**. Neurocomputing 56, 2004. p. 205-232.

TOMEK, W. G. **Commodity Futures Prices as Forecasts**. Review Of Agricultural Economics, v.19, n.1, 1997, p.44-68.

TRUCCO, P.; CAVALLIN, M. **A Quantitative Approach to Clinical Risk Assessment: the CREA Method**. Safety Science 44, 2006. p. 491-513.

TSENG, F.; TZENG, G. T. **A fuzzy seasonal ARIMA model for forecasting**. Fuzzy and Systems, v.126, n.3, 2002, p.367-376.

TUOMINEN, P.; RANTA, J.; MAIJALA, R. **Studying the Effects of POs and MCs on the Salmonella ALOP with a Quantitative Risk Assessment Model for Beef Production**. International Journal of Food Microbiology 118, 2007. p. 35-51.

VEMURI, V.R.; ROGERS, R.D. **Artificial Neural Networks: forecasting time series**. IEEE Computer Society Press: Institute of Electrical and Electronics Engineers, Inc. 1994.

VOSE, D. **Risk Analysis: a quantitative guide**. 3^o Ed. John Wiley & Sons, Ltd., The Atrium, Southern Gate, Chichester, West Sussex, England, 2008. 729 p.

ZHANG, G.; PATUWO, B. Eddy; HU, M. Y. **Forecasting with artificial neural networks: the state of the art**. International Journal of Forecasting, v.14, n.1, 1998, p.35-62.

ZOU, H. F. et al. **An investigation and comparison of artificial neural network and time series models for Chinese food grain price forecasting**. Neurocomputing, v.70, n. 16-18, 2007, p. 2913-2923.

WASSERMAN, P. D. **Neural Computing: Theory and Practice**. New York: Van Nostrand Reinhold, 1989.

WHEELWRIGHT, S. C.; MAKRIDAKIS, S. **Forecasting Methods for Management**. 4th edition. New York: John Wiley & Sons Inc, 1985.

WIDROW, B.; RUMELHART, D. E.; LEHR, M. A. **Neural Networks: applications in Industry, business and science**. Communications of the ACM, v. 37, n. 3, 1994, p.93-105.

WOOLDRIDGE, M.; HARTNETT, E.; COX, A.; SEAMAN, M. **Quantitative Risk Assessment Case Study: smuggled meats as disease vectors**. Rev. Sci. Tech. Off. Int. Epiz, 2006, 25 (1), p. 105-117.

ANEXO 01 – Valores críticos teste t de Dickey-Fuller

Critical Values for the Dickey-Fuller Unit Root t-Test Statistics

		Probability to the Right of Critical Value								
Model	Statistic	N	1%	2.5%	5%	10%	90%	95%	97.5%	99%
Model I (no constant, no trend)										
	ADF _{tr}	25	-2.66	-2.26	-1.95	-1.60	0.92	1.33	1.70	2.16
		50	-2.62	-2.25	-1.95	-1.61	0.91	1.31	1.66	2.08
		100	-2.60	-2.24	-1.95	-1.61	0.90	1.29	1.64	2.03
		250	-2.58	-2.23	-1.95	-1.61	0.89	1.29	1.63	2.01
		500	-2.58	-2.23	-1.95	-1.61	0.89	1.28	1.62	2.00
		>500	-2.58	-2.23	-1.95	-1.61	0.89	1.28	1.62	2.00
Model II (constant, no trend)										
	ADF _{tr}	25	-3.75	-3.33	-3.00	-2.62	-0.37	0.00	0.34	0.72
		50	-3.58	-3.22	-2.93	-2.60	-0.40	-0.03	0.29	0.66
		100	-3.51	-3.17	-2.89	-2.58	-0.42	-0.05	0.26	0.63
		250	-3.46	-3.14	-2.88	-2.57	-0.42	-0.06	0.24	0.62
		500	-3.44	-3.13	-2.87	-2.57	-0.43	-0.07	0.24	0.61
		>500	-3.43	-3.12	-2.86	-2.57	-0.44	-0.07	0.23	0.60
Model III (constant, trend)										
	ADF _{tr}	25	-4.38	-3.95	-3.60	-3.24	-1.14	-0.80	-0.50	-0.15
		50	-4.15	-3.80	-3.50	-3.18	-1.19	-0.87	-0.58	-0.24
		100	-4.04	-3.73	-3.45	-3.15	-1.22	-0.90	-0.62	-0.28
		250	-3.99	-3.69	-3.43	-3.13	-1.23	-0.92	-0.64	-0.31
		500	-3.98	-3.68	-3.42	-3.13	-1.24	-0.93	-0.65	-0.32
		>500	-3.96	-3.66	-3.41	-3.12	-1.25	-0.94	-0.66	-0.33

APÊNDICE 01 – Resultados obtidos no Exame de Qualificação

Os resultados abaixo representam os resultados avaliados para o Exame de Qualificação e que serviram de base para o desenvolvimento do trabalho de tese.

A partir das séries temporais de preço dos elos da cadeia de carne bovina com o uso do *Software Model Risk Standard Version 4.3.0.5*, foi possível iniciar a análise do comportamento de preços a fim de determinar uma distribuição de incertezas do resultado possível do modelo previsto nesta pesquisa de doutorado.

Inerentes a um dos elos da cadeia de carne bovina, os valores/preços do bezerro para o ano de 2004, foram inseridos no *Model Risk* e analisados para predição do preço a fim de validar o modelo de risco proposto inicialmente. Utilizou-se uma distribuição triangular em que o intervalo mínimo e máximo e o valor mais provável dentro do intervalo, a média, podem ser estimados.

Os resultados apresentados partem da premissa do modelo proposto de que o preço futuro depende do comportamento médio dos preços passados. A partir da inserção dos preços das séries históricas e do modelo proposto de predição de preços com o comportamento médio dos preços passados, é possível gerar um gráfico conforme figuras 4 a 9.

Os gráficos representam, no eixo X, o comportamento mínimo, médio e máximo dos preços passados e, no eixo Y, as probabilidades de ocorrência do modelo proposto. As distribuições mostradas por barras representam as distribuições previstas no modelo de preços futuros dependendo de comportamento médio de preços passados. As distribuições mostradas em linha representam comportamento dos preços reais. Como resultado do modelo, a indicação das probabilidades é demonstrada por retas verticais e os intervalos são representações da comparação com os dados reais.

Figura 46 – Análise de Risco para o Mês de Março de 2004

Considerou-se no modelo que os preços de Março de 2004 se comportariam como sendo a média dos preços estabelecidos praticados em Janeiro e Fevereiro de 2004. O resultado é mostrado na figura 4 em que a probabilidade de ocorrer este evento foi de 31,37%, demonstrando um modelo ruim. Porém, nota-se um deslocamento da média embora a curva mostre que a variabilidade está próxima.

Figura 47 – Análise de Risco para o Mês de Abril de 2004

Considerou-se no modelo que os preços de Abril de 2004 se comportariam como sendo a média dos preços estabelecidos praticados em Janeiro, Fevereiro e Março de 2004. No resultado mostrado na figura 5 a probabilidade de ocorrer este evento foi de 74,52%, demonstrando um modelo de médias útil para o propósito de análise de risco. Porém, nota-se que mantendo os mesmos parâmetros de médias, aumentando o período de recorrência e as variáveis para análise, o modelo não consegue os mesmos resultados. Este fenômeno está demonstrado na figura 6 e na figura 7, aumentando o período de análise e utilizando-se a média dos últimos meses para o modelo proposto. Quando se avalia a variabilidade nota-se que no período de Janeiro a Maio de 2004 o comportamento de preços para Junho de 2004 não se comporta como uma média dos últimos meses. A variabilidade real é bem maior que a variabilidade do modelo proposto.

Figura 48 – Análise de Risco para o Mês de Maio de 2004

Figura 49 – Análise de Risco para o Mês de Junho de 2004

Considerando a mesma avaliação de risco para o ano de 2005, no período de Janeiro e Fevereiro com previsão para Março, a probabilidade aumenta para 89,11% de chance do modelo se comportar com a média dos meses anteriores. Ainda assim, a variabilidade do modelo é bem menor que a variabilidade dos preços reais, demonstrado na figura 8.

Figura 50 – Análise de Risco para o Mês de Março de 2005

Porém, no mesmo período de probabilidade considerada satisfatória no modelo em 2004, no ano de 2005 o comportamento se altera totalmente representando que em períodos de recorrência maiores ou menores afetam o modelo não sendo possível utilizar-se da média dos meses anteriores, o que pode ser observado na figura 9.

Figura 51 – Análise de Risco para o Mês de Abril de 2005

Os resultados parciais demonstraram que a premissa do modelo de que os preços futuros dependem do comportamento médio dos preços passados não descreve o comportamento real observado. Este resultado sinaliza que as dependências são mais complexas e que não podem ser avaliadas por meio de médias aritméticas.

A pesquisa, desta forma, deverá encontrar o modelo ideal para predição de preços na cadeia de carne bovina a partir do estudo de análise de sensibilidade dos preços e o treinamento de uma rede neural para o real peso de cada período no processo de predição de preços.

As limitações encontradas até o momento indicam que o estudo do comportamento dos preços para predição não apresenta um comportamento estável e que há necessidade de utilização de outras ferramentas para encontrar o modelo que represente de forma mais aproximada a realidade como, por exemplo, a de redes neurais.