

UNIVERSIDADE FEDERAL DO PAMPA

CLAUDIA MARIA DIAS GUERRA DISCONZI

**PREVISÃO DOS PREÇOS DE *COMMODITIES* AGRÍCOLAS BRASILEIRAS NO
MERCADO FUTURO UTILIZANDO REDES NEURAS ARTIFICIAIS**

**Santana do Livramento
2018**

CLAUDIA MARIA DIAS GUERRA DISCONZI

**PREVISÃO DOS PREÇOS DE *COMMODITIES* AGRÍCOLAS BRASILEIRAS NO
MERCADO FUTURO UTILIZANDO REDES NEURAS ARTIFICIAIS**

Dissertação apresentada ao Curso de Mestrado Acadêmico em Administração da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Administração.

Orientador: Dr. Rafael Camargo Ferraz

**Santana do Livramento
2018**

CLAUDIA MARIA DIAS GUERRA DISCONZI

**PREVISÃO DOS PREÇOS DE *COMMODITIES* AGRÍCOLAS BRASILEIRAS NO
MERCADO FUTURO UTILIZANDO REDES NEURAS ARTIFICIAIS**

Dissertação apresentada ao Curso de Mestrado Acadêmico em Administração da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Administração.

Dissertação defendida e aprovada em: 19 de março de 2018.

Banca examinadora:

Prof. Dr. Rafael Camargo Ferraz
Orientador
UNIPAMPA

Prof. Dr. Paulo Vanderlei Cassanego Junior
UNIPAMPA

Prof. Dr. João Fernando Zamberlan
UNICRUZ

AGRADECIMENTOS

Agradeço a todos que me ajudaram e apoiaram de alguma forma a concluir este trabalho, em especial:

Ao corpo docente do PPGA que, através de seus ensinamentos, transmitiram-me suas experiências.

Às bancas de qualificação e defesa, pelas correções, dicas e contribuições.

Ao meu orientador, que me acolheu como orientanda, guiando-me em cada etapa.

Aos colegas que me acompanharam nesta jornada, compartilhando anseios, dúvidas, opiniões e vivências.

À minha mãe, Carmen, minha avó, Leda, minha irmã, Clarissa e a todos meus familiares, inclusive os de coração, Sueli e Renato, que me apoiaram e acompanharam nos bons e maus momentos, sempre me incentivando a ir em frente.

Dedico este trabalho à minha mãe e irmã,
mulheres inteligentes, fortes e determinadas.
Vocês são tudo pra mim.

RESUMO

O mercado das *commodities* agrícolas é caracterizado por ser dinâmico e complexo. Os preços no mercado futuro das *commodities* são negociados em bolsas de valores e variam rapidamente de acordo com diversos fatores, como mudanças cambiais, variações climáticas, políticas governamentais, estoques mundiais, entre outros. Tendo em vista a instabilidade do mercado das *commodities*, este trabalho tem por objetivo analisar a contribuição das redes neurais artificiais para a previsão de preços de *commodities* agrícolas no mercado futuro, avaliando o ajuste das redes como ferramenta estratégica no processo de tomada de decisão. Trata-se de uma pesquisa empírica, de caráter descritivo, com abordagem quantitativa. O método utilizado foi o de levantamento, por meio de dados secundários obtidos na base de dados do Cepea. Como resultados, desenvolveram-se redes com desempenho classificados como “ótimos” para todas as *commodities* consideradas, o que demonstrou a alta previsibilidade das redes neurais artificiais. Através da construção de cenários de preços mensais para as *commodities*, verificou-se que as redes selecionadas são sensíveis às variações de alta e queda nos preços. Assim, as RNAs demonstraram ser uma ferramenta importante que pode auxiliar com sucesso os interessados em investir neste mercado, através da simulação do comportamento dos preços.

Palavras-chave: commodities agrícolas; redes neurais artificiais; previsão de preços.

ABSTRACT

The commodities market is characterized by being dynamic and complex. Futures market prices are traded on stock exchanges and short-term variables such as exchange rate changes, future payments, government reports, world stocks, among others. Considering the instability of the commodities market, this work aims to analyze the construction of artificial neural networks for forecasting agricultural commodity prices in the future market, with the objective of evaluating the networks as a strategic measure in the process of making decision. It is an empirical research, of descriptive character, with quantitative approach. The method used was the survey, using data base results in the database of Cepea. As networks were developed with indicators as "optimal" for all commodities, which demonstrated a high predictability of artificial neural networks. Through the construction of monthly commodity scenarios, it was verified that the selected networks are sensitive to the variations of rise and fall in prices. Thus, the RNAs have proved to be an important tool that can successfully aid the search in this market, through the simulation of the behavior of prices.

Keywords: agricultural commodities; artificial neural networks; price forecast.

LISTA DE FIGURAS

Figura 1 – Exportações líquidas de commodities (% do PIB).....	21
Figura 2 – Produção da lavoura temporária, de 2004 a 2014, em Milhões de Toneladas	25
Figura 3 – Produção da lavoura temporária, de 2004 a 2014, em Milhões de Toneladas	27
Figura 4 – Índice CRB em pontos	28
Figura 5 – Fatores influenciadores dos preços das commodities	29
Figura 6 – Neurônio biológico.....	37
Figura 7 – Representação de um neurônio artificial.....	38
Figura 8 – Representação de um neurônio artificial com bias	39
Figura 9 – Estrutura da Perceptron	40
Figura 10 – Estrutura da Multilayer Perceptron	40
Figura 11 – Arquitetura de uma RNA	40
Figura 12 – Rede com conexão do tipo feedforward.....	41
Figura 13 – Rede com conexão do tipo feedback.....	42
Figura 14 – Fluxo do algoritmo backpropagation	44
Figura 15 – Número de publicações por ano abordando RNAs	49
Figura 16 – Etapas para realização dos testes.....	57
Figura 17 – Regressão linear Açúcar9.....	63
Figura 18 – Regressão linear Algodão5	64
Figura 19 – Regressão linear Arroz7	65
Figura 20 – Regressão linear Cafés5.....	66
Figura 21 – Regressão linear Milho6	67
Figura 22 – Regressão linear Soja10	68
Figura 23 – Regressão linear Trigo7	69
Figura 24 – Cenário de preços para o Açúcar	72
Figura 25 – Cenário de preços para o Algodão	73
Figura 26 – Cenário de preços para o Arroz.....	74
Figura 27 – Cenário de preços para o Café	75
Figura 28 – Cenário de preços para o Milho	76
Figura 29 – Cenário de preços para a Soja	77
Figura 30 – Cenário de preços para o Trigo	78

LISTA DE TABELAS

Tabela 1 – PIB do Agronegócio Brasileiro, 2010 a 2015, em Milhões de Reais	22
Tabela 2 – Variação Anual (em %) de cada segmento do PIB do Agronegócio.....	22
Tabela 3 – Participação do Agronegócio no PIB do Brasil (em %)	23
Tabela 4 – Funções de ativação	43
Tabela 5 – Tipos de normalização	46
Tabela 6 – Métodos para estimação do número de neurônios.....	47
Tabela 7 – Indicadores de preços disponibilizados pelo Cepea no dia 06/03/2017	54
Tabela 8 – Índices para verificação do desempenho das redes	56
Tabela 9 – Desempenho da rede conforme o Índice de Desempenho.....	58
Tabela 11 – Testes para a commodity Açúcar.....	60
Tabela 12 – Testes para a <i>commodity</i> Algodão	60
Tabela 13 – Testes para a <i>commodity</i> Arroz.....	61
Tabela 14 – Testes para a <i>commodity</i> Café	61
Tabela 15 – Testes para a <i>commodity</i> Milho	61
Tabela 16 – Testes para a <i>commodity</i> Soja.....	62
Tabela 17 – Testes para a <i>commodity</i> Trigo	62
Tabela 18 – Arquiteturas das redes selecionadas	69

LISTA DE QUADROS

Quadro 1 – Artigos que utilizam as RNAs para previsão de preços de commodities..... 50

LISTA DE ABREVIATURAS E SIGLAS

BI - Business Intelligence

CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

CBOT - Chicago Board of Trade

CEPEA - Centro de Estudos Avançados em Economia Aplicada

CME - Chicago Mercantile Exchange

CONAB - Companhia Nacional de Abastecimento

CRB - Commodity Research Bureau

CRCE - Chicago Rice and Cotton Exchange

EMA - Erro Médio Absoluto

EPMA - Erro Relativo Percentual Médio Absoluto

Esalq - Escola Superior de Agronomia Luiz de Queiroz

HKEX - Hong Kong Futures Exchange

IBGE - Instituto Brasileiro de Geografia e Estatística

IA - Inteligência Artificial

IC – Índice de Concordância

IC-Br - Índice de Commodities Brasil

ID – Índice de desempenho

LIFFE – London International Financial Futures Exchange

LME - London Metal Exchange

MAPA - Ministério da Agricultura, Pecuária e Abastecimento

ME – Erro Médio

MLP - Multilayer Perceptron

MSE – Erro Médio Quadrático

NYCE - New York Cotton Exchange

NYMEX - New York Mercantile Exchange

OTC - Over the Counter

PIB – Produto Interno Bruto

RMSE - Raiz Quadrada do Erro Médio

RNAs – Redes Neurais Artificiais

RR - Relação média entre os valores estimados e observados

SPELL - Scientific Periodicals Electronic Library

UNCTAD - United Nations Conference on Trade and Development

USDA - United States Department of Agriculture

USP – Universidade de São Paulo

VBPA - Valor Bruto da Produção Agropecuária

SUMÁRIO

1 INTRODUÇÃO.....	14
1.1 Objetivos da pesquisa	15
1.2 Justificativa da pesquisa	16
1.3 Delimitação do tema.....	17
1.4 Estrutura do trabalho	17
2 REFERENCIAL TEÓRICO.....	19
2.1 As <i>commodities</i> agrícolas e o cenário do agronegócio no Brasil	19
2.1.1 As <i>Commodities</i> agrícolas	19
2.1.2 A comercialização das <i>commodities</i> agrícolas	20
2.1.3 As <i>commodities</i> agrícolas e a agropecuária no Brasil	21
2.2 Planejamento estratégico	31
2.2.1 Planejamento por cenários.....	32
2.2.2 O processo de tomada de decisão nas organizações.....	34
2.2.3 O uso da Inteligência Artificial (IA) como ferramenta estratégica	36
2.3 As Redes Neurais Artificiais (RNAs).....	37
2.3.1 Histórico, conceitos e arquitetura das redes	37
2.3.2 Modelando as RNAs.....	45
2.3.3 Estudos no Brasil sobre as RNAs	48
3 METODOLOGIA.....	54
3.1 Caracterização da pesquisa.....	54
3.2 Banco de dados	54
3.3 Modelagem e desempenho das redes	55
4 RESULTADOS E DISCUSSÕES	60
5 CONSIDERAÇÕES FINAIS	79
REFERÊNCIAS	81
APÊNDICES	88

1 INTRODUÇÃO

Commodities são mercadorias comercializadas mundialmente em grande escala e geralmente envolvem produtos que não sofrem alterações industriais desde a sua extração até sua comercialização, portanto são conhecidas como insumo ou matéria-prima. Podem ser classificadas em quatro grupos: *commodities* minerais, *commodities* financeiras, *commodities* ambientais e *commodities* agrícolas. A comercialização das *commodities* ocorre, basicamente, através do mercado futuro, onde os preços dos insumos são negociados nas bolsas de valores (KALDOR, 1939; TEWELES; HARLOW; HERBERT, 1983; GEMAN, 2005).

O Brasil destaca-se mundialmente como grande produtor de *commodities* agrícolas, sendo o maior concorrente dos EUA em exportações de mercadorias deste setor (USDA, 2017). Ainda, com relação às exportações brasileiras, mais de 45% são advindos de produtos agrícolas, sendo os mais vendidos: café, açúcar, suco de laranja, soja, carne de frango e celulose (VALOR ECONÔMICO, 2012; GUIMARÃES, 2015; CASTRO, 2016). O Valor Bruto de Produção Agropecuária (VBPA) no ano de 2016 foi de 508,3 bilhões e, de acordo com a Companhia Nacional de Abastecimento (2016), o agronegócio é responsável por mais de 20% do Produto Interno Bruto (PIB) brasileiro. Tais dados demonstram o tamanho e a importância econômica do setor agropecuário e das *commodities* agrícolas para o país.

Apesar dos grandes valores resultantes da produção de *commodities* agrícolas, o VBPA mostrou queda de 1,5% no último ano. A lavoura caiu 0,2%, enquanto a pecuária diminuiu em torno de 3,9% sua produção (MAPA, 2016). Com relação aos preços destes produtos no mercado, o Índice de *Commodities* Brasil (IC-Br) do ano de 2016 demonstrou queda de 14,77% com relação ao ano anterior e, a nível mundial, o índice *CRB* (*Commodity Research Bureau*) apresentou quedas e variações constante de preços nos últimos 5 anos (Castro, 2016). Contudo, Zampieri e Castro (2017) salientam mudanças nesse cenário envolvendo os preços de *commodities*, afirmando que haverá um aumento no Índice de *Commodities* Brasil nos próximos anos.

Com isso, verifica-se que o mercado das *commodities* possui interferências de diversos fatores que influenciam a produção e, conseqüentemente, os preços de mercado. Segundo Menezes (2015), as principais causas responsáveis pelo comportamento variável dos preços de mercado das *commodities* são: as variações climáticas, os custos de produção, as políticas governamentais, os níveis de estoque mundiais, as variações de taxas cambiais, os efeitos especulativos de mercados financeiros, o *Random Walk* (fatores aleatórios) e os preços de bolsas internacionais.

A ampla variedade de fatores influenciadores de preços torna os processos de tomada de decisões complexos neste âmbito de negócios. Com isso, interessados nesse setor acabam por buscar ferramentas e métodos que os auxiliem nos processos decisórios. No ramo das negociações envolvendo preços de mercado futuro, o método do planejamento por cenários é valioso, pois se baseia na criação por parte dos interessados de possíveis cenários, permitindo a elaboração de estratégias prévias que garantam boas decisões (GODET, 2000). Para desenvolvimento dos cenários e prospecção de dados quantitativos, modelos matemáticos são utilizados no intuito de prever o comportamento de variáveis, com destaque para as redes neurais artificiais, modelo computacional que vem alcançando resultados positivos na previsão de séries de preços de produtos (COELHO JR. et al., 2013; CAVALHEIRO et al., 2016). Portanto, este trabalho depara-se com a seguinte questão de pesquisa: Como a previsão de preços de *commodities* agrícolas no mercado futuro, através das redes neurais artificiais, pode contribuir para o processo de tomada de decisão estratégica?

1.1 Objetivos da pesquisa

Visando responder à questão de pesquisa proposta, tem-se como objetivo geral **analisar a contribuição das redes neurais artificiais para a previsão de preços de *commodities* agrícolas no mercado futuro, avaliando o ajuste das redes como ferramenta de estratégia no processo de tomada de decisão.** As *commodities* agrícolas consideradas são: açúcar, algodão, arroz, café, milho, soja e trigo. Tais *commodities* foram selecionadas por serem significativas no setor agropecuário, em nível de produção e rendimentos, além de apresentarem vasto histórico de preços mantidos pelo Centro de Estudos Avançados em Economia Aplicada (Cepea), o que permite o aprendizado e a modelagem das redes (CEPEA, 2016).

Para atender ao objetivo geral, buscam-se atingir os seguintes objetivos específicos:

- a) Desenvolver as redes para cada *commodity*, considerando previsões diárias;
- b) Identificar as melhores arquiteturas de redes encontradas para a previsão de preços das *commodities*;
- c) Avaliar a estimativa das melhores arquiteturas de redes obtidas;
- d) Desenvolver cenários de preços com as redes de melhor desempenho.

1.2 Justificativa da pesquisa

O mercado das *commodities* agrícolas é instável, caracterizado por constantes variações de preços devido a diversos fatores (MENEZES, 2015). Este tipo de cenário comercial mutável exige dos envolvidos nesse setor, habilidades de gestão e planejamento. Portanto, ferramentas que auxiliam na elaboração do planejamento estratégico são muito importantes, pois podem ser utilizadas pelas partes envolvidas no negócio; produtor rural, comprador e interessados; a elaborarem suas estratégias de produção, compra e venda.

Como ferramenta do planejamento estratégico, tem-se o método do planejamento por cenários, o qual é indicado para todos os tipos de organizações e negócios, pois permite que os gestores se preparem para as mais variadas situações que possam vir a ocorrer no mercado (GODET, 2000). Este método possibilita que a empresa se prepare para enfrentar a concorrência e as mudanças mercadológicas, fornecendo suporte para as tomadas de decisões. Com relação à comercialização de *commodities* no mercado futuro, o uso dos cenários prospectivos é interessante, tendo em vista a possibilidade, por parte dos interessados, a simulação de preços considerando aumento ou queda na produção, situações de chuvas ou secas, mudanças cambiais, políticas, entre outras informações. Quando se faz uso de dados quantitativos, como é o caso dos preços, modelos matemáticos são os mais utilizados para a prospecção dessas variáveis. Dentre estes métodos, as redes neurais artificiais vêm se destacando por apresentarem bons resultados na previsão do comportamento de preços.

Estudos recentes realizados no Brasil demonstraram sucesso na aplicação das redes neurais artificiais para a previsão de preço. Coelho Júnior et al. (2013) conseguiram prever os preços do carvão vegetal no Estado de Minas Gérias com 99% de acurácia. Outro exemplo é a pesquisa de Gaio, Castro Jr. e Oliveira (2007), onde o preço do boi gordo foi previsto com um erro quadrático médio de apenas 0,007. Assim, considerando os resultados positivos encontrados na aplicação das Redes Neurais Artificiais (RNAs) para a previsão de série de preços, o presente estudo justifica-se no intuito de buscar aplicar as redes neurais para a previsão do preço no mercado futuro das principais *commodities* agrícolas brasileiras, através dos preços Esalq/BM&F, disponibilizados pelo banco de dados do Centro de Estudos Avançados em Economia Aplicada (Cepea), mantido pela Universidade Federal de São Paulo.

Conforme Ferreira et al. (2011), pesquisas que visam apoiar os gestores agrícolas brasileiros no processo decisório envolvendo preços são poucas e necessárias, havendo espaço para estudos que busquem metodologias bem estruturadas e aplicáveis. Menezes (2015) explica que as instabilidades do setor envolvendo as *commodities* agrícolas podem causar

desestimulo de produção; quando há queda constante nos preços, ou até mesmo superprodução; quando ocorrem períodos de aumento dos preços de comercialização. Portanto, poder compreender o comportamento do mercado é fundamental para que produtores, compradores, governo e investidores possam se planejar estrategicamente nesse setor de destaque na economia do país, tendo em vista a participação de mais de 20% do agronegócio no PIB do Brasil (CONAB, 2016). Além disso, ferramentas fáceis de serem utilizadas e que obtenham bons resultados na previsão de preços podem estimular produtores rurais a fazerem parte do mercado futuro, tendo em vista que menos de 1% dos pequenos produtores rurais brasileiros participam como investidores neste mercado (INFOMONEY, 2011).

Ao se obter bons resultados de previsão com as redes neurais, aplicativos (plataforma móvel ou web) podem ser construídos e disponibilizados para auxiliar interessados no planejamento e tomada de decisão a partir do comportamento e previsão dos preços de *commodities* agrícolas brasileiras no mercado futuro.

1.3 Delimitação do tema

O tema desta dissertação limita-se a previsão diária dos preços Esalq/BM&F de *commodities* agrícolas brasileiras para o mercado futuro, sendo estas: açúcar, algodão, arroz, café, milho, soja e trigo. Os preços previstos utilizam os dados provenientes do banco de dados *online* mantido pelo Centro de Estudos Avançados em Economia Aplicada (Cepea). A previsão dos preços foi realizada por meio da aplicação do modelo matemático computacional de redes neurais artificiais. Utilizaram-se como variáveis de entrada para as redes a data do preço da *commodity* a ser previsto e preços de dias anteriores a este dia, sem considerar outras variáveis que possam afetar o comportamento dos preços das *commodities*.

1.4 Estrutura do trabalho

Este trabalho apresenta cinco seções, sendo esta a introdução, constituída da contextualização do tema, objetivos, justificativa, delimitação do tema e estrutura do trabalho. A segunda seção é composta pelo referencial teórico, formado por três temas: a) As *commodities* agrícolas e o cenário no agronegócio no Brasil, trazendo uma contextualização sobre o tema das *commodities* agrícolas; b) Planejamento estratégico, abordando conceitos de estratégia, planejamento por cenários, características do processo de tomada de decisão e o

uso da Inteligência Artificial como ferramenta estratégica; e c) Redes Neurais Artificiais (RNAs), apresentando conceitos das RNAs, histórico, arquitetura, como funcionam e estudos envolvendo as redes neurais e *commodities* no Brasil. A terceira seção é formada pela metodologia, contendo a caracterização da pesquisa e informações sobre os procedimentos metodológicos que foram realizados. A quarta seção é constituída pelos resultados dos testes; onde os desempenhos obtidos com as diferentes redes construídas para cada *commodity* são apresentados e discutidos; e são apresentados cenários quantitativos desenvolvidos com as melhores arquiteturas de redes selecionadas. A quinta, e última seção, traz as considerações finais deste trabalho, discutindo os resultados obtidos com as redes neurais, limitações de pesquisa e sugestões de trabalhos futuros.

2 REFERENCIAL TEÓRICO

2.1 As *commodities* agrícolas e o cenário do agronegócio no Brasil

2.1.1 As *Commodities* agrícolas

O termo “*commodities*” é uma palavra no plural que vem do inglês e significa “mercadorias”, no singular é descrita como “*commodity*”. Em português, a palavra *commodity* também é utilizada e faz referência, geralmente, a mercadorias do setor agrícola e de minérios, que são comercializadas em grande escala, a nível mundial (PINHEIRO; SENNA, 2016). As *commodities* são definidas como ativos físicos padronizados, os quais não sofrem processos de alteração (ou quase nenhum) desde sua extração até sua comercialização, podendo ser transportadas e estocadas por longos períodos de tempo. Por se tratarem de produtos que não passam por processos industriais, são normalmente classificadas como insumos ou matérias-primas (KALDOR, 1939; TEWELES; HARLOW; HERBERT, 1983; GEMAN, 2005).

As *commodities* podem ser divididas em quatro grandes grupos: *commodities* minerais, *commodities* financeiras, *commodities* ambientais e *commodities* agrícolas. Como exemplos de *commodities* minerais têm-se: minério de ferro, petróleo, níquel, ouro e prata. Moedas negociadas em variados mercados, como o dólar, real e o euro; e títulos públicos de governos federais são modelos de *commodities* financeiras. Uma importante *commodity* ambiental são os créditos de carbono e quando se trata do grupo das *commodities* agrícolas, inúmeros são seus exemplos, tais como: soja, trigo, algodão, café, laranja, borracha, feijão, milho, boi, frango, cana-de-açúcar, entre outros (BRANCO, 2008).

Mundialmente, as *commodities* mais comercializadas são o minério de ferro, a madeira, carne de boi e frango, e o petróleo. O país que mais importa *commodities* é a China, com 697 bilhões de dólares gastos neste mercado, seguida dos Estados Unidos, com 564 bilhões de dólares, Japão com 402 bilhões de dólares, Alemanha com 329 bilhões de dólares e Índia com 231 bilhões de dólares desembolsados (CASTRO, 2016). O valor do Produto Interno Bruto (PIB) brasileiro fechou o ano de 2015 em torno de 6 trilhões de reais correntes (CEPEA, 2016), dos quais, em torno de 5% são advindos das exportações de *commodities* (UNCTAD; 2014, CASTRO, 2016). As principais *commodities* produzidas no país são: petróleo, café, suco de laranja, minério de ferro, soja e alumínio. No comércio mundial, o Brasil se sobressai no setor das *commodities* agrícolas, aparecendo como líder no *ranking* de vendas de seis produtos: café, açúcar, suco de laranja, soja, carne de frango e celulose. Além

disso, também se destaca na exportação de carne bovina, com produção anual de 9,1 milhões de toneladas; e grãos e fibras, 160 milhões de toneladas ao ano. O agronegócio no Brasil mostra-se promissor, com participação em torno de 22% do PIB total (VALOR ECONÔMICO, 2012; GUIMARÃES, 2015; CASTRO, 2016).

2.1.2 A comercialização das *commodities* agrícolas

As *commodities* agrícolas podem ser comercializadas de quatro maneiras, via mercado físico, mercado de opções, mercado a termo ou mercado de futuros. O mercado físico, também conhecido por mercado disponível ou *spot*, envolve a troca imediata de uma quantidade física de determinado produto por certo valor em dinheiro (HULL, 2006; PEREIRA, 2009).

No mercado de opções, são negociados os direitos de compra e venda de um produto, havendo uma definição prévia dos preços e prazos. Neste mercado se tem a opção, e não a obrigação, de comprar ou vender algo a certo preço, dentro de um determinado prazo (HULL, 2006).

O mercado a termo é explicado por Hull (2006) como sendo: “um acordo de compra e venda de um ativo em uma data determinada por um preço determinado”. Ou seja, consiste em um negócio com entrega futura, com valor atual definido. Este tipo de mercado foca na eliminação do risco de preço, pois as partes envolvidas combinam previamente os valores da venda, além da quantidade e data de liquidação do contrato.

Os mercados de futuros, ou mercados de derivativos, são considerados uma evolução do mercado a termo, pois o processo de negociação neste tipo de mercado também considera a compra e venda de um ativo, entre duas partes, com preço pré-estabelecido e data futura de entrega. A diferença é que neste tipo de negócio as partes não se conhecem, as operações são publicamente divulgadas, os contratos são comumente negociados via bolsa de valores, envolvendo quantidades padrões e sem obrigação de entrega do produto (HULL, 2006). Como exemplo de bolsas que negociam valores de *commodities* se tem: *Chicago Board of Trade (CBOT)*, *Chicago Rice and Cotton Exchange (CRCE)* e *Chicago Mercantile Exchange (CME)* em Chicago; *New York Cotton Exchange (NYCE)* e *New York Mercantile Exchange (NYMEX)* em Nova Iorque; *London International Financial Futures Exchange (LIFFE)* e *London Metal Exchange (LME)* ambas de Londres; *Hong Kong Futures Exchange (HKEX)* de Hong Kong, entre outras (GEMAN, 2005; PEREIRA, 2009). No Brasil, a bolsa de maior destaque na negociação de contratos futuros em *commodities* é a Bolsa de Valores,

Mercadorias e Futuros (BM&FBOVESPA) (GAIO; CASTRO JR; OLIVEIRA, 2007; PEREIRA, 2009).

2.1.3 As *commodities* agrícolas e a agropecuária no Brasil

Conforme dados do *United States Department of Agriculture (USDA, 2017)*, o Brasil é o maior competidor dos EUA em vendas mundiais de *commodities* agrícolas, principalmente quando se tratam da soja, carne de boi, carne de frango e milho. Com relação ao total das exportações brasileiras, cerca de 46% são de produtos advindos do agronegócio. Apesar do destaque no mercado internacional de venda de *commodities*, a exportação destas representa apenas em torno de 5% do PIB brasileiro nos últimos anos (GUIMARÃES, 2015; CONAB, 2016). Como se pode observar na Figura 1, a exportação líquida de *commodities* apresentou baixo percentual no PIB do país em 2015, ficando o Brasil atrás de muitos países da América do Sul.

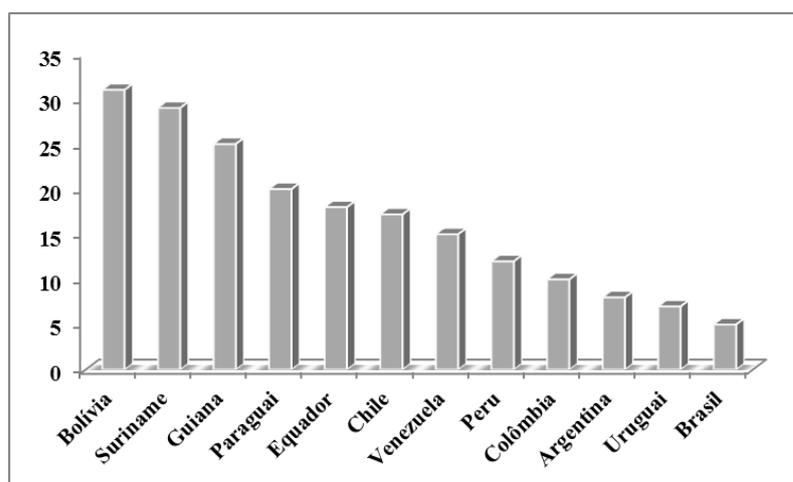


Figura 1 – Exportações líquidas de *commodities* (% do PIB)
Fonte: Adaptado de Guimarães (2015)

Contudo, o agronegócio é responsável por mais de 20% do PIB do país e estudo publicado pela Companhia Nacional de Abastecimento (CONAB, 2016), denominado “Perspectivas para a Agropecuária, safra 2016/2017” confirmam este cenário, demonstrando que a agropecuária continua em alta na economia brasileira. Segundo dado desta pesquisa apesar do PIB brasileiro ter caído 3,8% em 2015, o setor do agronegócio subiu 1,46% neste mesmo ano. Dados da pesquisa do Cepea (2016) corroboram com os resultados fornecidos pela Conab, pois demonstram crescimento no PIB do agronegócio nos últimos anos. Tais dados são apresentados na Tabela 1.

Tabela 1 - PIB do Agronegócio Brasileiro, 2010 a 2015, em Milhões de Reais

ANO	2010	2011	2012	2013	2014	2015
Agronegócio Total (A+B+C+D)	1.155.704	1.215.615	1.180.519	1.241.738	1.262.452	1.280.827
A) Insumos	123.963	139.349	138.902	144.469	147.974	152.254
B) Agropecuária	303.626	339.487	329.845	359.355	374.662	382.721
C) Indústria	358.439	353.508	339.788	351.071	349.244	351.859
D) Serviços	369.676	383.271	371.984	386.844	390.573	393.992
Ramo Agrícola (A+B+C+D)	824.083	859.379	846.041	862.950	856.689	871.779
A) Insumos	75.760	84.759	85.421	85.866	85.326	88.566
B) Agropecuária	173.763	197.302	196.936	202.101	202.744	208.291
C) Indústria	312.158	306.670	296.460	304.859	301.940	305.359
D) Serviços	262.402	270.648	267.225	270.124	266.679	269.563
Ramo Pecuário (A+B+C+D)	331.621	356.236	334.477	378.788	405.763	409.048
A) Insumos	48.203	54.591	53.481	58.603	62.647	63.689
B) Agropecuária	129.863	142.185	132.909	157.254	171.918	174.430
C) Indústria	46.281	46.838	43.328	46.211	47.304	46.500
D) Serviços	107.274	112.623	104.759	116.719	123.894	124.429

Fonte: Adaptado de Cepea (2016)

Observa-se grande participação do setor da Agropecuária, sendo responsável no ano de 2015 por 30% do PIB total do Agronegócio brasileiro, ficando atrás apenas dos Serviços, com 31%. Na Tabela 2, pode-se verificar a variação anual de cada um destes segmentos no intervalo de tempo entre os anos de 2010 e 2015.

Tabela 2 - Variação Anual (em %) de cada segmento do PIB do Agronegócio

ANO	2010	2011	2012	2013	2014	2015
Agronegócio Total (A+B+C+D)	7,54	5,18	-2,89	5,19	1,67	1,46
A) Insumos	4,79	12,41	-0,32	4,01	2,43	2,89
B) Agropecuária	10,92	11,81	-2,84	8,95	4,26	2,15
C) Indústria	6,64	-1,38	-3,88	3,32	-0,52	0,75
D) Serviços	6,68	3,68	-2,94	3,99	0,96	0,88
Ramo Agrícola (A+B+C+D)	7,89	4,28	-1,55	2,00	-0,73	1,76
A) Insumos	4,55	11,88	0,78	0,52	-0,63	3,80
B) Agropecuária	12,20	13,55	-0,19	2,62	0,32	2,74
C) Indústria	7,08	-1,76	-3,33	2,83	-0,96	1,13
D) Serviços	7,13	3,14	-1,26	1,09	-1,28	1,08
Ramo Pecuário (A+B+C+D)	6,67	7,42	-6,11	13,25	7,12	0,81
A) Insumos	5,16	13,25	-2,03	9,58	6,90	1,66
B) Agropecuária	9,25	9,49	-6,52	18,32	9,32	1,46
C) Indústria	3,76	1,20	-7,49	6,65	2,36	-1,70
D) Serviços	5,60	4,99	-6,98	11,42	6,15	0,43

Fonte: Adaptado de Cepea (2016)

Com os dados da Tabela 2, percebem-se variações, no PIB do Agronegócio total, com queda no ano de 2012, seguido de aumento nos anos seguintes. Nos anos de 2014 e 2015 observa-se aumento, sobressaindo-se os setores dos insumos e da agropecuária. Considerando o PIB total brasileiro, a participação do agronegócio foi de 21,35% em 2015, conforme Tabela 3.

Tabela 3 - Participação do Agronegócio no PIB do Brasil (em %)

ANO	2010	2011	2012	2013	2014	2015
PIB total do Brasil (em R\$ milhões correntes)	3885847	4376382	4814760	5331619	5778953	6000570
Agronegócio Total (A+B+C+D)	21,64	21,94	20,52	20,68	20,44	21,35
A) Insumos	2,32	2,51	2,41	2,41	2,40	2,54
B) Agropecuária	5,69	6,13	5,73	5,98	6,06	6,38
C) Indústria	6,71	6,38	5,91	5,85	5,65	5,86
D) Serviços	6,92	6,92	6,47	6,44	6,32	6,57
Ramo Agrícola (A+B+C+D)	15,43	15,51	14,71	14,37	13,87	14,53
A) Insumos	1,42	1,53	1,48	1,43	1,38	1,48
B) Agropecuária	3,25	3,56	3,42	3,37	3,28	3,47
C) Indústria	5,85	5,53	5,15	5,08	4,89	5,09
D) Serviços	4,91	4,88	4,65	4,50	4,32	4,49
Ramo Pecuário (A+B+C+D)	6,21	6,43	5,81	6,31	6,57	6,82
A) Insumos	0,90	0,99	0,93	0,98	1,01	1,06
B) Agropecuária	2,43	2,57	2,31	2,62	2,78	2,91
C) Indústria	0,87	0,85	0,75	0,77	0,77	0,77
D) Serviços	2,01	2,03	1,82	1,94	2,01	2,07

Fonte: Adaptado de Cepea (2016)

Apesar de se verificar quedas na participação do PIB do agronegócio no PIB total brasileiro nos anos de 2011 e 2014, observa-se que a porcentagem de participação permanece entre o intervalo de 20% a 22% no período considerado de 2010 a 2015. Isto demonstra que mais de 1/5 do PIB do país é resultante do agronegócio.

Através dos dados fornecidos pelo Cepea (2016), denota-se uma grande participação do ramo agrícola no PIB do agronegócio. Nas tabelas anteriores, observa-se um crescimento contínuo do ramo da pecuária entre os anos de 2012 e 2015, enquanto o agrícola apresenta duas quedas neste mesmo período de tempo. Apesar disso, o ramo agrícola tem participação de 68% no PIB do agronegócio, contra 32% provindos do ramo da pecuária em 2015.

No ano de 2016, o Valor Bruto da Produção Agropecuária (VBPA) foi de 508,3 bilhões de reais. Dos quais 338 bilhões de reais resultaram da lavoura e os 170,3 bilhões de reais restantes, da pecuária (MAPA, 2016). Quando consideradas as regiões brasileiras, o VBPA da região Sul é o maior (R\$ 151 bilhões), seguido da região Centro-Oeste (R\$ 143,2

bilhões), Sudeste (R\$ 138,8 bilhões), Nordeste (R\$ 45,5 bilhões) e Norte (R\$ 29,8 bilhões). Quando se tratam dos Estados, cinco se destacam, sendo o líder o Mato Grosso (R\$ 72,4 bilhões), seguido de São Paulo (R\$ 70,6 bilhões), Paraná (R\$ 66,3 bilhões), Minas Gerais (R\$ 57,6 bilhões) e Rio Grande do Sul (R\$ 56,4 bilhões). Estes Estados juntos correspondem a 62,6% do valor bruto da produção agropecuária do Brasil.

Ao se comparar o VBPA de 2016 ao ano anterior, o qual obteve um VBPA de 516 bilhões de reais, verifica-se uma queda de quase 1,5% (MAPA, 2016). Ainda, de acordo com dados da Conab (2016), a lavoura apresentou queda de 0,2% enquanto a pecuária caiu em torno de 3,9% de 2015 para 2016. A pecuária apresentou queda em sua produção considerando todos os produtos do segmento: carne bovina, carne de frango, carne suína, leite e ovos. Com relação às lavouras isto ocorreu, pois houve uma redução na safra onde, por exemplo, quando considerada a safra de grãos, o ano de 2015 apresentou um total de 207,67 milhões de toneladas, enquanto o ano de 2016 colheu 202,34 milhões de toneladas (CONAB, 2016).

Considerando apenas os cultivos agrícolas, dados disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) demonstram o comportamento da quantidade produzida pelas lavouras temporárias e permanentes no Brasil entre os anos de 1990 e 2014. As lavouras permanentes envolvem culturas de longa duração, as quais não necessitam replantio após a colheita, enquanto nas temporárias, as culturas de curta duração (menos de um ano) geralmente necessitam de um novo plantio (IBGE, 2017). A Figura 2 apresenta o comportamento da produção dos quinze principais cultivos temporários entre os anos de 2004 e 2014.

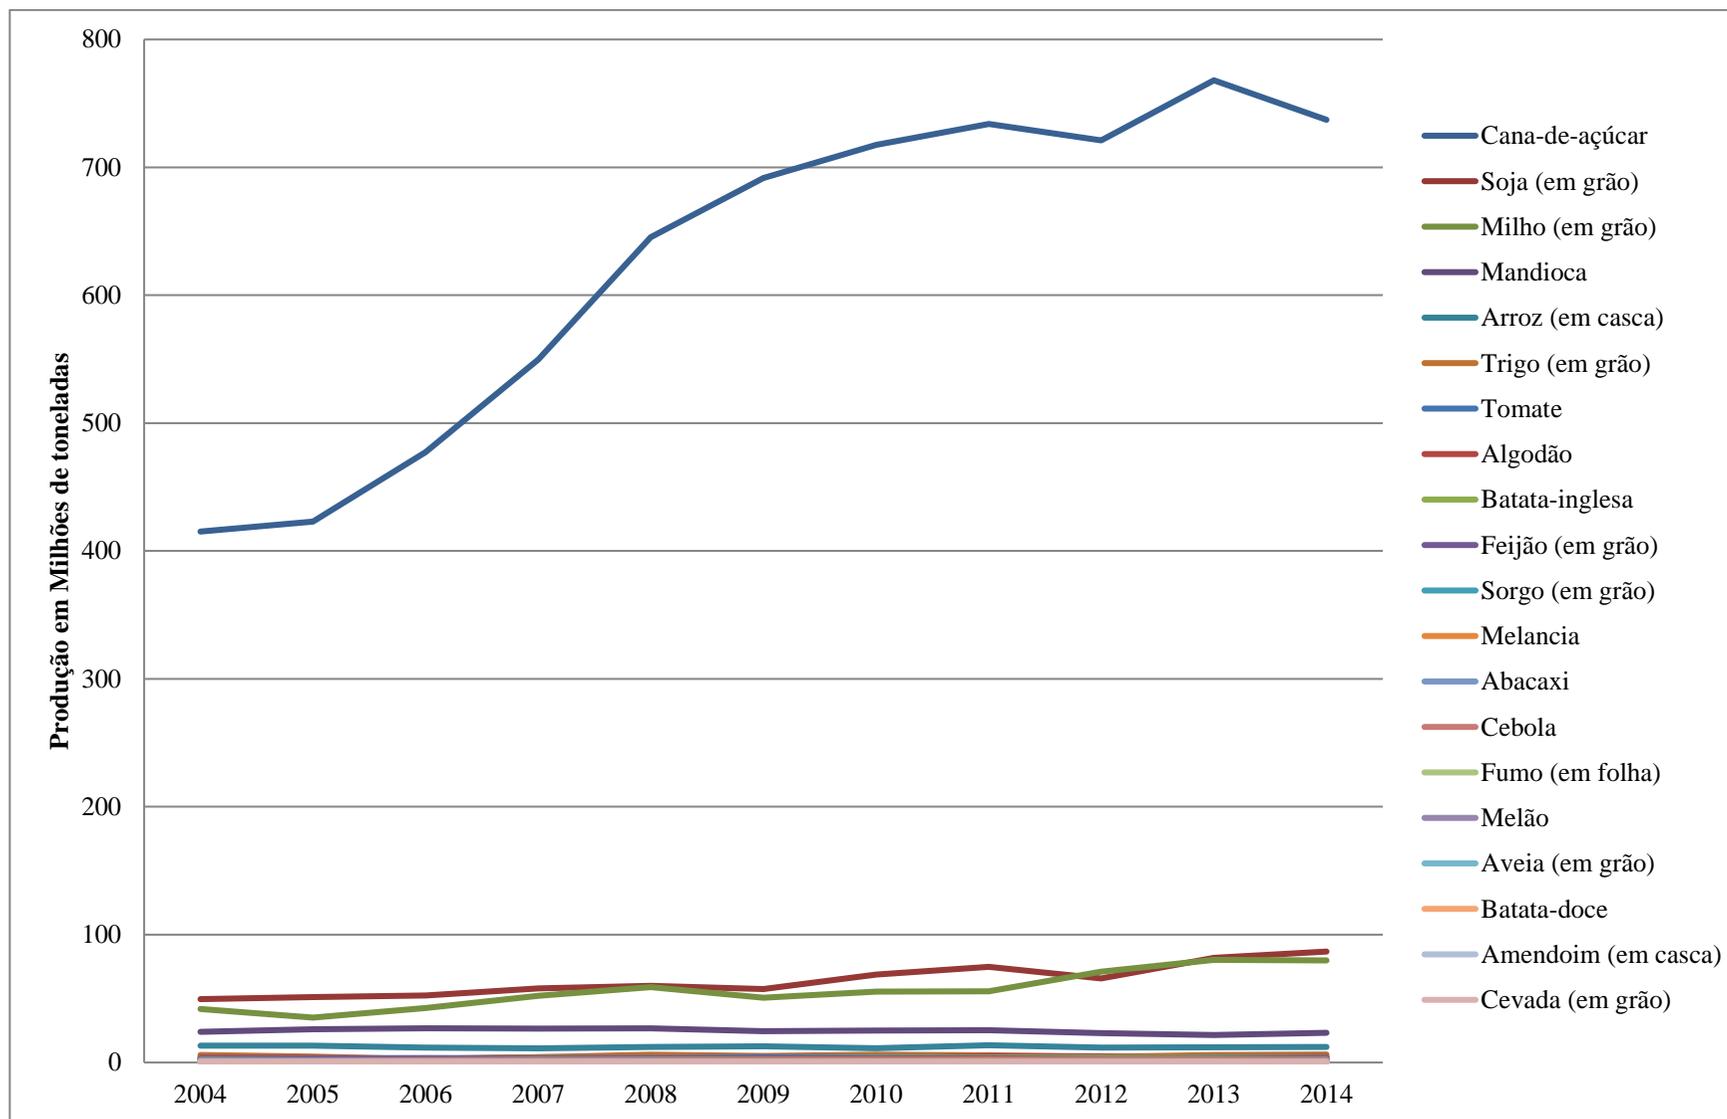


Figura 2 - Produção da lavoura temporária, de 2004 a 2014, em Milhões de Toneladas
 Fonte: elaborada com base em dados do IBGE (2015)

Observa-se na Figura 2 que a cana-de-açúcar se destaca de acordo com a quantidade produzida em relação às demais culturas temporárias, mostrando crescimento contínuo da sua produção ano-a-ano até 2011. Após esse período, apresenta variações entre acréscimo e decréscimo até o ano de 2014. Outras duas culturas que se sobressaem são a soja e o milho, as quais apresentam crescimento na quantidade de produção discreto anualmente. Após a cana-de-açúcar, a soja e o milho, as culturas mais produzidas no Brasil em 2014 foram em ordem decrescente de produção: Mandioca, Arroz, Trigo, Tomate, Algodão, Batata-inglesa, Feijão, Sorgo, Melancia, Abacaxi, Cebola, Fumo, Melão, Batata-doce, Aveia, Amendoim e Cevada (IBGE, 2015). Através da Figura 2, verifica-se que apesar de alguns produtos apresentarem comportamentos mais lineares de produção, todos os cultivos apresentaram variações anuais na quantidade produzida total.

A Figura 3 ilustra o comportamento dos cultivos que se destacam quanto à quantidade de produção na lavoura permanente.

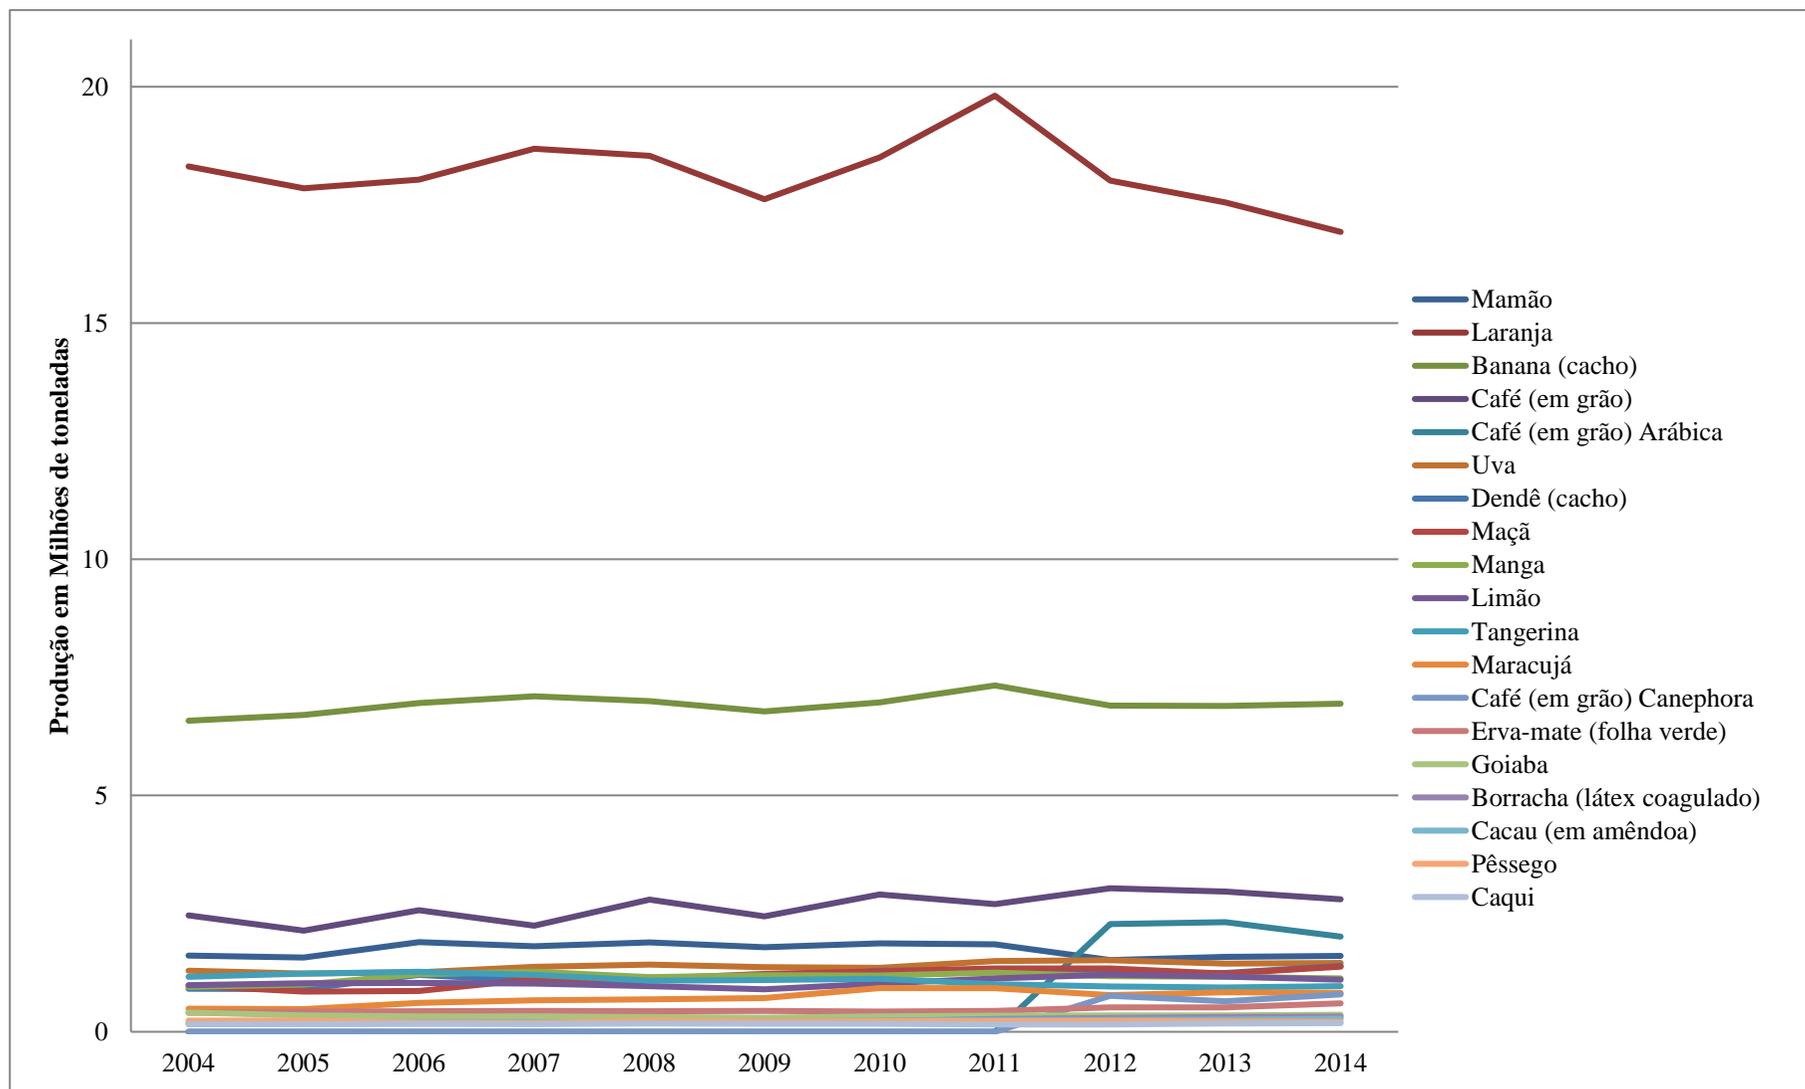


Figura 3 – Produção da lavoura temporária, de 2004 a 2014, em Milhões de Toneladas

Fonte: elaborada com base em dados do IBGE (2015)

Analisando-se a Figura 3, pode-se observar que a produção da laranja se resalta entre as demais, mostrando que a quantidade produzida varia anualmente. Cultivos como café, café arábica, café Canephora, limão e manga demonstram pouca variação na quantidade de um ano para o outro, contudo, até mesmo pequenas variações na quantidade de produção de cultivos acabam por influenciar o mercado, não apenas na oferta, mas diretamente nos preços dos produtos, causando oscilações de valores (IBGE, 2015; CONAB, 2016).

As variações e reduções nas safras de muitos produtos ocorrem geralmente, segundo a Companhia Nacional de Abastecimento (2016), devido às variações climáticas, como excesso de chuvas e longos períodos de seca. O ano de 2016 no Brasil foi marcado por esses comportamentos extremos do clima, prejudicando lavouras importantes como a do algodão, soja, arroz e milho, o que acaba por diminuir a oferta destes produtos e consequentemente, influencia seus preços de mercado. Dentre os produtos que obtiveram os melhores desempenhos no faturamento no ano de 2016 e foram responsáveis por 67% do VBPA das lavouras, estão: banana (+22,3 %); batata-inglesa (+14,5%); café (+15,7%); feijão (+7,9 %); milho (+6,7%); soja (+3,7%); trigo (+9,9%); maçã (+10,9%) (CONAB, 2016). Conforme dados do Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2016), o crescimento do VBPA destes alimentos deu-se basicamente pelo aumento dos preços, e não por um aumento considerável na produção. Já os produtos que apresentaram as maiores reduções no faturamento foram: algodão (-8,2%); arroz (-10,6%); cebola (-8,0%); fumo (-26,5%); laranja (-13,2%); mandioca (-13,3%); tomate (-47,6%); e uva (-17,7%) (CONAB, 2016).

Com relação às *commodities*, Castro (2016) informa que o comércio mundial de *commodities* cresceu gradativamente até 2011, mantendo-se estacionado até o ano de 2014 e vindo a decair desde então. Para justificar sua afirmativa, traz uma amostra da evolução do índice *CRB* (*Commodity Research Bureau*), índice utilizado para medir preços de *commodities* no mercado internacional, apresentado na Figura 4.

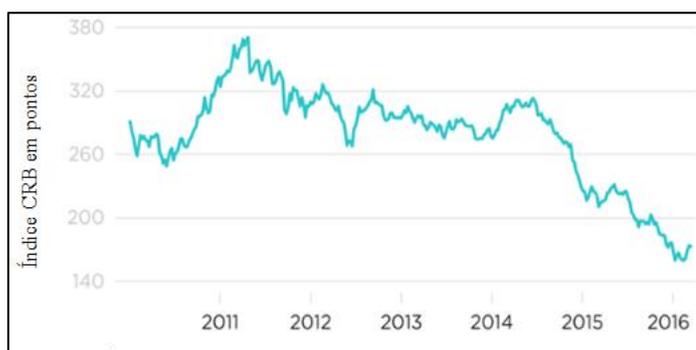


Figura 4 – Índice *CRB* em pontos
Fonte: Castro (2016)

Dados mais recentes considerando o ano de 2016, informam que o índice *CBR* caiu 12,9% nesse ano e o Índice de *Commodities* Brasil (IC-Br) acompanhou este comportamento, com queda de 14,77%. Dentre as *commodities* que compõe o IC-Br, as do setor agropecuário mostraram a maior baixa, em torno de 0,90% ao mês, sendo elas carne de boi, carne de porco, soja, açúcar, milho, café e arroz (CAMPOS, 2016). Contudo, Zampieri e Castro (2017) indicam em janeiro de 2017 um aumento no índice *CBR* nos últimos meses, atingindo o maior patamar do índice neste semestre.

Portanto, verifica-se que o mercado das *commodities* se trata de um mercado instável e dinâmico, marcado por variações de preço devido a fatores como, mudanças climáticas, custos de produção, políticas governamentais, níveis de estoque mundiais, variações de taxas cambiais, efeitos especulativos de mercados financeiros, *Random Walk*, preços de bolsas internacionais, entre outros fatores (MENEZES, 2015). A Figura 5 apresenta os fatores que influenciam a demanda e a oferta das *commodities*, bem como seu preço de mercado.

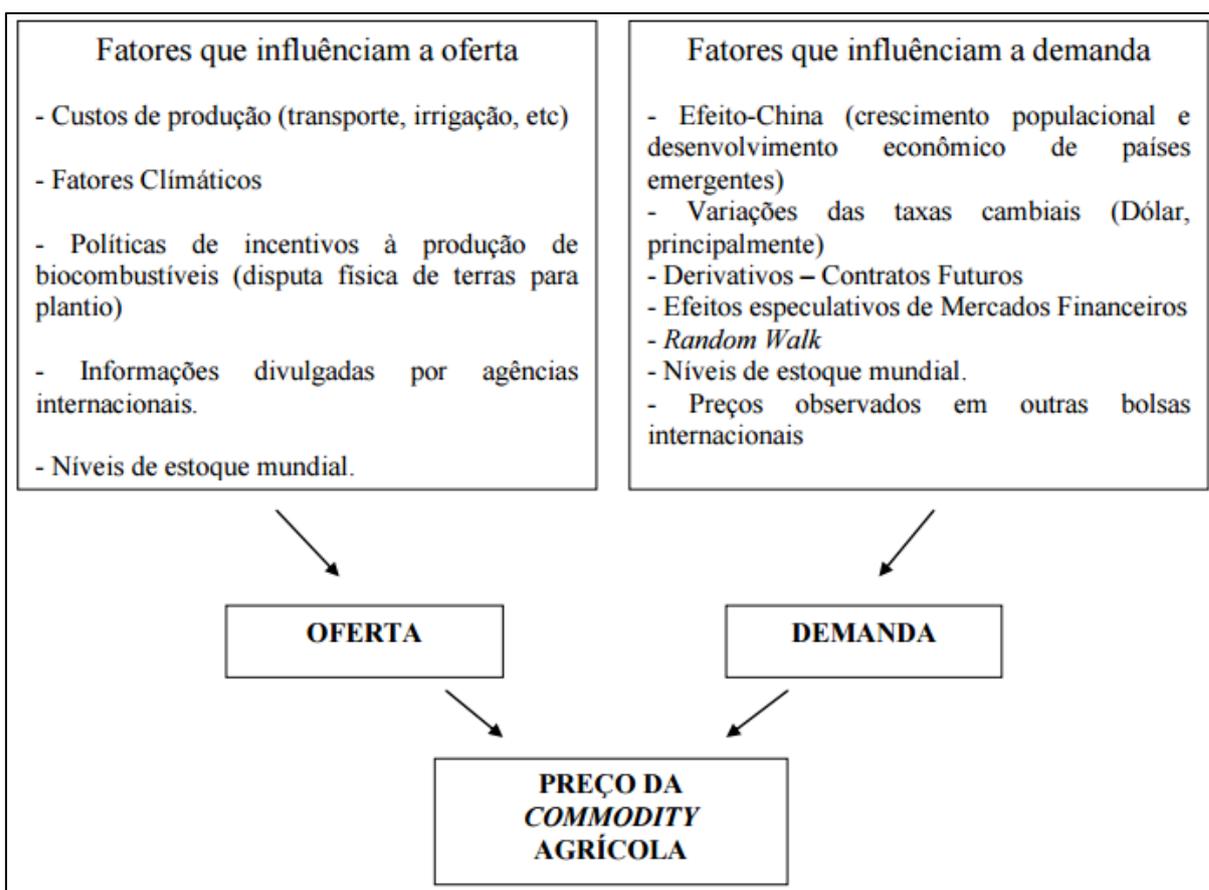


Figura 5 – Fatores influenciadores dos preços das *commodities*

Fonte: Menezes (2015)

Menezes (2015) ressalta que além de se estudar e conhecer os fatores que influenciam os preços das *commodities*, também é importante fazer uso de métodos e ferramentas que ajudem a prevê-los, para garantir que decisões importantes, tais como compra e venda, sejam tomadas de forma mais segura, envolvendo menos incertezas. Conforme o autor, a instabilidade do mercado pode vir a desestimular a produção e conseqüentemente afetar a renda do produtor rural, bem como provocar alterações nos orçamentos dos investidores e dos governos. Assim, como em qualquer empresa, os gestores do agronegócio devem se planejar, a fim de criarem possíveis cenários, variando preços, oferta e demanda, no intuito de se prepararem estrategicamente para os negócios (PEREIRA, 2009; FERREIRA et al., 2011; MENEZES, 2015).

2.2 Planejamento estratégico

De acordo Wright, Kroll e Parnell (2010), no campo da administração estratégica, a palavra “estratégia” relaciona-se aos planos da alta administração que tem por finalidade alcançar resultados consistentes através da definição e do cumprimento da missão e dos objetivos gerais da organização. Ainda, conforme os mesmos autores, a expressão “administração estratégica” pode ser compreendida como uma série de etapas as quais devem ser cumpridas pelos gestores no intuito de contextualizarem a empresa nos ambientes externo e interno de seus negócios (WRIGHT, KROLL E PARNELL, 2010). Resumidamente, as etapas que devem ser realizadas são: análise do ambiente externo da organização (oportunidades e ameaças); análise do ambiente interno (pontos fortes e pontos fracos); definição da missão organizacional e dos seus objetivos; formulação das estratégias; implantação das estratégias e controle das mesmas. Destaca-se a importância em manter esses passos inter-relacionados, pois caso algum mude, os demais são afetados (WRIGHT; KROLL; PARNELL, 2010; KICH; PEREIRA, 2014).

O planejamento estratégico, vinculado à estratégia e à administração estratégica, é uma ferramenta organizacional que tem por finalidade englobar toda a empresa, relacionando-se com todos os níveis hierárquicos e demais fatores da organização. É caracterizado por ser um processo analítico e formalizado, tendo como foco principal as tomadas de decisões estratégicas ótimas para que as empresas tenham vantagem competitiva, sejam capazes de se adaptarem às mudanças, poupem custos e tempo, para que assim possam permanecer ativas no mercado, acompanhando mudanças e tendências (MINTZBERG, 2003; KICH; PEREIRA, 2011).

As constantes mudanças mercadológicas e a alta competitividade exigem gestores cada vez mais eficientes e preparados. Conforme Moritz e Pereira (2005) deve-se buscar a combinação de mão-de-obra qualificada com a adoção de ferramentas e metodologias que visem auxiliar a elaboração e a sustentação do planejamento estratégico. Dentre essas metodologias, a técnica de planejamento por cenários vem ganhando destaque, pois tem por principal função elaborar e identificar possíveis cenários futuros, os quais permitem aos gestores das organizações a tomarem decisões com mais confiança, simulando resultados e diminuindo incertezas (MORITZ; PEREIRA, 2005; SARTURI; MASCENA, 2012).

2.2.1 Planejamento por cenários

Os cenários prospectivos são utilizados desde o início da humanidade, pois segundo Marcial e Grumbach (2002), as civilizações mais antigas buscavam através de “previsões do futuro”, amenizar riscos envolvidos nos mais variados processos de tomada de decisões. Ansof (1990) explica que a mente de cada indivíduo tende a criar histórias com base no passado, relacionando variáveis importantes com a realidade e o futuro, descrevendo as pessoas como “planejadores naturais de cenários”.

Para Schwartz (1996), os cenários são vistos como instrumentos para ordenamento das percepções dos indivíduos em relação a futuros alternativos. Ou seja, ao se construírem cenários, o objetivo não é “prever o futuro” determinando exatamente o que irá acontecer, mas sim abordar variadas situações possíveis de ocorrerem visando tomar decisões estratégicas plausíveis para cada um desses panoramas. Portanto, cenários prospectivos são ferramentas úteis que consideram alternativas possíveis de futuro através de histórias plausíveis (GODET, 2000). Segundo Godet (1993), uma previsão é uma projeção, pois envolve a probabilidade de ocorrência no futuro. Em contrapartida, Cornelius et al., (2005) diferencia cenário de previsão. Para esse autor, os cenários não são projeções, mas sim histórias coerentes que possam vir ou não a decorrer.

Enquanto a maioria dos autores une construção de cenários com o planejamento de cenários, outros os separam. Para Mietzner e Reger (2004), a construção de cenários considera as incertezas que cercam o futuro, antecedendo o processo de planejamento, sendo este último explicado como uma metodologia da administração utilizada por gestores para organizarem e articularem seus modelos mentais, auxiliando o processo de decisão (LOURENÇO JR; OLIVEIRA; KILIMNIK, 2010).

No contexto atual, o ambiente no qual as organizações estão inseridas, é descrito por Moritz e Pereira (2005) como complexo e instável. Tanto o ambiente externo como o ambiente interno são afetados diretamente por variáveis como: cultura, valores, tecnologia, políticas governamentais, concorrência, economia, questões sociais e demográficas. Assim, exige-se cada vez mais atenção e habilidade dos gestores organizacionais para lidarem com as influências do mercado em seus setores (MORITZ; PEREIRA, 2005; SARTURI; MASCENA, 2012). Apesar das divergências citadas anteriormente na conceituação de cenários entre os principais autores da área, observa-se concordância em relação aos benefícios trazidos pela técnica de cenários ao planejamento estratégico. Acredita-se que os cenários prospectivos auxiliam no processo de tomada de decisão, permitindo aos gestores

optarem por decisões de qualidade, decididas com segurança e agilidade (MORITZ; PEREIRA, 2005). Além disso, segundo Ansof (1977), os cenários permitem que as organizações se preparem para as mudanças típicas do ambiente, diminuindo fraquezas e aproveitando oportunidades.

Outro aspecto relevante referente ao planejamento por cenários é o aprendizado. Para Ansof (1990), a cultura organizacional se dá de forma mútua (empresa-indivíduo), sendo esta sempre menor que a soma total do conhecimento dos membros de uma organização. O aprendizado organizacional é muito importante, pois é através dele que a organização aprende com o passado, considerando erros e acertos. Empresas que aprendem com suas experiências, tendem a estarem mais preparadas para cenários semelhantes que possam ocorrer, ganhando vantagem competitiva em relação à concorrência despreparada.

Ansof (1990) descreve que para se garantir um planejamento por cenários de sucesso, o planejador deve criar uma ponte entre a compreensão existente na organização e as novas visões alternativas. O autor descreve que planejar algo totalmente novo pode parecer ficção para o pessoal da organização e, por outro lado, fornecer cenários já enfrentados pela empresa pode ser considerado um trabalho inútil. O foco está em encontrar o equilíbrio entre o conhecido e o novo, portanto, os cenários devem ser construídos envolvendo o conhecimento organizacional existente e novas perspectivas, para assim serem considerados interessantes e tornarem-se parte da linguagem institucional.

Para por em prática a técnica de planejamento por cenários, diversos autores da área desenvolveram métodos onde etapas são propostas para auxiliarem os gestores na construção dos cenários (GODET, 1993; SCHWARTZ, 1996; SARTURI; MASCENA, 2012). Contudo, Sarturi e Mascena (2012) afirmam que não existe uma receita única para elaboração de cenários. O processo de elaboração de cenários pode utilizar um ou mais métodos combinados, com abordagem de cunho qualitativo, quantitativo ou misto. Para os autores, a escolha do método, abordagem e estratégia para desenvolvimento dos cenários depende da organização, do seu negócio e dos seus objetivos, não existindo um padrão de construção. Godet (2000) afirma que o processo de criação dos cenários exige tempo, prática e dedicação do pessoal envolvido, mas garante que cenários planejados de maneira sólida são importantes ferramentas que auxiliam os gestores a tomarem decisões estratégicas essenciais para sobrevivência de seus negócios em um mercado caracterizado por ser dinâmico, complexo e instável.

O uso dos cenários como ferramenta estratégica nas organizações não é novidade, e segundo Godet (2000), é uma prática mundialmente difundida devido a sua importância,

serventia e resultados satisfatórios. No Brasil, grandes empresas costumam desenvolver essa técnica, mas conforme Pereira et al. (2015), ainda se trata de uma ferramenta pouco difundida entre as médias e pequenas empresas, apesar de ser simples, flexível e útil para o planejamento estratégico dos mais variados tipos e tamanhos de negócios, auxiliando nos mais diversos assuntos que necessitem de tomada de decisão.

2.2.2 O processo de tomada de decisão nas organizações

De acordo com Bertoncini et al. (2013), o processo decisório está presente no dia-a-dia das organizações, ocorrendo em todos os seus níveis, da produção até a mais alta administração. Todos os funcionários de uma empresa tomam os mais variados tipos de decisões compreendendo suas funções, desde as mais triviais, abrangendo atividades rotineiras de trabalho, até as mais complexas, envolvendo estratégias as quais podem definir o futuro de uma organização como sua sobrevivência no mercado, estagnação ou expansão.

As decisões são definidas por pessoas, as quais são formadas e afetadas por diversos fatores como o ambiente em que o indivíduo está inserido, suas percepções, crenças, família, aspectos culturais, físicos e psicológicos. Quando se lidam com decisões gerenciais que envolvem um negócio importante, por exemplo, tem-se que ter cautela, pois se trata de um processo delicado e volúvel, aonde se deve optar pela melhor alternativa, considerando-se que não existe decisão “perfeita” que garanta o sucesso de uma organização (BERTONCINI et al., 2013).

Caravantes, Panno e Kloeckner (2005) conceituam a tomada de decisão como a escolha de uma alternativa entre um conjunto de diversas alternativas. Conforme os autores, sempre há no mínimo duas alternativas envolvidas no processo de tomada de decisão, pois a opção de se permanecer como está sempre existe. Certo (2005) afirma que um indivíduo tem por finalidade no processo de decisão definir e escolher qual a melhor alternativa para seu problema, ou seja, aquela que trará maiores benefícios para sua organização.

Segundo Robbins, Judge e Sobral (2010) tem-se um problema quando o estado atual das coisas está diferente da situação desejável, portanto a tomada de decisão acontece como uma resposta a este tipo de circunstância. Para Porto (2004), o processo de escolha da melhor solução consiste em avaliar possíveis cursos de ação para posterior implantação do melhor plano. Assim, busca-se atingir o objetivo de resolução do problema ou um “caminho que leve” a organização ao desenvolvimento é escolhido.

O processo decisório é descrito por Roman, Osinski e Selig (2016) como sistemático, paradoxal e conceitual. Conforme os autores, não existe um padrão para que o processo ocorra e autores como Certo (2005), Maximiano (2009) e Robbins, Judge e Sobral (2010) informam que se trata de um procedimento passível de falhas, tendo em vista que as pessoas sofrem influências emocionais e do ambiente. Assim, algumas etapas são sugeridas pela literatura com a finalidade de nortear o processo de tomada de decisão: identificação do problema; enumeração das possíveis alternativas para solução do problema; seleção da alternativa mais benéfica; implementação da alternativa selecionada; e controle para verificação da viabilidade da alternativa escolhida (BERTONCINI et al., 2013).

Drucker (1972) classifica as decisões de duas formas: táticas e estratégicas. As táticas são as mais simples, podem ser tomadas de forma intuitiva pelo decisor. Já as decisões estratégicas são mais complexas, exigem geralmente um processo sistemático para identificação da melhor solução para uma determinada situação. Em situações problemáticas que demandam certo nível de dificuldade, a tomada de decisão deve envolver trabalho em equipe, tempo, experiência, pessoal qualificado e a adoção de métodos e técnicas que auxiliem no processo (MORITZ; PEREIRA, 2006).

Bertoncini et al. (2013) informa algumas técnicas que podem ajudar na escolha da melhor decisão, tornando o processo decisório mais claro de ser compreendido. São estas: o Diagrama de Ishikawa, o Princípio de Pareto, o *Brainstorming* e o *Brainwriting*. O Diagrama de Ishikawa é comumente conhecido como “espinha de peixe” e consiste em organizar o raciocínio em busca de uma solução através das causas do problema. O Princípio de Pareto auxilia na resolução de problemas que apresentam muitas causas, permitindo localizar as mais importantes que são responsáveis por grande parte do problema, portanto é chamado de 80-20. O *Brainstorming* trata-se da conhecida “tempestade cerebral”, onde pessoas se reúnem para discussão de um tema e discutem suas ideias de forma espontânea, visando solucionar um problema. Já no *Brainwriting* as pessoas manifestam suas ideias em papéis, sem comunicação verbal (CERTO 2005; MAXIMIANO, 2009; BERTONCINI et al., 2013).

Além destas técnicas, muitas outras podem ser usadas no intuito de tornar o processo de tomada de decisão mais fácil e seguro. O uso destes métodos é válido, pois ajudam os gestores dos mais variados setores de negócios a tomarem todos os tipos de decisões, de forma mais segura e confiante, garantindo a resolução de seus problemas independentemente do tamanho de suas organizações (MAXIMIANO, 2009; BERTONCINI et al., 2013; ROMAN; OSINSKI; SELIG, 2016).

2.2.3 O uso da Inteligência Artificial (IA) como ferramenta estratégica

De acordo com Fuchs e Fumagalli (2016), uma área que tem muito a oferecer em técnicas para auxiliar nos processos de tomada de decisão e na elaboração do planejamento estratégico das empresas é o campo da Inteligência Artificial (IA). Acima da capacidade humana, a IA é capaz de solucionar problemas de maneira rápida e ótima. Segundo Nikolopoulos (1997), a Inteligência Artificial é um campo formado por diversas áreas, como a computação, engenharia, psicologia, matemática e cibernética, e seu foco principal é o de solucionar problemas, através de sistemas inteligentes, com desempenho igual ou superior ao de um especialista humano. Arariboia (1988) explica que as técnicas de Inteligência Artificial são criadas no intuito de imitar os mecanismos na natureza humana através do uso de computadores, mas não se limitam em atingir apenas o biologicamente aceitável.

Nos anos 80, conforme Primak (2009) começaram a aparecer técnicas de inteligência artificial aplicadas para o mundo dos negócios, ficando essa área conhecida como *Business Intelligence* (BI). Tal termo tem por tradução “inteligência de negócios” e relaciona-se com o processo de coleta, organização, análise e compartilhamento de informações relevantes utilizadas na gestão de negócios. As técnicas do BI são aplicadas como suporte ao apoio de decisão em áreas como *marketing*, finanças, produção e atendimento ao cliente (FORTULAN; GONÇALVES FILHO, 2005, AMARAL, 2010).

Dentre os benefícios do uso da IA nos negócios, Das (2016) destaca a possibilidade de criar cenários estratégicos através do tratamento e simulação de variáveis, fornecendo aos tomadores de decisão dados precisos, que quando transformados em informação por especialistas, facilitam e tornam a tomada de decisão mais ágil, segura e eficaz.

Para Fuchs e Fumagalli (2016) a inteligência artificial é viável estrategicamente para as organizações, pois permite analisar padrões e antecipar decisões; proporciona uma análise de cenários com agilidade e interatividade; e facilita a tomada de decisão através de dados tratados, antes mesmos de serem requeridos. Ainda, segundo o autor, a automatização inteligente pode diminuir custos, aumentar lucros e satisfazer os clientes. Contudo, conforme Robinson (2005), tais vantagens somente são alcançadas com mão-de-obra qualificada e boas práticas de gestão. Dentre às técnicas de IA utilizadas como apoio à decisão, tem-se: o Data Mining, o Data Warehouse, o Data Marts e as Redes Neurais Artificiais (MOURA; ANDRADE; KIKUCHI, 2005; SANTOS; RAMOS, 2006; AMARAL, 2010; VALENÇA, 2010).

2.3 As Redes Neurais Artificiais (RNAs)

2.3.1 Histórico, conceitos e arquitetura das redes

As redes neurais artificiais (RNAs) ou simplesmente redes neurais são conjuntos de modelos matemáticos com capacidade para aprendizagem de padrões complexos de informação para generalização, os quais se baseiam no funcionamento do neurônio biológico. O cérebro humano é composto por uma rede formada por cerca de 10 bilhões de neurônios que se interconectam e se comunicam via ligações sinápticas. Conforme se pode observar na Figura 6, o neurônio humano é formado por três partes: os dendritos, o corpo celular e o axônio (PERETTO, 1992; HARVEY, 1994; VENUGOPAL; BAETS, 1994).

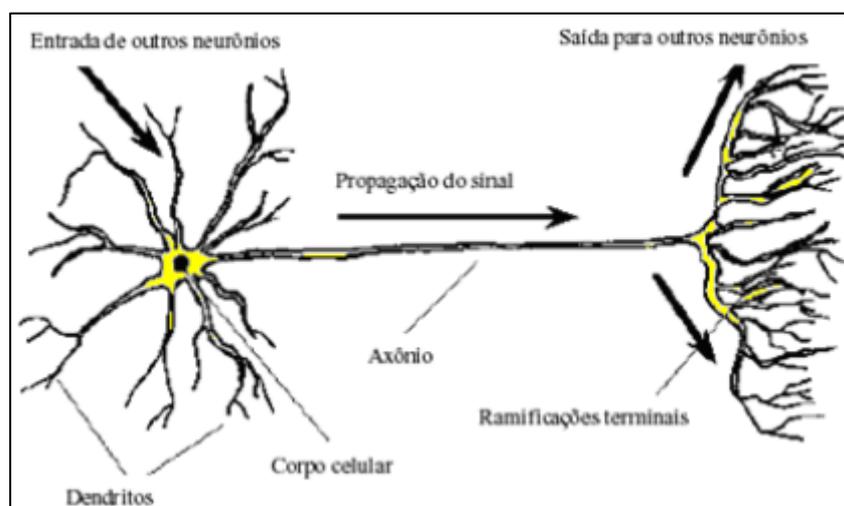


Figura 6 – Neurônio biológico
Fonte: Finocchio (2014)

Os dendritos são os responsáveis por capturar as informações advindas do ambiente externo e enviá-las para o corpo celular; o corpo celular é capaz de processar tais informações e gerar um sinal constante por todo o axônio; o axônio envia tal estímulo para os dendritos de outros neurônios que estão conectados, ocorrendo assim as sinapses (BRAGA; CARVALHO; LUDEMIR, 2000; VALENÇA, 2010).

Conforme Valença (2010), a intensidade do estímulo recebido por um neurônio depende do limiar excitatório. Quando um neurônio recebe um estímulo muito pequeno, o qual não alcança o limiar excitatório, o impulso nervoso não é gerado, não ocorrendo a sinapse. Quando esse limiar é ultrapassado, o impulso ocorre da mesma forma, independente da intensidade do estímulo. Segundo o autor, este fenômeno é descrito pela lei do Tudo ou Nada. Tendo como base o funcionamento do neurônio biológico e a Lei do Tudo ou Nada,

McCulloch e Pitts, em 1943, propuseram a primeira representação do neurônio artificial, apresentada na Figura 7.

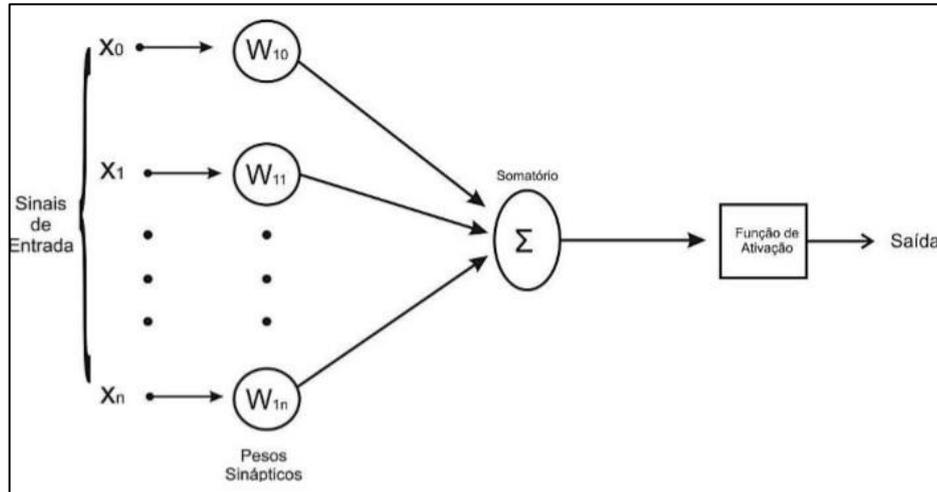


Figura 7 - Representação de um neurônio artificial
Fonte: Ferraz (2013)

Como se pode observar na Figura 7, o neurônio matemático apresenta “n” Sinais de Entrada (X_0, X_1, \dots, X_n), os quais representam os dendritos, e um terminal de Saída, em analogia ao axônio. O neurônio artificial é formado por quatro elementos, sendo estes: pesos sinápticos, somatório, função de ativação e função de transferência. Os pesos sinápticos ($W_{10}, W_{11}, \dots, W_{1n}$), ou sinapses, tem a função de ponderar um sinal de intensidade para cada entrada do neurônio. O somatório é capaz de agregar os dados da entrada ponderados de acordo com seus pesos. A função de ativação é composta por uma decisão do próprio neurônio sobre o que fazer com a informação fornecida pelo somatório. E, por fim, a função de transferência fornece a saída da informação, ou seja, o limiar lógico entendido pelo neurônio (HAYKIN, 2001; VALENÇA, 2010).

O limiar da função de ativação pode ser substituído por um peso alternativo, denominado bias, o qual permite ao modelo atingir um maior grau de liberdade, pois age como um erro contínuo. A Figura 8 demonstra um neurônio artificial com bias, onde “b” é a bias a qual representa o limiar de ativação do neurônio, “p” é a entrada do sinal, “w” é o peso, “F” é a função de ativação do neurônio e “a” o valor de saída (FINOCCHIO, 2014).

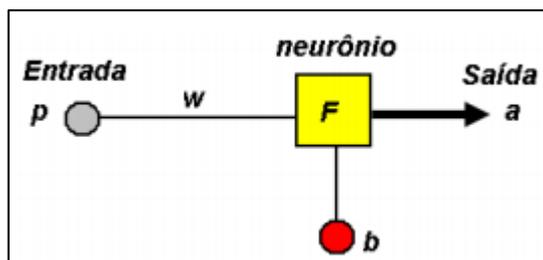


Figura 8 – Representação de um neurônio artificial com bias
Fonte: Finocchio (2014)

Assim como o cérebro humano apresenta uma rede de neurônios, uma rede neural é formada por um conjunto de simuladores de neurônios conectados, na qual a força de intensidade dessas conexões pode variar a informação de saída, permitindo que ocorra aprendizado. O aprendizado da rede ocorre através de exemplos, onde o algoritmo de aprendizado é responsável por adaptar os parâmetros da rede, no intuito de que em um número finito de interações do algoritmo obtenha-se a solução desejada de saída. Basicamente, além de se definir a arquitetura da rede, a rede neural artificial apenas necessita como informação as variáveis de entrada e saída ou apenas entrada, e assim, através de treinamento/aprendizado, é capaz de estimar a resposta esperada, com certo erro envolvido (BRAGA; CARVALHO; LUDEMIR, 2000).

O neurônio artificial proposto por McCulloch e Pitts foi criticado por apresentar algumas limitações quando aplicado para interpretação de sentenças complexas e negativas seguidas, principalmente em relação à operação XOR (ou-exclusivo), além da ausência de um método que permitisse o aprendizado. No intuito de complementar o modelo do neurônio matemático, Rosenblatt, em 1958, criou o modelo mais simples de rede neural, conhecida como *Perceptron*. A rede *Perceptron* é composta por uma camada de entrada e uma camada de saída, estando estas camadas ligadas pelos pesos sinápticos. Ao contrário do neurônio matemático que faz uso de valores binários e polares, a *perceptron* utiliza valores contínuos tanto para as entradas como para os pesos, o que acabou por tornar o modelo mais útil para aplicação, geralmente no reconhecimento de padrões. Apesar de mostrar-se mais sensível do que o modelo de McCulloch e Pitts, o problema XOR persistiu, sendo corrigido pelo modelo *Multilayer Perceptron (MLP)*. O modelo *MLP*, ou *Perceptron* Multicamadas, é composto por pelos menos duas camadas de neurônios, ao contrário da camada única utilizada pelos modelos descritos anteriormente (PERETTO, 1992; HARVEY, 1994). A Figura 9 demonstra a rede *perceptron*, enquanto a Figura 10 apresenta uma rede *Multilayer*.

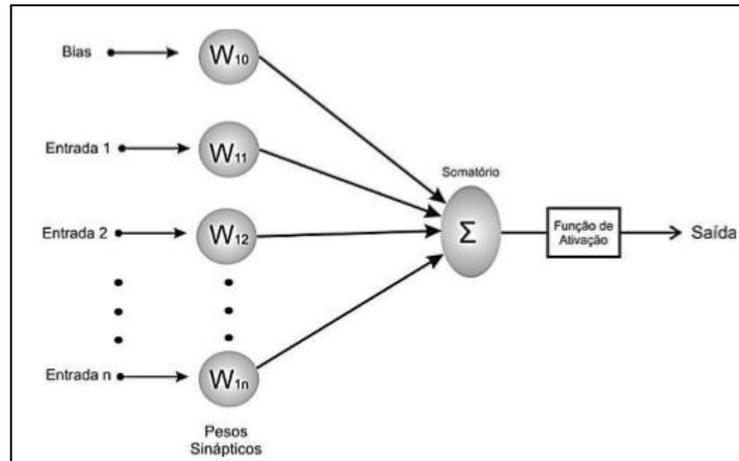


Figura 9 – Estrutura da *Perceptron*
Fonte: Ferraz (2013)

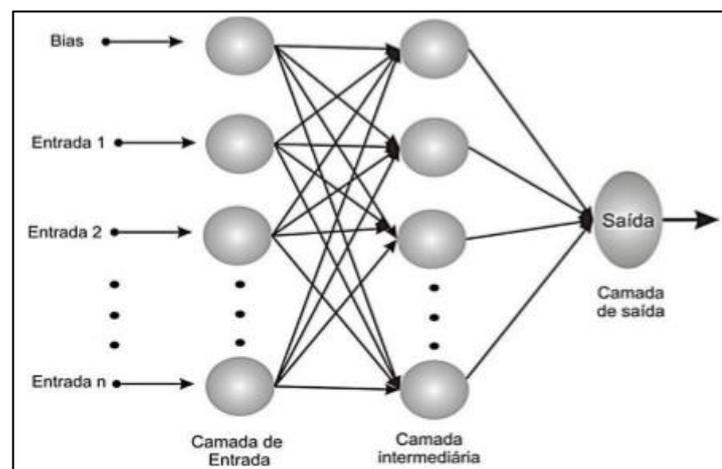


Figura 10 – Estrutura da *Multilayer Perceptron*
Fonte: Ferraz (2013)

De maneira geral, como se pode observar na Figura 11, a arquitetura de uma rede neural artificial é composta por três camadas: a camada de entrada, a camada intermediária e a camada de saída.

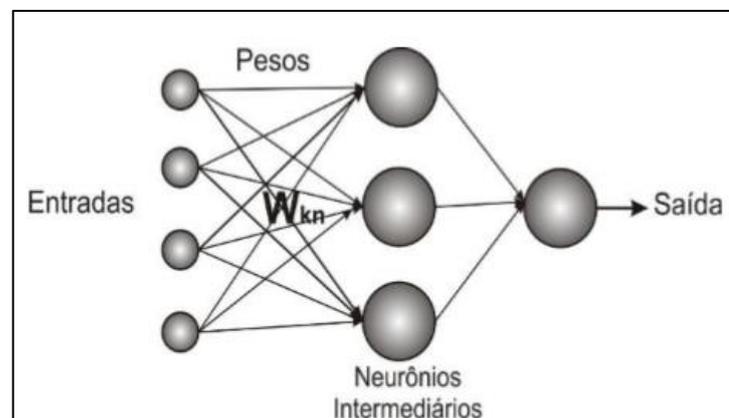


Figura 11 – Arquitetura de uma RNA
Fonte: Ferraz (2013)

A camada de entrada é composta pelas informações de entrada da rede, ou seja, onde são fornecidos os dados do modelo. A camada intermediária, também conhecida como oculta ou escondida, é a camada na qual se dá a maior parte do processamento da rede, envolvendo as conexões ponderadas, treinamento e aprendizado. A camada de saída conclui e apresenta o resultado final (PERETTO, 1992).

A definição da arquitetura de uma rede refere-se à distribuição dos neurônios e varia de acordo com a sua finalidade de aplicação. A literatura fornece diversas sugestões de arquiteturas de redes, mas é através da análise do problema e via experimentação que o pesquisador deve definir informações da estrutura da rede, tais como: tipo de conexão, conectividade, número de camadas, número de neurônios de cada camada e algoritmo de treinamento (BRAGA; CARVALHO; LUDEMIR, 2000).

Com relação ao tipo de conexão entre os neurônios, esta pode ser *feedforward* (acíclica) ou *feedback* (cíclica). A conexão *feedforward* é muito usada para reconhecimento e classificação de padrões e ocorre quando a saída de um neurônio na “i-ésima” camada de uma rede neural não pode ser utilizada como entrada nos nós em camadas que apresentam índice menor ou igual a “i”. Já na conexão do tipo *feedback*, também chamadas de redes recorrentes, ocorre o contrário. A saída de algum neurônio da “i-ésima” camada é usada como entrada de nós em camadas com índice igual ou menor que “i”, formando um ciclo (BRAGA; CARVALHO; LUDEMIR, 2000). A Figura 12 apresenta a estrutura de uma rede *feedforward*, enquanto a Figura 13 representa um rede com conexão do tipo *feedback*.

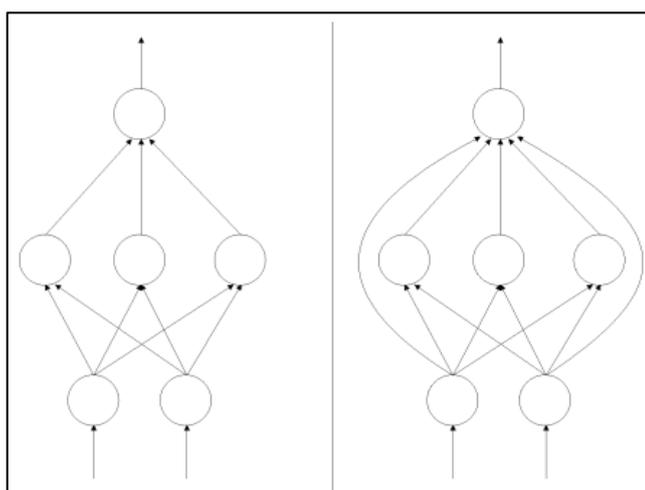


Figura 12 – Rede com conexão do tipo *feedforward*
Fonte: Carvalho; Ludemir (1998)

Como exemplo de redes do tipo *feedforward* tem-se: *Madaline*, *Perceptron* Multicamadas e Função Base Radial (RBF) (FERRAZ, 2013).

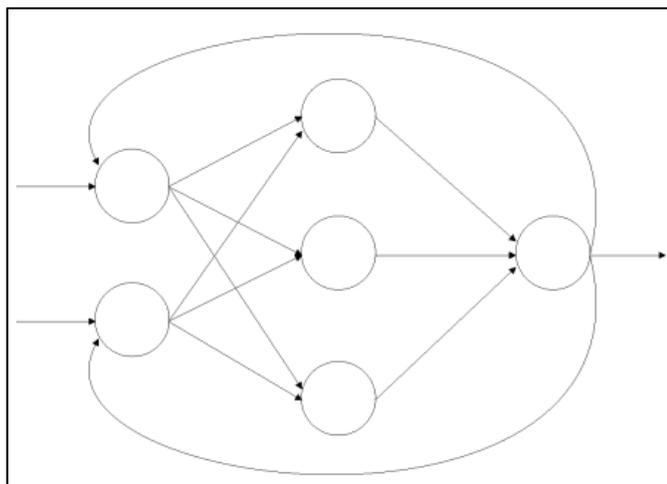


Figura 13 – Rede com conexão do tipo *feedback*
 Fonte: Carvalho; Ludemir (1998).

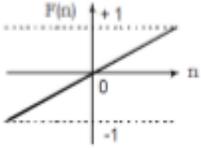
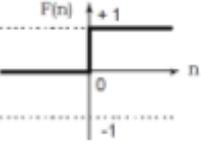
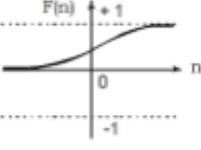
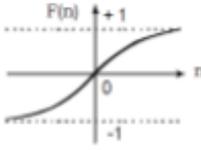
As redes recorrentes são usadas em sistemas dinâmicos, memória associativa, previsão e estimação, previsão e controle. Como exemplo tem-se o modelo Hopfield e *Perceptron* com retroalimentação (FERRAZ, 2013).

Quanto ao tipo de conectividade de uma rede, ela pode ser de dois tipos conforme Braga, Carvalho e Ludemir (2000): fracamente conectada, quando os nós de uma camada não estão ligados a todos os nós da camada seguinte e; completamente conectada, onde cada um dos nós de uma camada está conectado a todos os outros nós da camada posterior. De acordo com o número de camadas apresentadas por uma rede neural, ela pode ser classificada como uma rede de camada única ou como uma rede de múltiplas camadas. Ou seja, no primeiro caso existe apenas uma camada de neurônio entre a entrada e a saída e, no segundo caso, existe mais de uma camada (BRAGA; CARVALHO; LUDEMIR, 2000; REINKE, 2008).

Dentre as decisões que devem ser tomadas para definição da rede, está a escolha das funções de ativação e transferência. A função escolhida para ativação é a que irá determinar o sinal que será transmitido de um neurônio para os demais que se conectam a ele (VALENÇA, 2010). De acordo com Haykin (2001) as funções mais utilizadas são: linear, degrau, sigmoide logística e tangente hiperbólica. Já para Reinke (2008) e Ferraz (2013), as funções sigmoide logística e tangente hiperbólica são as mais adotadas, pois apresentam melhores resultados nas redes neurais artificiais.

A Tabela 4 apresenta as funções, com suas devidas equações e representações gráficas, onde “n” é o valor da variável.

Tabela 4 – Funções de ativação

Função	Equação	Representação gráfica
Linear	$f(n) = n$	
Degrau	$f(n) = \begin{cases} 1, \forall n \geq 0 \\ 0, \forall n < 0 \end{cases}$	
Sigmoide logística	$f(n) = \frac{1}{1 + e^{-n}}$	
Tangente Hiperbólica	$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	

Fonte: adaptado de Ferraz (2013).

A função linear é a função que não apresenta limite para a saída da rede, sendo usada para manter dados de entrada e saída armazenados. Neurônios com esse tipo de função funcionam como aproximadores lineares. Na função degrau, os neurônios tomam decisões do tipo binárias, tendo apenas duas opções como saída, o que caracteriza esse neurônio como classificador. As funções sigmoide logística e tangente hiperbólica são do tipo limitadas, onde os valores de saída da sigmoide logística variam entre 0 e +1, nunca atingindo estes valores extremos, enquanto os valores da função tangente hiperbólica variam num intervalo entre -1 e +1 (SILVA et al., 2004). Segundo Reinke (2008) e Ferraz (2013) estas últimas duas funções são favoráveis de serem usadas nas RNAs, pois são funções semi-lineares, simétricas, contínuas, deriváveis em suas extensões, crescentes e limitadas por assíntotas horizontais.

Com relação ao algoritmo de aprendizado da rede, Braga, Carvalho e Ludemir (2000) afirmam que não existe um único algoritmo de aprendizado, cada um apresenta suas vantagens e desvantagens. Segundo os autores, o algoritmo deve ser escolhido de acordo com o tipo de problema a ser resolvido e estes algoritmos basicamente se diferenciam pelo modo com que realizam os ajustes dos pesos. Os algoritmos podem ser classificados de duas formas de acordo com seu aprendizado: supervisionado ou não supervisionado. No aprendizado supervisionado os valores de entrada e saída são informados à rede, enquanto no aprendizado

do tipo não supervisionado, os valores da saída são desconhecidos (HAYKIN, 2001; VALENÇA, 2010).

Atualmente, a topologia de rede neural mais empregada é do tipo *Feedforward*, *Multilayer Perceptron*, com algoritmo de aprendizado *Backpropagation* (HAYKIN, 2011; MAKRIS et al., 2017). Diversos autores afirmam que quando se tratam de redes *MLP*, as quais apresentam aprendizado do tipo supervisionado, o algoritmo *backpropagation* é muito eficiente e o mais utilizado (BRAGA; CARVALHO; LUDEMIR, 2000; REINKE, 2008; VALENÇA, 2010; HAYKIN, 2011). Esse algoritmo realiza seu aprendizado cumprindo dois passos: primeiro seus sinais propagam-se no sentido progressivo, da camada de entrada para a de saída, calculando o valor da saída e o erro, com pesos mantidos fixos; o segundo passo consiste em propagar os erros no sentido inverso, da cama de saída para a de entrada, onde os pesos são ajustados. Estes dois processos são conhecidos por *Forward* e *Backward*, respectivamente, os quais são representados na Figura 14.

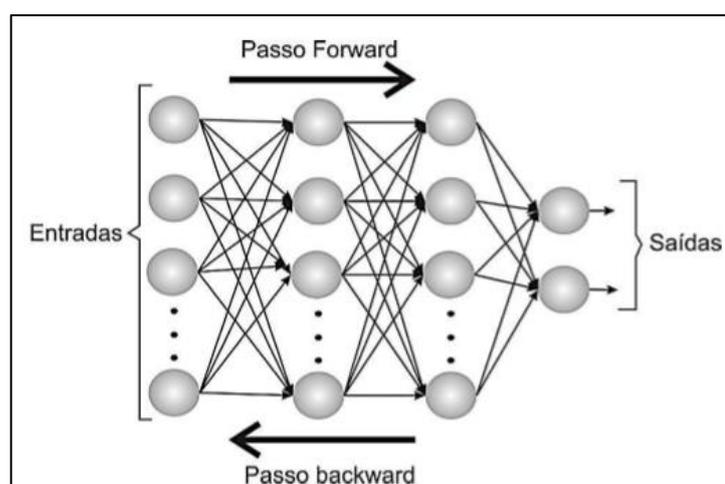


Figura 14 – Fluxo do algoritmo *backpropagation*
Fonte: Ferraz (2013)

A estratégia utilizada pelo algoritmo *backpropagation* consiste na Regra Delta generalizada e baseia-se na seguinte sequência de processos, conforme Finocchio (2014). Primeiramente, um padrão de valores é informado à camada de entrada, o processo resultante é propagado pela rede através das camadas, até uma resposta ser produzida pela camada de saída. É então feita a comparação entre o valor obtido e o valor desejado, caso o valor não esteja correto, o erro resultante é calculado. Após isso, o erro é propagado desde a camada de saída até a camada de entrada, havendo modificações nos valor dos pesos das camadas internas conforme a retro-propagação do erro. Enquanto um valor de saída aceitável não for obtido, o processo se repete, até que o erro médio quadrático (EMQ) das saídas tenha um

valor aceitável. Resumidamente, o algoritmo *backpropagation* funciona ajustando os valores dos pesos de acordo com o erro quadrático médio.

Uma desvantagem advinda do uso deste algoritmo foi o seu funcionamento computacional lento. Visando contornar este problema, técnicas de otimização estão sendo aplicadas para melhorar seu desempenho, com destaque para o algoritmo de Levenberg-Marquardt. Este algoritmo incorpora-se ao *backpropagation*, assegurando uma *performance* de 10 a 100 vezes mais rápida (FINOCCHIO, 2014). Além da Regra Delta de Widrow, outras leis de aprendizado podem ser utilizadas, como o Princípio de Aprendizado de Hebb, a Lei de Hopfield e a Lei de Aprendizado de Teuvo Kohonen (BRAGA; CARVALHO; LUDEMIR, 2000; VALENÇA, 2010).

2.3.2 Modelando as RNAs

A formulação de uma rede neural requer uma sequência de passos básicos propostos por Reinke (2008). O primeiro passo é a definição do problema que será estruturado; o segundo passo consiste em selecionar os dados de entrada/saída; no terceiro passo ocorre o treinamento da rede, mas antes se deve definir o algoritmo de treinamento, o número de camadas escondidas, o número de neurônios e o tipo de conexão. Obtendo-se sucesso no treinamento, deve-se passar para o quarto passo, onde a rede é testada e por fim, no quinto passo, a mesma é validada e executada. Caso um resultado não satisfatório seja obtido no passo três, deve-se permanecer nesta etapa realizando modificações na estrutura da rede visando melhorar os resultados via experimentação (VALENÇA, 2010; FERRAZ, 2013).

Valença (2010) apresenta cinco passos para modelagem de uma RNA, semelhantes aos propostos por Reinke (2008), sendo estes: coleta e divisão de dados, seleção das variáveis de entrada e saída, definição da arquitetura da rede, treinamento e validação do desempenho. A coleta de dados baseia-se em encontrar os dados referentes ao problema abordado que servirão como amostra. Nesta etapa é muito importante a seleção e coleta de dados confiáveis, a fim de minimizar erros que influenciem o desempenho final do modelo. O processo de divisão dos dados é composto por três subconjuntos independentes de dados: um conjunto para ajuste de pesos ao longo do treinamento, um conjunto para validação e um conjunto para verificação (HAYKIN, 2001; REINKE, 2008; VALENÇA, 2010). Valença (2010) indica que 50% do total da amostra coletada pode ser utilizada para treinamento, 25% para validação e 25% para verificação do modelo. Já para Finocchio (2010), um subconjunto de treinamento

pode variar entre 60% e 90% do total da amostra, enquanto o subconjunto de teste (validação/verificação) utiliza de 10% a 40% dos dados amostrais.

A seleção das variáveis de entrada geralmente depende do problema trabalhado e do conhecimento do modelador. Além da literatura de apoio, algumas técnicas estatísticas podem ser manipuladas no intuito de contribuir na identificação de variáveis como a correlação, a técnica de *stepwise*, as redes polinomiais, entre outras. Estas técnicas são úteis quando se tratam de modelos lineares, deixando a desejar em aplicações que envolvem modelos não-lineares. (VALENÇA, 2005). Quanto maior a quantidade de dados relevantes, maior a acurácia da rede, lembrando que quanto mais dados de entrada o modelo tiver, maior sua complexidade e o tempo requerido. Portanto, Valença (2005) destaca que dados irrelevantes podem prejudicar o resultado da rede neural.

Além dos cuidados com a coleta e divisão dos dados de entrada, é necessário o processo de normalização desses dados para que não haja discrepância entre os diferentes intervalos das variáveis. Os valores devem ser normalizados proporcionalmente com a função de ativação, para que estejam entre os limites dessa função (FERRAZ, 2013). Os tipos de normalização mais empregados e suas equações são apresentados na Tabela 5, onde: “y” é o valor do dado normalizado; “ x_i ” é o valor do dado original; “ x_{min} ” é o valor mínimo da variável; “ x_{max} ” é o valor máximo da variável; “ \bar{x} ” é o valor médio da variável, “a” e “b” são os limites e “s” o desvio-padrão.

Tabela 5 – Tipos de normalização

Tipo de normalização	Equação
Transformação linear	$y = \frac{(b - a)(x_i - x_{min})}{x_{max} - x_{min}} + a$
Normalização estatística	$y = \frac{x_i - \bar{x}}{s}$
Normalização simples	$y = \frac{x_i}{x_{max}}$

Fonte: Adaptado de Ferraz (2013)

A definição da arquitetura de uma rede *MLP* envolve basicamente a quantidade de neurônios nas camadas intermediárias. Esta é uma decisão que deve ser feita com cuidado, pois segundo Valença (2005), quanto maior a quantidade de neurônios, maior a capacidade de mapeamento não-linear da rede. Portanto, se houverem poucos neurônios, a rede neural fica subajustada (*underfitting*), perdendo sensibilidade na aproximação dos valores. Por outro

lado, caso haja muitos neurônios, a rede se torna superajustada (*overfitting*), perdendo sua capacidade de generalização dos dados.

Alguns autores afirmam que o número de neurônios é mais bem definido por tentativa e erro, verificando qual escolha traz o menor erro envolvido (HAYKIN, 2001; REINKE, 2008; VALENÇA, 2010). Contudo, existem algumas propostas que auxiliam a estimar o número de neurônios, ou ao menos, ajudam na aproximação do melhor valor, tais como o método de Kolmogorov, o método de Fletcher-Gloss e o método de Weca (FINOCCHIO, 2010). As equações propostas por esses métodos são apresentadas na Tabela 6.

Tabela 6 – Métodos para estimação do número de neurônios

Método	Equação	Onde:
Kolmogorov	$n = 2 \times n_1 + 1$	n_1 – representa o número de variáveis de entradas da rede.
Fletcher-Gloss	$2 \times \sqrt{n_1} + 1 \leq n \leq 2 \times n_2 + 1$	n_1 – representa o número de variáveis de entradas da rede; n_2 – representa o número de neurônios de saída da rede; n – quantidade de neurônios.
Weca	$n_1 = \frac{n + n_c}{2}$	n_1 – representa o número de variáveis de entradas da rede; n – quantidade de neurônios; n_c – número de classes.

Fonte: Adaptado de Finocchio (2010)

Segundo Valença (2005), na etapa de treinamento da rede, o valor do erro médio quadrático é o mais usado como parâmetro para minimizar o erro. Como benefícios de utilização do valor do erro médio quadrático no treinamento, tem-se: facilidade de cálculo do valor, métrica que penaliza grandes erros e cálculo simples das derivadas parciais em relação aos pesos. Geralmente, no início do treinamento o EMQ apresenta valor alto, tendendo a diminuir e estabilizar com o número de cenários treinados.

No que se refere ao processo de verificação do desempenho da rede neural, os valores de erros mais utilizados são: Erro Médio Quadrático (EMQ), Erro Médio Absoluto (EMA), Erro relativo Percentual Médio Absoluto (EPMA), Erro padrão de Predição (EP), Coeficiente de Eficiência (CE) e o coeficiente de determinação (r^2) (VALENÇA, 2005; FERRAZ, 2013).

2.3.3 Estudos no Brasil sobre as RNAs

Apesar da necessidade do cumprimento de passos e de conhecimentos matemáticos e estatísticos, as redes neurais artificiais são ferramentas estratégicas poderosas que, segundo Freitas e Silva (1999), Paliwal e Kumar (2009), Valença (2010), e Makris et al. (2017), podem ter seu uso estendido nas mais diversas áreas da ciência, sem se limitar a um campo específico. Conforme Paliwal e Kumar (2009), a adoção a este método é cada vez mais frequente, pois as redes permitem generalizar o conhecimento adquirido, trabalhar de forma otimizada com dados, e são flexíveis, mostrando-se úteis na resolução dos mais variados tipos de problemas. Dentre as áreas em que as RNAs são empregadas, evidencia-se a medicina, a engenharia, a área de *marketing* e finanças.

Em estudo bibliométrico considerando as plataformas *SPELL* e *CAPEL*, entre os anos de 2004 e 2013, um total de 126 artigos publicados no Brasil foram encontrados, os quais desenvolveram as redes neurais em seu conteúdo. Neste mesmo estudo, com relação às áreas de aplicação das pesquisas, o campo de aplicações gerais apresentou 59 artigos, engenharia e manufatura 24 artigos, contabilidade e finanças 22 artigos, saúde e medicina 17 artigos e apenas 4 artigos envolvendo a área de *marketing* (SANTOS et al., 2016). Em *review* publicado por Paliwal e Kumar (2009), foram apresentados 73 trabalhos internacionais abordando as RNAs, com destaque para a área das finanças, onde o foco deste estudo foi o de comparar o desempenho das RNAs com outras técnicas estatísticas. Em geral, segundo os autores da pesquisa, as redes neurais mostraram-se uma técnica útil para a previsão e classificação de problemas. Outro aspecto identificado em ambos os trabalhos de Paliwal e Kumar (2009) e Santos et al. (2016) foi a migração do uso das RNAs para outras áreas, além das finanças. Nos anos 2000, as RNAs tornaram-se ferramentas muito utilizadas no ambiente do mercado de ações, no intuito de auxiliar na tomada de decisões financeiras.

Santos et al. (2016) afirmam que ao analisar o período de tempo considerado de 10 anos, observou-se um aumento de 30% nas publicações sobre as redes neurais no Brasil. Ao se pesquisar os termos “redes neurais”, “redes neuronais” e “redes neurais artificiais” nas bases *SPELL* e *Scopus*, um total de 124 artigos foram encontrados, publicados entre os anos de 1990 e 2016. A Figura 15 demonstra o número de publicações por ano no Brasil, com base nas plataformas *SPELL* e *Scopus*.

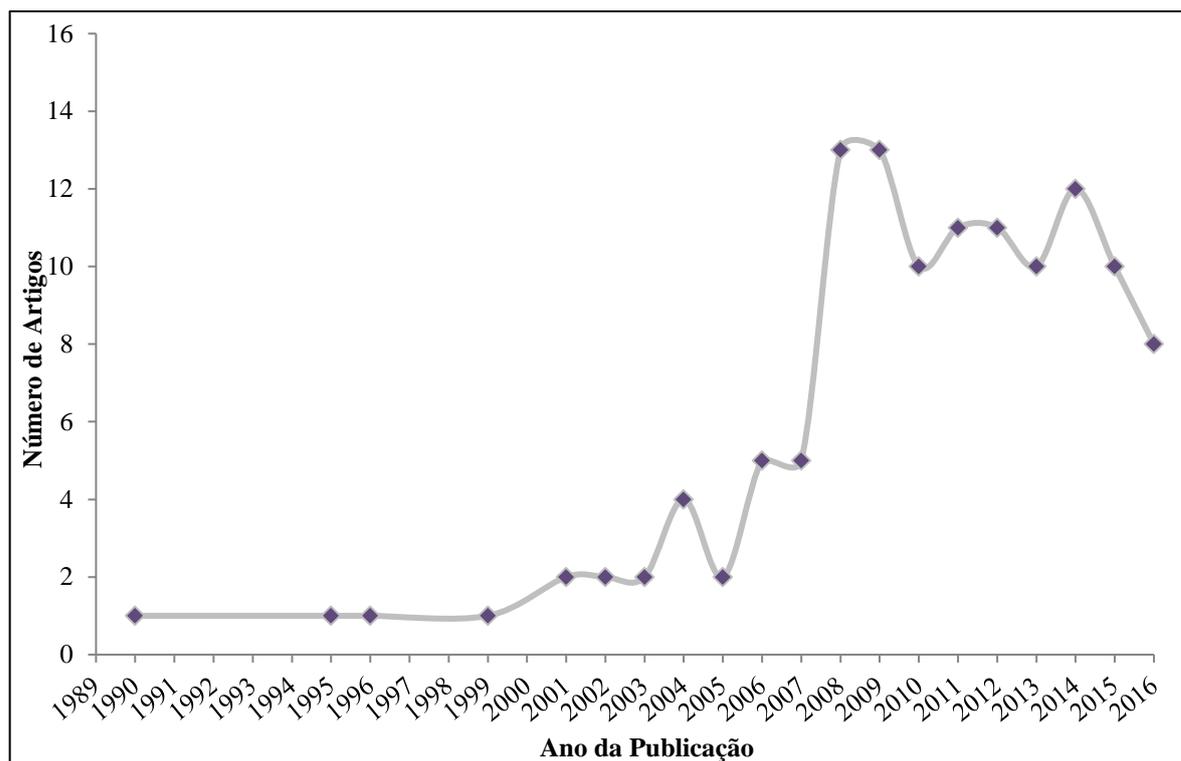


Figura 15 - Número de publicações por ano abordando RNAs
 Fonte: Disconzi et. al (2017).

A Figura 15 demonstra que houve um aumento nas pesquisas sobre redes neurais a partir do ano de 2007, com destaque para a área de finanças, indo ao encontro do estudo de Paliwal e Kumar (2009). A partir deste ano, o nível de publicações manteve-se constante, variando de 10 a 13 artigos por ano. As áreas de destaque encontradas nas bases *SPELL* e *Scopus* foram: mercado financeiro, agricultura, *marketing*, solos, elementos químicos e transformadores de potência (DISCONZI et. al, 2017).

No estudo de Santos et al. (2016), a área das ciências agrárias e agricultura foram colocadas no setor de aplicações gerais, o que segundo os autores, colaborou para o destaque desta área em publicações. No artigo de Paliwal e Kumar (2009), estudos que envolveram previsão de preços na área do agronegócio foram colocados na área das finanças, setor que também se evidenciou. Portanto, ao analisarem-se estes estudos, verifica-se que as redes neurais artificiais vêm ganhando espaço de aplicação nos mais variados setores, tanto no Brasil como a nível internacional, demonstrando bons resultados principalmente como técnica para análise de finanças e ferramenta estratégica para apoio à decisão.

Tendo em vista o objetivo deste trabalho, o Quadro 1 traz artigos encontrados nas plataformas *SPELL*, *Scopus*, *CAPES* e *Scielo* que desenvolveram as redes neurais artificiais para previsão de preços envolvendo *commodities* no Brasil.

Quadro 1 - Artigos que utilizam as RNAs para previsão de preços de *commodities*

Título	Autores	Ano de publicação	Objetivo	Commodities
Aplicação de análise multivariada e redes neurais para previsão de preços no mercado agrícola brasileiro	PINHEIRO, C.; SENNA, V.	2017	Aplicar a metodologia proposta por PINHEIRO & SENNA (2015) a um conjunto de produtos agrícolas negociados no Brasil.	Açúcar, algodão, milho e soja.
Modelagem e prognose do preço de carvão usando um sistema neuro-fuzzy	ARAÚJO JR, C.; SILVA, L.; SILVA, M.; LEITE, H.; VALDETARO, E.; DONATO, D.; CASTRO, R.	2016	Avaliar o uso do sistema neuro-fuzzy para modelagem e previsão de preços do carvão vegetal em Minas Gerais.	Carvão vegetal
Previsão de Preços Através da Análise Espectral Multivariada: Evidências para Commodities da BM&Fbovespa	PINHEIRO, C.; SENNA, V.	2016	Realizar previsões dos preços de um grupo de commodities através do modelo espectral de análise multivariada e compará-las com aquelas obtidas por modelos clássicos de previsão e de redes neurais.	Etanol, boi gordo, milho, café e soja
Previsão de preços para contratos futuros agropecuários através de redes neurais e análise espectral multivariada	PINHEIRO, C.; SENNA, V.; MATSUMOTO, A.	2016	Comparar os resultados preditivos da combinação do modelo de Análise Espectral Singular Multivariada (AESM) e o modelo de Redes Neurais Artificiais (RNA) com os resultados obtidos por modelos clássicos de previsão e de redes neurais para preços dos contratos futuros agropecuários comercializados na BM&FBOVESPA.	Café, etanol, boi, milho e soja
Stochastic models of forecasting prices of soybeans in Brazil	FELICIANI, A.; SOUZA, A.; SOUZA, F.	2015	Descrever e prever por meio de modelos estocásticos a média e a variabilidade da série de preços de tonelada de soja no Brasil	Soja

			no período de 2000 a 2011.	
Uso de redes neurais artificiais para a prognose dos preços do carvão vegetal em Minas Gerais	COELHO JR, L.; REZENDE, J.; BATISTA, A.; MENDONÇA, A.; LACERDA, W.	2013	Fazer a prognose para o ano de 2007 da série de preços do carvão vegetal, utilizando as Redes Neurais Artificiais.	Carvão vegetal
Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio	FERREIRA, L.; MOURA, G.; BORENSTEIN, D.; FISCHMANN, A.	2011	Prever o comportamento de diferentes commodities agrícolas: soja, trigo, boi gordo e milho.	Soja, milho, trigo e boi gordo.
Previsão de preços de commodities com modelos ARIMA-GARCH e redes neurais com ondaletas: velhas tecnologias – novos resultados	LIMA, F.; KIMURA, H.; ASSAF NETO, A.; PERERA, L.	2010	Explorar a aplicação de uma metodologia capaz de decompor uma série temporal via ondaletas, conjuntamente com os modelos econométricos e de redes neurais para a previsão de variáveis.	Soja
Precificação do etanol utilizando técnicas de redes neurais	SOBREIRO, V.; ARAÚJO, P.; NAGANO, M.	2009	Comparar o desempenho das redes neurais artificiais (RNAs), usando a arquitetura Perceptron multicamadas, com o do método ARIMA para previsão do preço do Etanol.	Etanol
Previsão de preço futuro do boi gordo na BM&F: uma comparação entre modelos de séries temporais e redes neurais	GAIO, L.; CASTRO JR, L.; OLIVEIRA, A.	2007	Comparar modelos de previsão de preço, para o mercado de boi gordo na Bolsa de Mercadorias & Futuros (BM&F), utilizando modelos baseados em redes neurais e ferramentas estatísticas de modelagem de séries heteroscedásticas.	Boi gordo
Previsão de preços do açúcar utilizando redes neurais artificiais	PENEDO, A.; PACAGNELLA JR., A.; OLIVEIRA, M.	2007	Analisar o impacto dos preços do contrato futuro de açúcar. bruto nº11 da Csce/Nybot, taxa de câmbio comercial, barril de petróleo WTI Spot (mercado norte-americano) e Europe Brent	Açúcar

			Spot (mercado europeu) nos preços do açúcar cristal acondicionado em sacas de 50 kg.	
Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais	BRESSAN, A.	2004	Determinar a viabilidade de aplicação de modelos de previsão de preços na negociação de contratos futuros de boi gordo, café e soja na BM&F.	Boi gordo, café e soja
Previsão de preços com um modelo de redes neurais artificiais	BRESSAN, A.	1995	Construção de um modelo de redes neurais artificiais para previsão de preços mensais no mercado de boi gordo de São Paulo.	Boi gordo

Fonte: elaboração própria

Com base nos artigos apresentados, verifica-se que o número de trabalhos publicados contendo aplicações de redes neurais artificiais na área das *commodities* abordando previsão de preços cresceu nos últimos anos. Portanto, segundo Ferreira et al. (2011) há espaço para estudos que visem amparar os gestores agrícolas no processo decisório envolvendo a previsão de preços, pois no contexto brasileiro tem-se carência de metodologias bem estruturadas neste ramo.

Os artigos listados no Quadro 1 mostraram em seu conteúdo resultados positivos sobre o uso das redes neurais para a previsão de preços, inclusive este método mostrou-se mais relevante, em alguns casos, que outros modelos estatísticos de séries temporais como ARIMA, SARIMA, ARIMA-GARCH e AR-EGARCH (BRESSAN, 2004; GAI0; CASTRO JR; OLIVEIRA, 2007; SOBREIRO; ARAÚJO; NAGANO, 2009; PINHEIRO; SENNA, 2016). No estudo de Coelho Júnior et al. (2013), os autores construíram uma rede capaz de prever o preço do carvão vegetal no Estado de Minas Gerias com acurácia de 99%, demonstrando a eficácia das RNAs. Outra pesquisa com excelentes resultados usando as redes foi o trabalho de Gaio, Castro Jr. e Oliveira (2007), onde foi possível prever o preço do boi gordo com um EQM de apenas 0,007051, contra um EQM de 0,084304 do modelo AR-EGARCH.

3 METODOLOGIA

3.1 Caracterização da pesquisa

Esta pesquisa apresenta natureza empírica e caráter descritivo, tendo em vista que este estudo busca a descrição e análise de dados de uma amostragem através da aplicação de redes neurais artificiais, método utilizado para as mais variadas finalidades em distintas áreas da ciência, desde 1940. (PALIWAL; KUMAR, 2009; VALENÇA, 2010).

O método de pesquisa adotado foi o de levantamento, com técnica de coleta de dados via dados secundários disponibilizados em um banco gratuito *online*. Por se tratar de um modelo matemático, a abordagem deste estudo tem caráter quantitativo, com análise de dados através da aplicação das redes neurais artificiais (HAIR, 2005b; GIL, 2010).

3.2 Banco de dados

Os dados necessários para realização deste estudo referentes às *commodities* açúcar, algodão, arroz, café arábica, milho, soja e trigo foram coletados em uma base de dados secundários na *internet*. O indicador utilizado é o preço Esalq/BM&F, disponibilizado no *site* do CEPEA/Esalq diariamente (dias úteis). O preço Esalq/BM&F é fornecido pelo Centro de Estudos Avançados em Economia Aplicada (Cepea), o qual é amplamente utilizado como índice que orienta o mercado futuro de vários produtos (PEREIRA, 2009; LIMA et al., 2013).

A Tabela 7 exemplifica as informações disponibilizadas pelo Cepea com relação às *commodities* consideradas neste estudo para o dia 6 de março de 2017.

Tabela 7 – Indicadores de preços disponibilizados pelo Cepea no dia 06/03/2017

<i>Commodity</i>	<i>Volume</i>	<i>Preço diário (R\$)</i>	<i>Preço diário (US\$)</i>	<i>Variação/dia</i>	<i>Variação/mês</i>	<i>Data início da série de preços</i>
Açúcar	Saca de 50 kg	80,44	25,74	0,09%	-1,11%	20/05/2003
Algodão	Libra-peso de pluma	2,7454	-	0,49%	1,18%	28/06/1996
Arroz	Saca de 50 kg	45,18	14,46	0,36%	-4,04%	30/06/2005
Café arábica	Saca de 60 kg	490,09	156,83	-0,45%	-2,90%	02/09/1996
Milho	Saca de 60 kg	35,95	11,50	-0,83%	-0,42%	02/08/2004
Soja	Saca 60 kg	72,64	23,25	0,00%	1,03%	13/03/2006
Trigo	Tonelada	519,75	166,32	3,30%	0,84%	02/02/2004

Fonte: elaborada com base nos dados disponibilizados pelo Cepea (2017)

O Cepea faz parte do Departamento de Economia, Administração e Sociologia da Escola Superior de Agronomia “Luiz de Queiroz” (Esalq), mantido por professores da Universidade Federal de São Paulo. Trata-se de uma instituição brasileira de referência em pesquisas no ramo rural e, desde a década de 90, mantém parcerias com a BM&FBovespa para a elaboração e divulgação de indicadores futuros de produtos agrícolas (PEREIRA, 2009; CEPEA, 2017).

No dia 20 de setembro de 2017, a coleta de dados foi encerrada e o banco de dados concluído para as *commodities*. Para cada *commodity*, uma planilha em Excel foi criada para tratamento das variáveis de entrada e saída. O tópico a seguir, descreve a escolha destas variáveis e o passo-a-passo dos testes.

3.3 Modelagem e desempenho das redes

Neste trabalho, a modelagem das redes foi realizada através do *software* MATLAB versão R2015a e seguiu o cumprimento das etapas sequenciais sugeridas por Valença (2010) para modelagem de redes neurais: coleta e divisão de dados, seleção das variáveis de entrada e saída, definição da arquitetura da rede, treinamento e validação do desempenho.

Os tipos de redes testadas nesta pesquisa apresentam alguns parâmetros definidos e previamente selecionados no *software* MATLAB. Tratam-se de redes do tipo *Multilayer Perceptron*, com algoritmo de treinamento *Backpropagation (feed-forward back prop)*, juntamente com a técnica de otimização do algoritmo *Levenberg-Marquardt (trainlm)*, função de adaptação de aprendizagem *learnngdm* (método de aprendizado que utiliza o gradiente para ajuste dos pesos do neurônio a cada época), função de ativação de saída do tipo tangente hiperbólica (TANSIG) e fator de ajuste com base no erro médio quadrático normalizado (*MSE*). Tais características são consideradas pela literatura como uma topologia de rede neural bastante utilizada, pois apresenta resultados eficientes e satisfatórios (VALENÇA, 2010; HAYKIN, 2011; FERRAZ, 2013).

Como discutido no tópico anterior, a coleta de dados encerrou-se no dia 20 de setembro de 2017 para todas as *commodities*. A Tabela 8 apresenta a data inicial do período de dados coletados e o número de observações diárias dos preços Esalq/BM&F levantados para cada *commodity*.

Tabela 8 – Séries de preços para cada *commodity*

<i>Commodity</i>	Data inicial	Número de observações
Açúcar	20/05/2003	3555
Algodão	28/06/1996	5290
Arroz	30/06/2005	3050
Café arábica	02/09/1996	5241
Milho	02/08/2004	3271
Soja	13/03/2006	2875
Trigo	02/02/2004	3397

Fonte: elaboração própria.

Na etapa de divisão de dados, o conjunto para treinamento é aquele responsável pelo ajuste dos pesos da rede neural e foi formado por 50% da amostra de cada *commodity*. O conjunto para validação informa quando a rede deve parar seu treinamento, para que não perca sua capacidade de generalização, e constituiu-se por 25% dos dados da amostra. O conjunto para verificação formou-se pelos 25% dos dados restantes e é responsável pela avaliação do modelo do desempenho do modelo. Tais dados foram selecionados pelo *software* MATLAB de forma aleatória.

Para definição das entradas das redes, levou-se em consideração o vasto histórico de preços disponíveis no banco de dados de cada *commodity* e os bons resultados encontrados em estudos semelhantes, como na pesquisa de Ferreira et al., (2011), na qual os autores desenvolveram redes com desempenhos satisfatórios para prever o preço mensal da soja, boi gordo, milho e trigo, no mercado futuro, inserindo apenas preços médios de dois meses anteriores ao que foi previsto como variáveis de entrada, com dados obtidos do banco da Emater/RS entre 1992 e 2006. Considerando os objetivos desta pesquisa e a disponibilidade de dados diários, optou-se por utilizar como variáveis de entrada a data, em formato juliano, e valores em reais dos preços dos dias anteriores ao que foi previsto.

Outro estudo que corrobora com a escolha de dias anteriores para previsão do dia seguinte foi o de Gaio, Castro e Oliveira (2007), com redes de predição do preço futuro do boi gordo com um EQM inferior a 0,008, fazendo uso de preços dos dois dias que antecederiam o dia previsto como variáveis de entrada. Como variável de saída no presente estudo, tem-se apenas uma: os preços diários, em reais, de cada *commodity*.

Com relação à arquitetura das redes, demais parâmetros necessários para realização dos testes, como quantidade de variáveis de entrada, número de neurônios, função de ativação e número de camadas, foram variados de acordo com o comportamento e os resultados apresentados pelas redes de cada commodity. Segundo Valença (2010), a arquitetura ótima das *MLP* se dá através de tentativa e erro, portanto diferentes redes, formadas por distintas combinações devem ser testadas. A Figura 16 ilustra, resumidamente, as etapas que compuseram os testes para a construção das redes neurais desempenhadas nesta pesquisa.

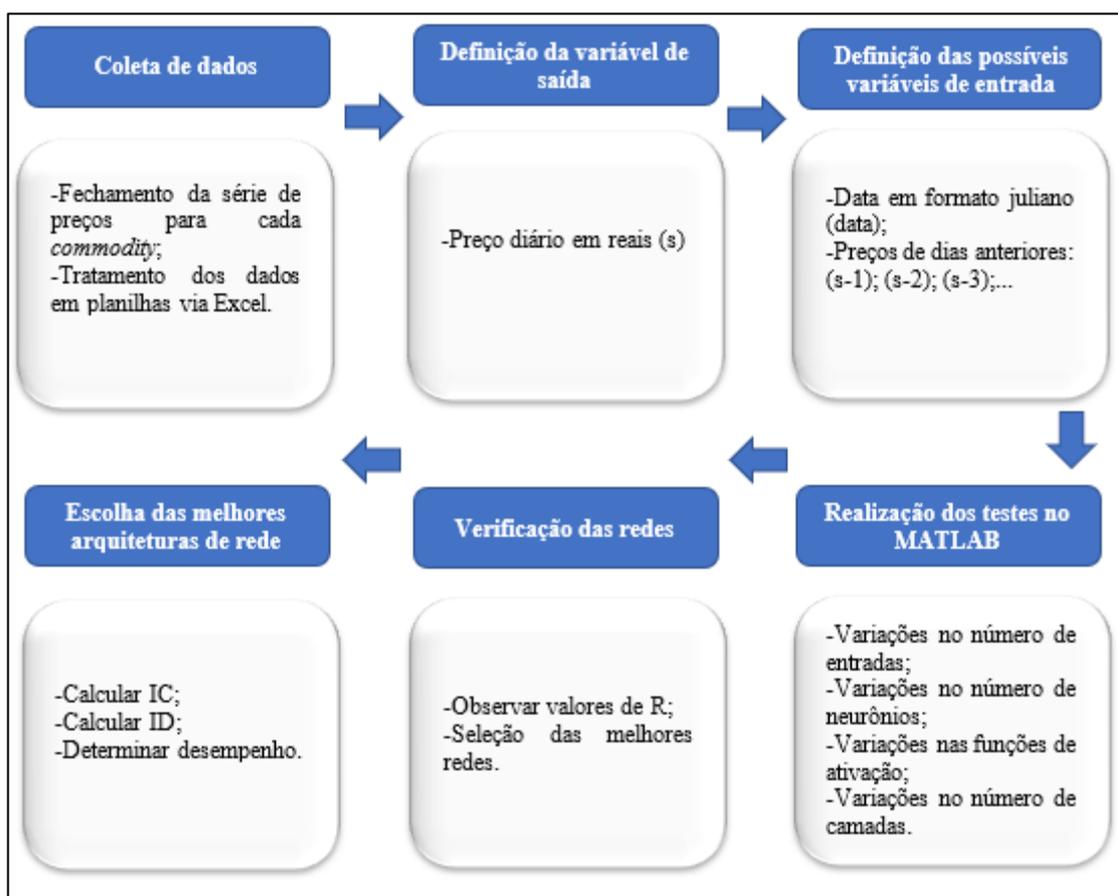


Figura 16 – Etapas de realização dos testes
Fonte: elaboração própria.

O treinamento das redes para cada commodity encerrou-se quando a função erro (Erro Quadrático Mínimo) apresentou o menor valor encontrado nos testes realizados no *software* MATLAB. A verificação do desempenho das redes se deu através de alguns índices, sugeridos por Valença (2005): Erro Médio Quadrático (MSE), Raiz Quadrada do Erro Médio (RMSE), coeficiente de correlação (r), índice de concordância (IC) e índice de desempenhos (ID). A Tabela 9 apresenta a equação para cálculo de cada um desses índices.

Tabela 9 – Índices para verificação do desempenho das redes

Índice	Equação	Onde:
Erro Médio Quadrático (MSE)	$MSE = \frac{\sum_{i=1}^n (Zp - Zo)^2}{n}$	Zp – valor previsto; Zo – valor ocorrido; n – número de valores da verificação.
Raiz Quadrada do Erro Médio (RMSE)	$RMSE = \sqrt{\frac{\sum_{i=1}^n (Zp - Zo)^2}{n}}$	Zp – valor previsto; Zo – valor ocorrido; n – número de valores da verificação.
Coefficiente de correlação (R)	$R = \frac{\sum_{i=1}^n (Zo - \bar{Z} o) \cdot (Zp - \bar{Z} p)}{\sqrt{\sum_{i=1}^n (Zo - \bar{Z} o) \cdot (Zp - \bar{Z} p)^2}}$	Zp – valor previsto; Zo – valor ocorrido; $\bar{Z} p$ – média dos valores previstos; $\bar{Z} o$ – média dos valores ocorridos; n – número de valores da verificação.
Índice de concordância (IC)	$IC = 1 - \frac{\sum_{i=1}^n (Zo - Zp)^2}{\sum_{i=1}^n (Zo - \bar{Z} o + Zp - \bar{Z} p)^2}$	Zp – valor previsto; Zo – valor ocorrido; $\bar{Z} o$ – média dos valores ocorridos; n – número de valores do período de verificação
Índice de desempenhos (ID)	$ID = r * IC$	r - coeficiente de correlação IC - índice de concordância

Fonte: Adaptado de Valença (2010) e Ferraz (2013)

No intuito de verificar os erros envolvidos na previsão das variáveis, primeiramente verificou-se o erro médio quadrático e a raiz do erro médio quadrático nos diferentes testes realizados para as redes no *software* MATLAB. O coeficiente de correlação (R), o qual demonstra o grau de correlação entre duas variáveis, no caso deste estudo o preço ocorrido e o preço estimado de cada *commodity*, foi utilizado para seleção das arquiteturas de rede.

Após a realização dos testes para cada *commodity* e a seleção das redes com base nos valores de R, calculou-se o índice de concordância (IC), que tem por finalidade fornecer o grau de exatidão entre as variáveis, onde 0 é nenhuma concordância e 1 representa concordância perfeita.

Por fim, calculou-se o índice de desempenho, que tem como função avaliar o desempenho da rede. Quanto mais próximo de 1 estiver o valor do ID, melhor o desempenho da rede, conforme Tabela 10 (ANDERSON; SWEENEY; WILLIAMS, 2007; FERRAZ, 2013).

Tabela 10 – Desempenho da rede conforme o Índice de Desempenho

Classes	Valores de ID	Desempenho
1	> 0,85	Ótimo
2	0,76 a 0,85	Muito Bom
3	0,66 a 0,75	Bom
4	0,61 a 0,65	Regular
5	0,51 a 0,60	Fraco
6	0,41 a 0,50	Muito Fraco
7	< 0,41	Péssimo

Fonte: Adaptado de Camargo e Sentelhas (1997) e Ferraz (2013)

Na seção a seguir, são apresentados e discutidos os resultados obtidos com os testes realizados envolvendo as diferentes redes neurais arquitetadas para previsão dos preços no mercado futuro das *commodities* agrícolas açúcar, algodão, arroz, café, milho, soja e trigo, bem como são demonstrados cenários com a predição dos preços diários no mercado futuro para o mês de agosto de 2017.

4 RESULTADOS E DISCUSSÕES

O número de testes desenvolvidos para cada *commodity* variou de acordo com o comportamento e desempenho das redes neurais artificiais durante as variações nos seguintes parâmetros: entradas, número de neurônios, função de ativação e número de camadas. O critério de seleção para identificação das melhores arquiteturas de redes foi a obtenção do maior valor médio de correlação (R) após a variação dos parâmetros citados.

A seguir, são apresentados e, posteriormente discutidos, os resultados dos testes realizados para as *commodities* açúcar, algodão, arroz, café, milho, soja e trigo. Cada tabela apresenta os testes de redes desempenhados para cada *commodity* e os valores obtidos no coeficiente de correlação para as etapas de treino, validação e teste. Na última coluna, é apresentado o coeficiente de correlação médio final (R).

Tabela 11 – Testes para a *commodity* Açúcar

Teste	Nº de entradas	Entradas	Nº de neurônios	Função	Nº de camadas	Treino	Validação	Teste	All (r)
Açúcar1	1	data	10	TANSIG	2	0,000	0,000	0,000	0,000
Açúcar2	1	s-1	10	TANSIG	2	0,9998	0,99984	0,99982	0,99981
Açúcar3	2	data; s-1	10	TANSIG	2	0,000	0,000	0,000	0,000
Açúcar4	3	data; s-1; s-2	10	TANSIG	2	0,99986	0,99925	0,99985	0,99985
Açúcar5	4	data; s-1; s-2; s-3	10	TANSIG	2	0,99986	0,99986	0,99984	0,99985
Açúcar6	5	data; s-1; s-2; s-3; s-4	10	TANSIG	2	0,99987	0,99989	0,99983	0,99987
Açúcar7	5	data; s-1; s-2; s-3; s-4	20	TANSIG	2	0,99987	0,99988	0,99985	0,99987
Açúcar8	5	data; s-1; s-2; s-3; s-4	30	TANSIG	2	0,99988	0,99984	0,99988	0,99987
Açúcar9	5	data; s-1; s-2; s-3; s-4	40	TANSIG	2	0,99988	0,9999	0,99984	0,99988
Açúcar10	5	data; s-1; s-2; s-3; s-4	50	TANSIG	2	0,99988	0,99988	0,99987	0,99988
Açúcar11	5	data; s-1; s-2; s-3; s-4	60	TANSIG	2	0,99987	0,99988	0,99987	0,99987
Açúcar12	5	data; s-1; s-2; s-3; s-4	55	TANSIG	2	0,99988	0,99987	0,99986	0,99988
Açúcar13	5	data; s-1; s-2; s-3; s-4	40	LOGSIG	2	0,99988	0,99988	0,99987	0,99988
Açúcar14	5	data; s-1; s-2; s-3; s-4	40	PURELIN	2	0,99478	0,99489	0,99472	0,99478
Açúcar15	5	data; s-1; s-2; s-3; s-4	40	TANSIG	3	0,99988	0,99987	0,99981	0,99987

Fonte: elaboração própria.

Tabela 12 – Testes para a *commodity* Algodão

Teste	Nº de entradas	Entradas	Nº de neurônios	Função	Nº de camadas	Treino	Validação	Teste	All (r)
Algodão1	1	data	10	TANSIG	2	0,000	0,000	0,000	0,000
Algodão2	1	s-1	10	TANSIG	2	0,99979	0,99988	0,99977	0,9998
Algodão3	2	data; s-1	10	TANSIG	2	-0,37182	-0,3911	-0,38752	-0,37669
Algodão4	3	data; s-1; s-2	10	TANSIG	2	0,99983	0,99988	0,99991	0,99985
Algodão5	4	data; s-1; s-2; s-3	10	TANSIG	2	0,99985	0,99992	0,99992	0,99987
Algodão6	5	data; s-1; s-2; s-3; s-4	10	TANSIG	2	0,99987	0,9999	0,99983	0,99987
Algodão7	4	data; s-1; s-2; s-3	20	TANSIG	2	0,99986	0,99991	0,99989	0,99987
Algodão8	4	data; s-1; s-2; s-3	30	TANSIG	2	0,000	0,000	0,000	0,000
Algodão9	4	data; s-1; s-2; s-3	25	TANSIG	2	0,99985	0,9991	0,9999	0,99987
Algodão10	4	data; s-1; s-2; s-3	10	LOGSIG	2	0,9992	0,99967	0,99968	0,99985
Algodão11	4	data; s-1; s-2; s-3	10	PURELIN	2	0,99207	0,993	0,99281	0,99234
Algodão12	4	data; s-1; s-2; s-3	10	TANSIG	3	0,9951	0,99597	0,99517	0,99523

Fonte: elaboração própria.

Tabela 13 – Testes para a *commodity* Arroz

Teste	Nº de entradas	Entradas	Nº de neurônios	Função	Nº de camadas	Treino	Validação	Teste	All (r)
Arroz1	1	data	10	TANSIG	2	0,98254	0,98082	0,98295	0,98235
Arroz2	1	s-1	10	TANSIG	2	0,99975	0,9998	0,99978	0,99976
Arroz3	2	data; s-1	10	TANSIG	2	0,99974	0,99979	0,99977	0,99975
Arroz4	3	data; s-1; s-2	10	TANSIG	2	0,99976	0,99973	0,99976	0,99975
Arroz5	4	data; s-1; s-2; s-3	10	TANSIG	2	0,99974	0,99981	0,99973	0,99975
Arroz6	2	data; s-1	20	TANSIG	2	0,99979	0,99979	0,99979	0,99979
Arroz7	2	data; s-1	30	TANSIG	2	0,99981	0,99979	0,99981	0,9998
Arroz8	2	data; s-1	40	TANSIG	2	0,99982	0,99976	0,99973	0,9998
Arroz9	2	data; s-1	50	TANSIG	2	0,99978	0,99983	0,99983	0,99979
Arroz10	2	data; s-1	30	LOGSIG	2	0,9998	0,99972	0,99982	0,9998
Arroz11	2	data; s-1	30	PURELIN	2	0,99419	0,99459	0,99404	0,99421
Arroz12	2	data; s-1	30	TANSIG	3	0,9998	0,99979	0,99983	0,9998
Arroz13	2	data; s-1	30	TANSIG	4	0,9998	0,99983	0,99978	0,998

Fonte: elaboração própria.

Tabela 14 – Testes para a *commodity* Café

Teste	Nº de entradas	Entradas	Nº de neurônios	Função	Nº de camadas	Treino	Validação	Teste	All (r)
Café1	1	data	10	TANSIG	2	0,97423	0,97799	0,97482	0,97486
Café2	1	s-1	10	TANSIG	2	0,99904	0,999878	0,99902	0,999
Café3	2	data; s-1	10	TANSIG	2	0,99902	0,999898	0,99985	0,999
Café4	3	data; s-1; s-2	10	TANSIG	2	0,99897	0,99908	0,99909	0,999
Café5	4	data; s-1; s-2; s-3	10	TANSIG	2	0,999	0,999897	0,9991	0,99901
Café6	5	data; s-1; s-2; s-3; s-4	10	TANSIG	2	0,99905	0,99889	0,99892	0,999
Café7	4	data; s-1; s-2; s-3	20	TANSIG	2	0,99903	0,99892	0,99899	0,999
Café8	2	data; s-1	20	TANSIG	2	0,000	0,000	0,000	0,000
Café9	4	data; s-1; s-2; s-3	15	TANSIG	2	0,99905	0,99882	0,99899	0,99901
Café10	4	data; s-1; s-2; s-3	17	TANSIG	2	0,86567	0,85799	0,85872	0,86359
Café11	4	data; s-1; s-2; s-3	16	TANSIG	2	0,99896	0,99913	0,99905	0,999
Café12	4	data; s-1; s-2; s-3	5	TANSIG	2	0,999	0,99901	0,99884	0,99898
Café13	4	data; s-1; s-2; s-3	10	LOGSIG	2	0,99903	0,99894	0,99892	0,999
Café14	4	data; s-1; s-2; s-3	10	PURELIN	2	0,99324	0,99334	0,9939	0,99353
Café15	4	data; s-1; s-2; s-3	10	TANSIG	3	0,99902	0,9989	0,99896	0,99899

Fonte: elaboração própria.

Tabela 15 – Testes para a *commodity* Milho

Teste	Nº de entradas	Entradas	Nº de neurônios	Função	Nº de camadas	Treino	Validação	Teste	All (r)
Milho1	1	data	10	TANSIG	2	0,94326	0,9409	0,93533	0,94159
Milho2	1	s-1	10	TANSIG	2	0,99826	0,99945	0,99956	0,99866
Milho3	2	data; s-1	10	TANSIG	2	0,99944	0,99386	0,99935	0,99862
Milho4	3	data; s-1; s-2	10	TANSIG	2	0,99839	0,99941	0,99954	0,99872
Milho5	4	data; s-1; s-2; s-3	10	TANSIG	2	0,99842	0,9995	0,98958	0,99717
Milho6	3	data; s-1; s-2	20	TANSIG	2	0,99848	0,99831	0,99944	0,99874
Milho7	3	data; s-1; s-2	30	TANSIG	2	0,99684	0,99567	0,99787	0,99684
Milho8	3	data; s-1; s-2	25	TANSIG	2	0,99851	0,99933	0,99933	0,99873
Milho9	3	data; s-1; s-2	21	TANSIG	2	0,99838	0,99942	0,9995	0,99869
Milho10	3	data; s-1; s-2	20	LOGSIG	2	0,9995	0,99942	0,99328	0,99866
Milho11	3	data; s-1; s-2	20	PURELIN	2	0,99432	0,99676	0,99523	0,9948
Milho12	3	data; s-1; s-2	20	TANSIG	3	0,99822	0,99891	0,99896	0,99843

Fonte: elaboração própria.

Tabela 16 – Testes para a *commodity* Soja

Teste	Nº de entradas	Entradas	Nº de neurônios	Função	Nº de camadas	Treino	Validação	Teste	All (r)
Soja1	1	data	10	TANSIG	2	0,89976	0,90955	0,91342	0,90326
Soja2	1	s-1	10	TANSIG	2	0,18954	0,195	0,14487	0,18376
Soja3	2	data; s-1	10	TANSIG	2	0,99906	0,9989	0,99861	0,99897
Soja4	3	data; s-1; s-2	10	TANSIG	2	0,9989	0,99895	0,99938	0,99898
Soja5	4	data; s-1; s-2; s-3	10	TANSIG	2	0,9989	0,99921	0,99922	0,99899
Soja6	5	data; s-1; s-2; s-3; s-4	10	TANSIG	2	0,99889	0,99903	0,9992	0,99896
Soja7	4	data; s-1; s-2; s-3	20	TANSIG	2	0,99891	0,99914	0,99939	0,99902
Soja8	4	data; s-1; s-2; s-3	30	TANSIG	2	0,99898	0,99921	0,99887	0,99899
Soja9	4	data; s-1; s-2; s-3	40	TANSIG	2	0,99898	0,99897	0,99916	0,99901
Soja10	4	data; s-1; s-2; s-3	50	TANSIG	2	0,99913	0,99902	0,99853	0,99903
Soja11	4	data; s-1; s-2; s-3	60	TANSIG	2	0,99845	0,99914	0,99836	0,99854
Soja12	4	data; s-1; s-2; s-3	55	TANSIG	2	0,99897	0,99897	0,99931	0,99902
Soja13	4	data; s-1; s-2; s-3	50	LOGSIG	2	0,9991	0,99877	0,99898	0,99903
Soja14	4	data; s-1; s-2; s-3	50	PURELIN	2	0,99411	0,99426	0,99458	0,9942
Soja15	4	data; s-1; s-2; s-3	50	TANSIG	3	0,99829	0,99907	0,9993	0,99855

Fonte: elaboração própria.

Tabela 17 – Testes para a *commodity* Trigo

Teste	Nº de entradas	Entradas	Nº de neurônios	Função	Nº de camadas	Treino	Validação	Teste	All (r)
Trigo1	1	data	10	TANSIG	2	0,69667	0,65223	0,67431	0,6872
Trigo2	1	s-1	10	TANSIG	2	0,99946	0,99949	0,99942	0,99946
Trigo3	2	data; s-1	10	TANSIG	2	0,99952	0,99959	0,99943	0,99951
Trigo4	3	data; s-1; s-2	10	TANSIG	2	0,9602	0,94409	0,96072	0,95788
Trigo5	4	data; s-1; s-2; s-3	10	TANSIG	2	0,99951	0,99949	0,9995	0,9995
Trigo6	2	data; s-1	20	TANSIG	2	0,99953	0,99947	0,99938	0,9995
Trigo7	2	data; s-1	30	TANSIG	2	0,99949	0,99964	0,99965	0,99953
Trigo8	2	data; s-1	40	TANSIG	2	0,99957	0,99947	0,99938	0,99953
Trigo9	2	data; s-1	50	TANSIG	2	0,99954	0,99955	0,99935	0,99951
Trigo10	2	data; s-1	30	LOGSIG	2	0,99952	0,99948	0,99945	0,9995
Trigo11	2	data; s-1	30	PURELIN	2	0,99351	0,99393	0,99438	0,99372
Trigo12	2	data; s-1	30	TANSIG	3	0,000	0,000	0,000	0,000

Fonte: elaboração própria.

Pode-se verificar que o número de testes variou entre 12 e 15 testes para as *commodities*. Para todas as *commodities*, iniciou-se com a configuração padrão do MATLAB, sendo esta de 10 neurônios, função de ativação TANSIG e 2 camadas, modificando-se, primeiramente, as entradas. Nos dois testes iniciais, testaram-se individualmente as entradas “data” e “s-1” (dia anterior à saída). Em seguida, as variáveis de entrada foram aumentando, colocando-se dias anteriores ao previsto, por exemplo: “s-2” (preços dos dois dias anteriores ao previsto), “s-3” (preços dos três dias anteriores ao previsto), e assim sucessivamente, até se observar uma queda ou equilíbrio no desempenho da rede. Com base na escolha das entradas, devido aos resultados dos testes, o segundo passo foi variar o número de neurônios das redes, posteriormente as funções e em seguida o número de camadas. No total, 94 arquiteturas de redes foram testadas para as *commodities* agrícolas consideradas nesta pesquisa.

Para a *commodity* açúcar, como se pode observar na Tabela 11, foram desenvolvidos 15 testes. Com relação às entradas, os testes demonstraram nenhuma correlação com apenas a data como entrada e ao utilizar-se a data combinada com os preços do dia anterior. Enquanto isso, apenas os valores dos preços do dia anterior ao previsto, apresentaram forte correlação. Quando houve a inserção da data e preços de mais de um dia anterior à saída, a correlação aumentou. Quanto à variação no número de neurônios, os testes mostraram crescimento nos valores de R até 40 neurônios, mantendo-se o valor de R constante com 50 e 55, vindo a decair com 60 neurônios. A mudança para função LOGSIG não apresentou diferença para o uso da TANSIG, vindo a decair o coeficiente de correlação com o uso da função PURELIN. Ao se variar o número de camadas para 3, houveram decréscimos significativos nos valores de R-treino, R-validação, R-teste e R-médio. Assim, o teste com melhor resultado verificado foi o número 9, com 5 entradas, sendo estas a data e os preços de 4 dias anteriores. O número de neurônios ficou em 40, com função de ativação TANSIG e 2 camadas, sendo o R médio obtido de 0,99988.

Na Figura 17 pode-se verificar que as variações dos preços reais explicam em 99,98% as variações dos preços previstos pela rede do teste Açúcar9.

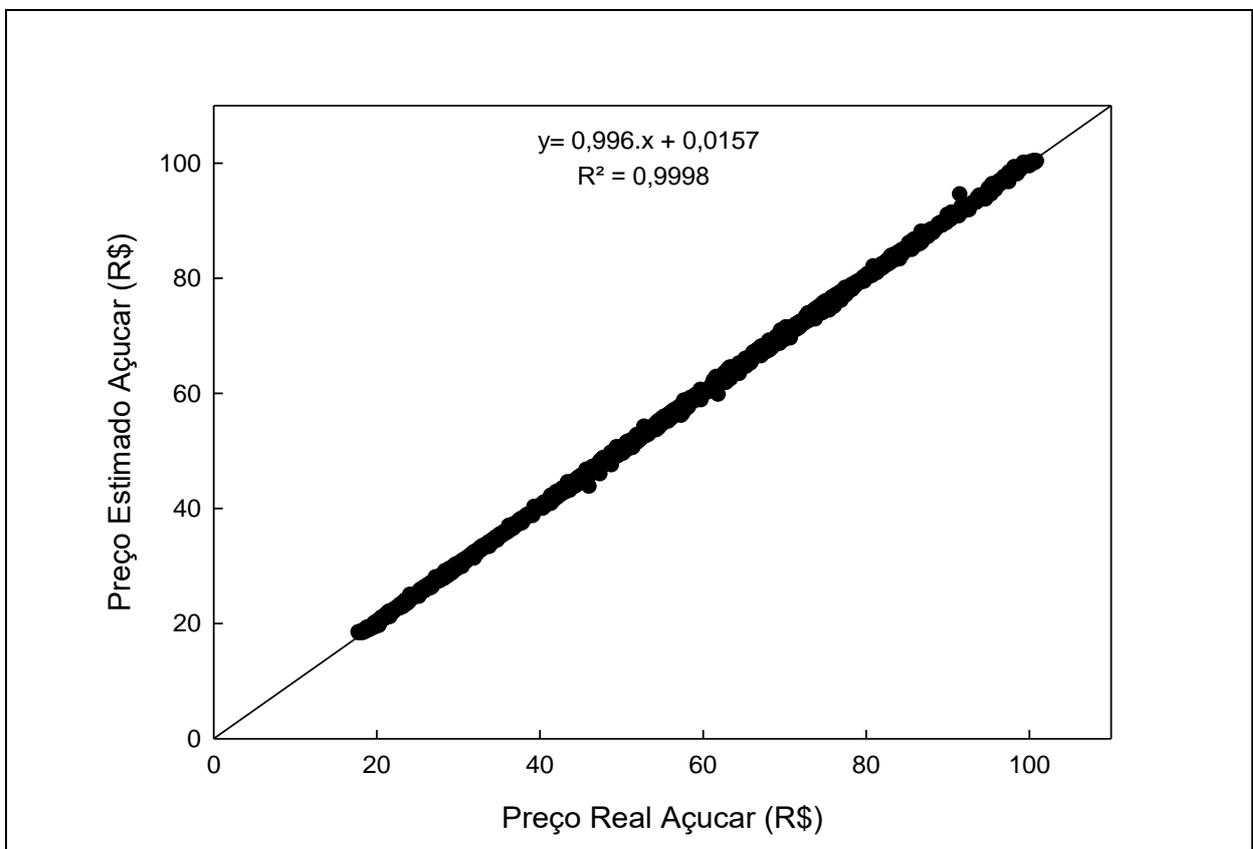


Figura 17 – Regressão linear Açúcar9
Fonte: elaborada através do *software* SigmaPlot

A Tabela 12, apresenta os 12 testes realizados para a *commodity* algodão, dos quais iniciou-se com bons resultados no momento em que se combinou a variável de entrada “data” com dois dias anteriores, ou mais. O teste número 2, que teve como entrada apenas os preços de um dia anterior demonstrou forte correlação, mas optou-se por continuar os testes no intuito de encontrar uma arquitetura de rede que apresentasse a variável data em conjunto com as demais, para ser possível a criação de cenários. Ao se variar o número de neurônios para 20 e 25, o valor de R manteve-se constante, caindo para zero com 30 neurônios. As funções LOGSIG e PURELIN, diminuíram o valor de R médio e ao se aumentar o número de camadas, esse valor também decaiu. Portanto, o teste número 5 apresentou os parâmetros selecionados para a previsão do preço do algodão, sendo esta rede composta por 4 entradas: data e preços dos três dias anteriores. O número de neurônios manteve-se em 10, a função de ativação escolhida foi a TANSIG e o número de camadas ficou em 2. O R médio final desta rede foi de 0,99987. A Figura 18 apresenta o gráfico referente a regressão linear, onde verifica-se que as variações dos preços reais explicam em 99,97% as variações dos preços previstos pela rede do teste Algodão5.

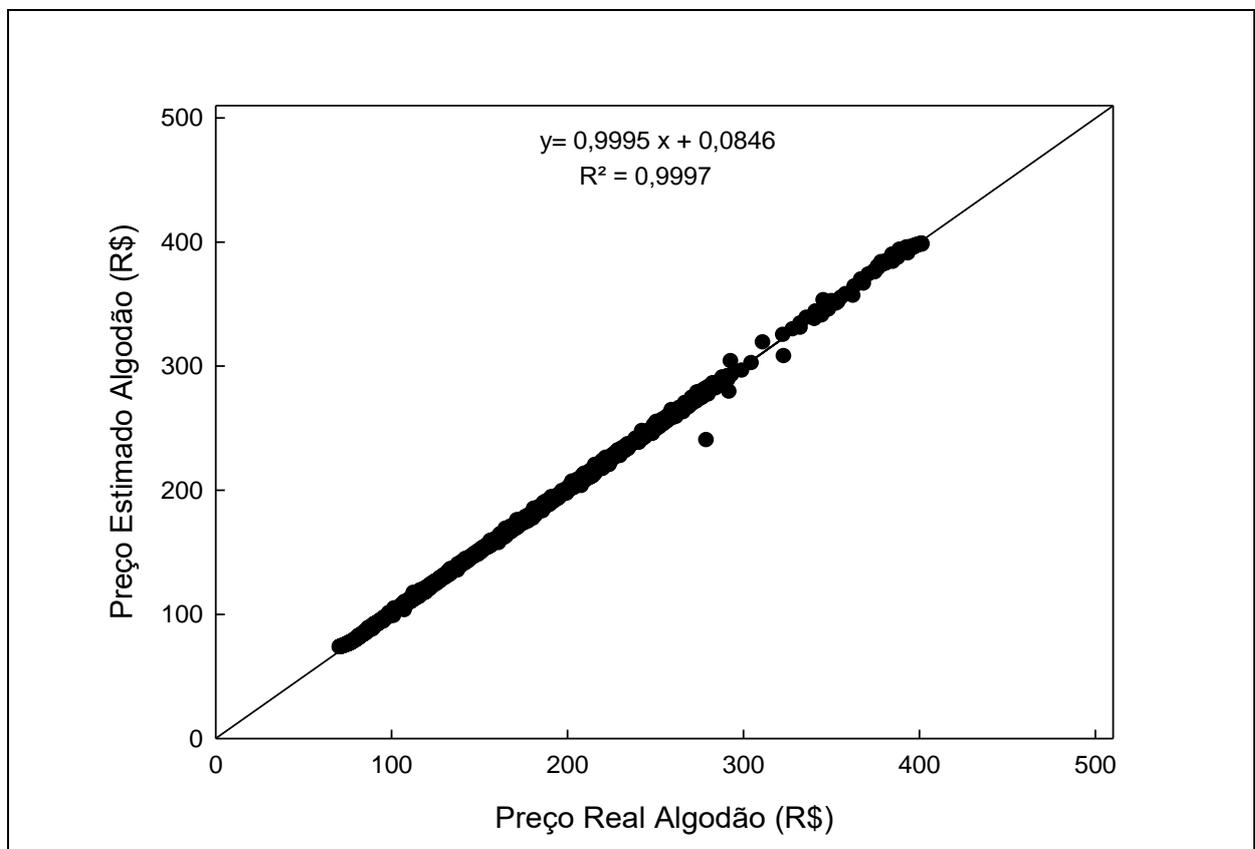


Figura 18 – Regressão linear Algodão5

Fonte: elaborada através do *software* SigmaPlot

O arroz apresenta na Tabela 13, 13 testes de redes desenvolvidos, onde a rede com maior correlação positiva entre as variáveis foi a número 7, com apenas 2 entradas, no caso, a data e o preço do dia anterior. Quando se aumentou o número de entradas, o valor de R médio diminuiu. Aumentando-se o número de neurônios, obteve-se crescimento no coeficiente de correlação até 30 neurônios, mantendo-se constante com 40 e vindo a diminuir com 50. Portanto, fixou-se o número de 30 neurônios. Não se obteve aumento em R alternando as funções, nem se modificando o número de camada para 3 e 4. O melhor valor para R médio encontrado foi de 0,9998, com 2 entradas, 30 neurônios, função TANSIG e 2 camadas. Na Figura 19 observa-se que as variações dos preços reais explicam em 99,95% as variações dos preços previstos pela rede do teste Arroz7.

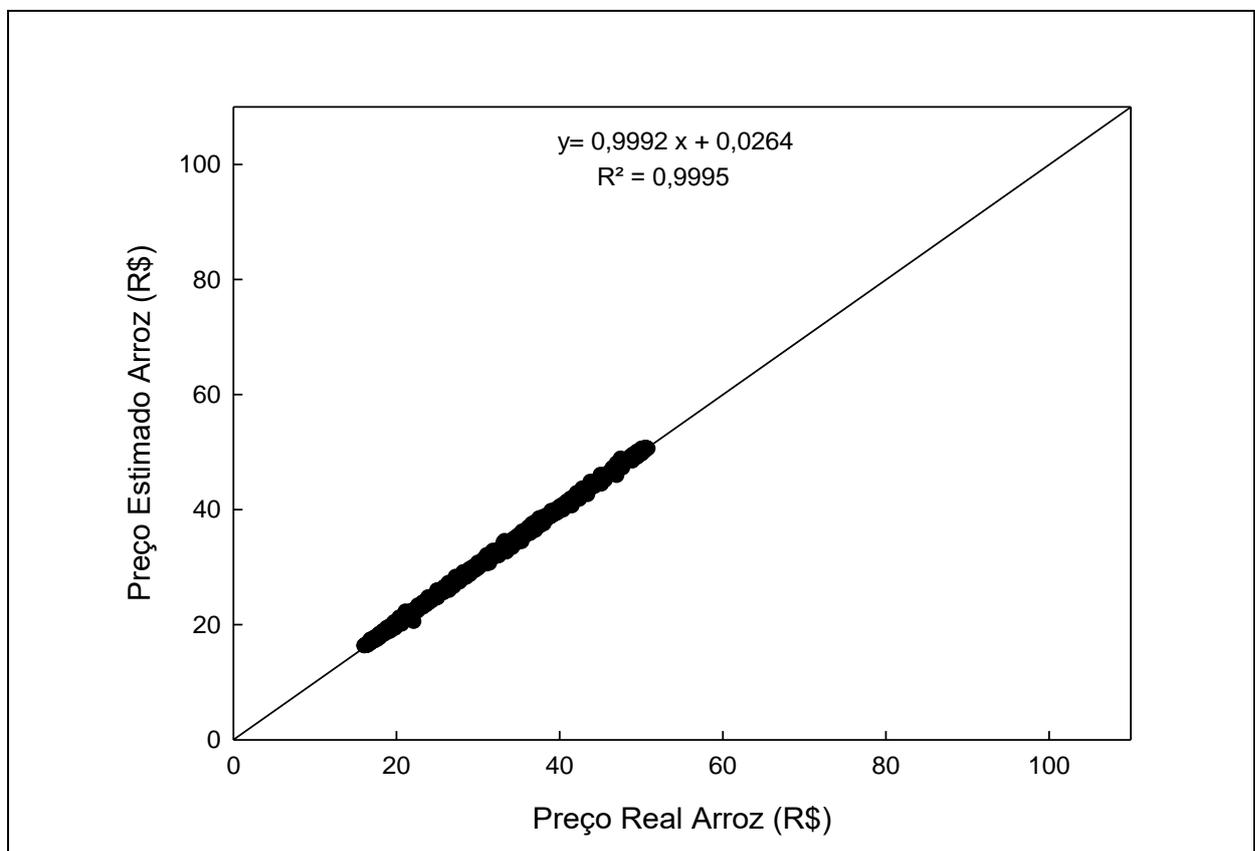


Figura 19 – Regressão linear Arroz7

Fonte: elaborada através do *software* SigmaPlot

Na Tabela 14, pode-se observar os 15 testes de redes para a *commodity* café. Com relação às entradas, o valor de R médio mostrou-se alto em todos os testes, mas optou-se pelo valor mais alto e com o menor número de variáveis possível, sendo estas a data e os preços dos três dias anteriores à saída. Ao se definir as variáveis de entrada, os neurônios foram sendo alterados gradativamente, até verificar-se uma queda no valor do coeficiente de

correlação. Portanto, foi definido o número de 10 neurônios. Com relação às funções de ativação, não houve aumento no valor de R médio ao utilizar-se LOGSIG e PURELIN. Quanto ao número de camadas, apenas duas foram suficientes. Com esses parâmetros, obteve-se um R médio de 0,99901 no teste número 5. Na Figura 20 observa-se que as variações dos preços reais explicam em 99,8% as variações dos preços previstos pela rede do teste Café5.

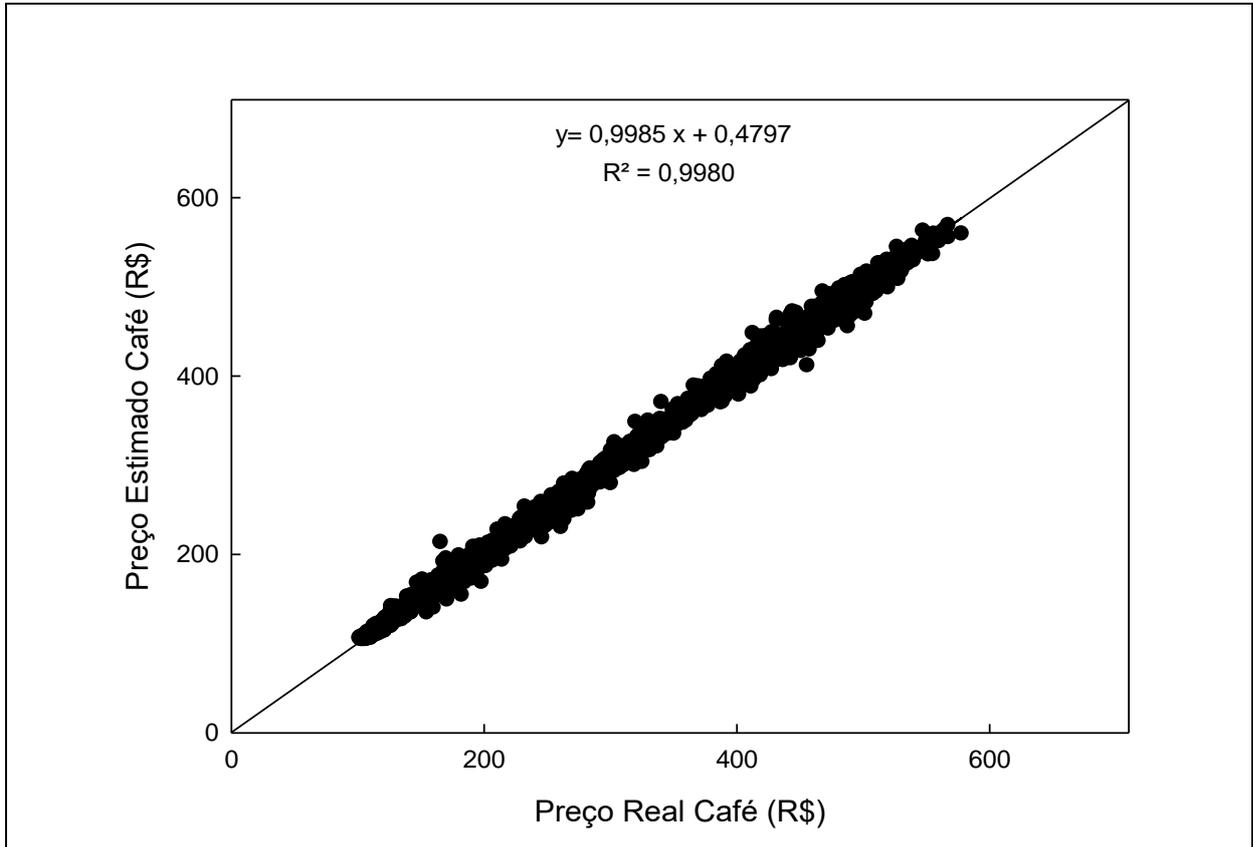


Figura 20 – Regressão linear Café5

Fonte: elaborada através do *software* SigmaPlot

Foram 12 testes de distintas redes para o milho, apresentados na Tabela 15, sendo o maior valor positivo de R médio obtido no teste número 6. Conforme se foi aumentando o número de entradas, o desempenho foi melhorando até decair no momento em que foram inseridas 4 entradas. Assim, 3 entradas foram selecionadas, data, preços de um dia anterior, preços de dois dias anteriores e preços de 3 dias anteriores ao previsto. Durante a alteração no número de neurônios, obteve-se ganho no aumento para 20 neurônios, vindo a diminuir o valor de R quando testados os valores 30, 25 e 21. Na variação das funções e no número de camadas, a rede não demonstrou maior aprendizado, mantendo-se como escolhida a função TANSIG e duas camadas. O R médio final do teste selecionado foi de 0,99874. Na Figura 21

observa-se que as variações dos preços reais explicam em 99,75% as variações dos preços previstos pela rede do teste Milho6.

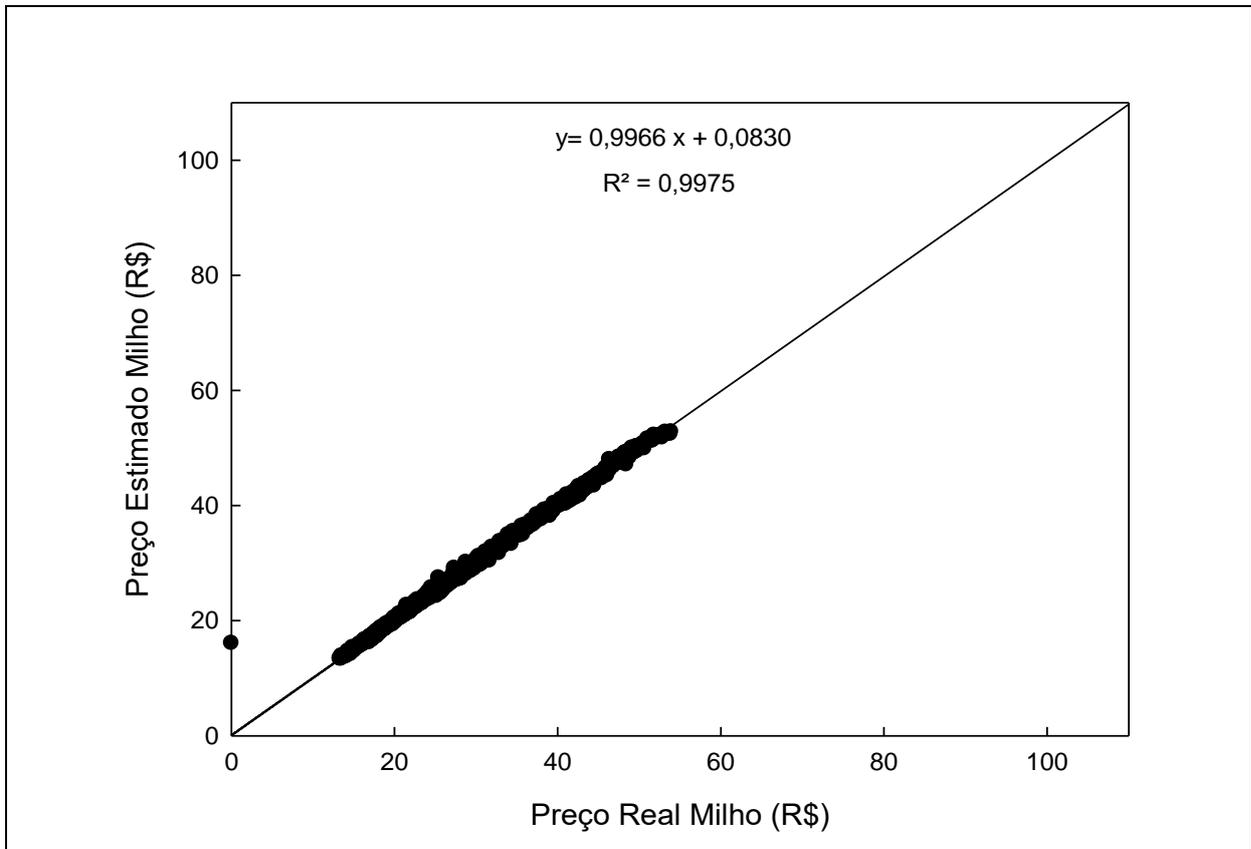


Figura 21 – Regressão linear Milho6
 Fonte: elaborada através do *software* SigmaPlot

Para a *commodity* soja, Tabela 16, os resultados de R aumentaram sensivelmente ao se agregar mais entradas, combinando a data com preços dos dias anteriores. Foram selecionadas 4 entradas, pois ao se testar a data com os preços dos cinco dias que antecedem o preço da saída, houve uma pequena diminuição no valor de R. Conforme aumentou-se o número de neurônios, até 50, observou-se um aumento nas correlações, vindo a decair quando se testaram 55 neurônios. A função LOGSIG apresentou o mesmo resultado que a TANSIG, enquanto a PURELIN diminuiu o valor de R. O número de camadas manteve-se em duas. O maior valor de R médio encontrado foi de 0,99903, no teste 10. Na Figura 22 observa-se que as variações dos preços reais explicam em 99,81% as variações dos preços previstos pela rede do teste Soja10.

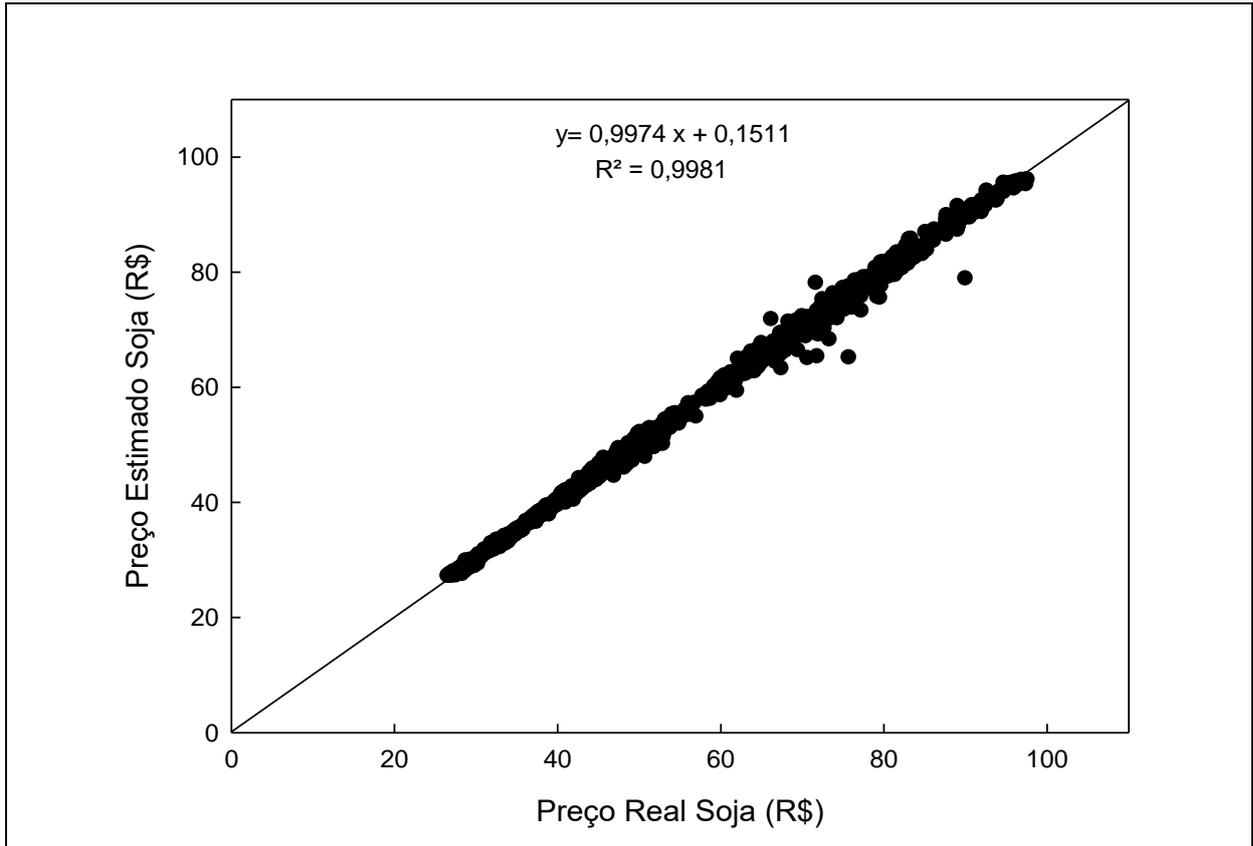


Figura 22 – Regressão linear Soja10

Fonte: elaborada através do *software* SigmaPlot

Por fim, a Tabela 17 apresenta os 12 testes realizados para a *commodity* trigo. O teste que apresentou os parâmetros selecionados de rede foi o número 7, com apenas 2 variáveis de entrada, sendo estas a data e os preços de um dia anterior à saída. Obteve-se aumento no valor de R médio até 30 neurônios, mantendo-se constante com 40, vindo a decair com 50. As funções LOGSIG e PURELIN mostraram-se inferiores à função TANSIG nos testes. Com relação ao número de camadas, a rede mostrou-se incapaz de aprendizado com 3 camadas, sendo apenas 2 camadas necessárias para obtenção de um forte coeficiente de correlação. O maior valor de R médio encontrado foi de 0,99953. Na Figura 23 observa-se que as variações dos preços reais explicam em 99,91% as variações dos preços previstos pela rede do teste Trigo7.

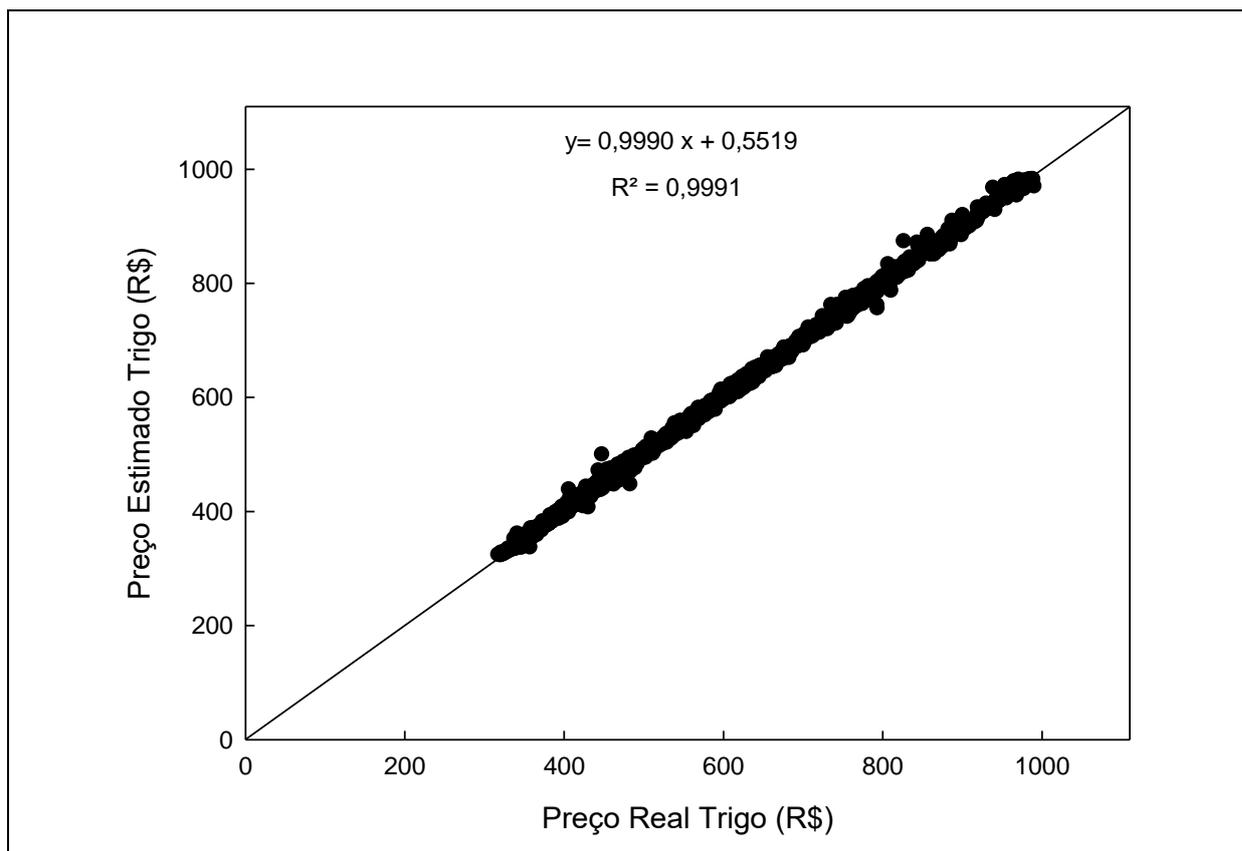


Figura 23 – Regressão linear Trigo7

Fonte: elaborada através do *software* SigmaPlot

A Tabela 18, apresenta as arquiteturas de redes selecionadas cada *commodity*, o seu coeficiente de correlação, o valor do índice de concordância, o índice de desempenho e a classificação final da rede.

Tabela 18 – Arquiteturas das redes selecionadas

<i>Commodity</i>	Arquitetura selecionada	Coefficiente de Correlação (R)	Índice de Concordância (IC)	Índice de Desempenho (ID)	Desempenho da Rede
Açúcar	5-40-1	0,99988	0,99994	0,99982	Ótimo
Algodão	4-10-1	0,99987	0,99994	0,99981	Ótimo
Arroz	2-30-1	0,9998	0,99989	0,99969	Ótimo
Café	4-10-1	0,99901	0,99950	0,99851	Ótimo
Milho	3-20-1	0,99874	0,99937	0,99811	Ótimo
Soja	4-50-1	0,99903	0,99951	0,99854	Ótimo
Trigo	2-30-1	0,99953	0,99977	0,99930	Ótimo

Fonte: elaboração própria.

Pode-se observar na Tabela 18 que as arquiteturas das redes neurais artificiais selecionadas variaram entre as *commodities*, não havendo um padrão, sendo que o número de

entradas oscilou de duas a cinco variáveis na camada de entrada. Esperava-se que apenas a variável “data” não fosse capaz de prever os preços com um bom desempenho, pois estudos já realizados para previsão de preços de *commodities*, faziam uso de preços de períodos anteriores obtendo ótimos resultados, sem combinar tal variável como entrada (GAIO; CASTRO JR.; OLIVEIRA, 2007; FERREIRA et al., 2011). Mesmo assim, algumas *commodities* apresentaram fortes correlações entre os preços previstos e os reais utilizando-se apenas a data como entrada, sendo elas: arroz, café, milho e soja. Entretanto, os testes para as *commodities* açúcar e algodão apresentaram coeficiente de correlação igual a zero e, para o trigo, o valor de R não foi satisfatório.

Neste estudo optou-se por utilizar a data no intuito de verificar o comportamento dos testes e obteve-se aumento positivo nas correlações ao combinar-se a variável data com os preços de dias anteriores. Como premissa para o uso da data como entrada, tem-se o comportamento sazonal na produção das *commodities* e variações em seus valores comerciais de acordo com diversos fatores discutidos no capítulo de contextualização sobre *commodities* que afetam os preços destes bens, tais como períodos de chuva, estações do ano e mudanças climáticas (MENEZES, 2015).

Durante os testes desenvolvidos, verificou-se que a combinação da variável data, juntamente com preços de dias anteriores ao previsto, mostrou-se eficaz para todas as *commodities* consideradas neste estudo. Porém, o número de dias anteriores não foi fixo, como na pesquisa de Gaio, Castro Jr. e Oliveira (2007), que usou apenas o preço de um dia anterior ao previsto para testar as redes de predição do valor da saca da soja; e o estudo de Ferreira et. al., (2011), que desenvolveram todas suas redes com apenas duas entradas: preço médio de um e dois meses anteriores ao mês previsto. Nesta pesquisa, para o açúcar, quatro dias anteriores à saída foram considerados, já para o algodão, o café e a soja, três dias foram inseridos na camada de entrada. A *commodity* milho apresentou o melhor desempenho com dois dias anteriores, enquanto arroz e trigo, com apenas um.

Quanto ao número de neurônios das redes selecionadas, estes variaram de 10 a 50 neurônios. Observa-se que quanto maior o número de entradas selecionadas, maior o número de neurônios necessários na arquitetura e, quanto menor o número de entradas, as redes mostraram melhor desempenho com um número menor de neurônios. Este tipo de comportamento vai de acordo com a literatura, pois segundo Haykin (2001), o número de neurônios está ligado diretamente com o poder de processamento da rede visto que, por exemplo, redes mais complexas que apresentam um número inferior de neurônios do que o

necessário, não irão apresentar bons resultados, enquanto redes simples, com muitos neurônios, irão aprender além do necessário, gerando ruído.

Considerando que os dados utilizados neste estudo se tratam de séries de preços, esperava-se que as funções do tipo sigmoide logística e tangente hiperbólica apresentassem os melhores resultados quando comparadas a uma função linear, que foi o ocorrido (REINKE, 2008; FERRAZ, 2013). Agora, conforme à literatura, a função do tipo sigmoide logística tende a apresentar melhores resultados para séries que não apresentam valores negativos, o que não se confirmou nesta pesquisa (HAYKIN, 2001; VALENÇA, 2010). Quando houve a variação na função de ativação da rede para sigmoide logística, apenas três *commodities* mantiveram-se com o mesmo coeficiente de correlação, sendo estas o açúcar, o arroz e a soja, as demais apresentaram queda no valor de R. Assim, optou-se por manter como função de ativação a função TANSIG, configuração inicial do *software* MATLAB, que envolve um intervalo maior de variação dos dados, de -1 a 1, o que não prejudicou a predição das redes.

Quanto ao número de camadas das redes, todas as redes neurais apresentaram duas camadas, ou seja, a camada intermediária, com seu respectivo número de neurônios, e a camada de saída, com a única variável esperada que é o preço. Assim, duas camadas foi a configuração mínima possível para a realização dos testes, e ao se realizar testes com mais camadas, as redes demonstraram queda no aprendizado. Segundo Hair et al. (2005a), mesmo que seja possível agregar múltiplas camadas intermediárias, existe um consenso de que o uso de apenas uma camada escondida é o ideal, para que não ocorra um superajuste ou aumento de tempo para obtenção dos resultados. Apenas a *commodity* arroz manteve o mesmo valor de R no teste com três camadas, vindo a decair com quatro camadas.

A Tabela 18 também apresenta o índice de concordância e o índice de desempenho para cada *commodity*. O IC foi calculado utilizando-se o valor real e o valor do preço previsto de cada *commodity*, seguindo equação apresentada na Tabela 9, conforme a arquitetura de rede selecionada. Posteriormente, calculou-se o índice de desempenho. Assim, foi possível caracterizar o desempenho das redes conforme Camargo e Sentelhas (1997), onde todas as redes escolhidas foram classificadas como ótimas.

A seguir, são apresentados cenários de preços diários para o mês de agosto de 2017. Optou-se pelo mês de agosto de 2017 por ser o último mês completo do banco de dados, podendo assim prever os preços e compará-los com os preços reais de todos os dias do mês.

Para a construção dos cenários, primeiramente utilizaram-se os parâmetros das redes selecionadas de cada *commodity*. Após a etapa de geração das matrizes das redes, as quais são

apresentadas nos apêndices deste trabalho, as saídas estimadas foram utilizadas; juntamente com as datas deste período; como entradas para a estimação das previsões do mês de agosto. A simulação das redes foi através do *software* MATLAB e a os gráficos de comparação entre preço real e preço estimado foram desenvolvidos no *software* SigmaPlot.

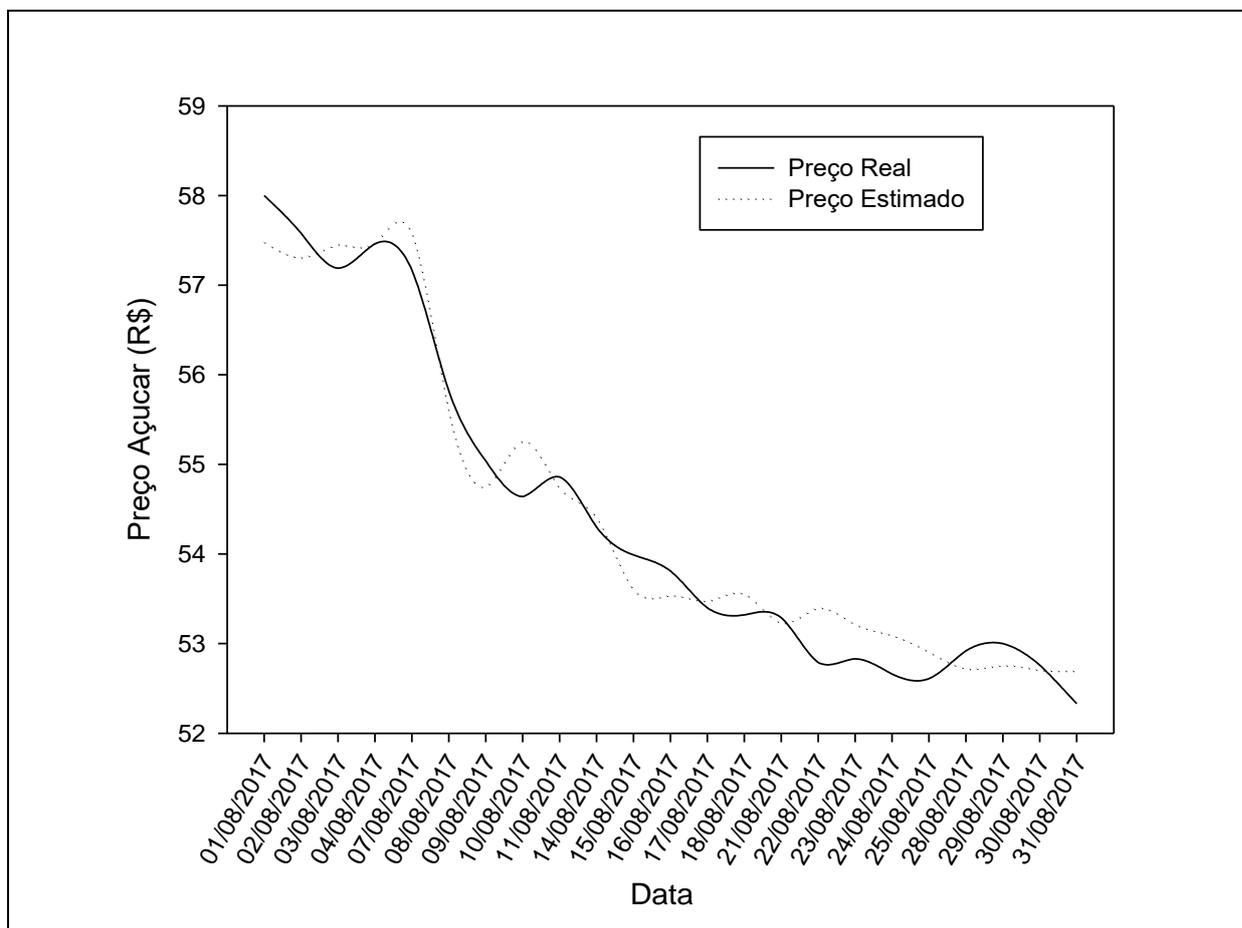


Figura 24 – Cenário de preços para o Açúcar
Fonte: elaborada através do software SigmaPlot

Na Figura 24, é apresentado o cenário de preços para a *commodity* açúcar. Ao analisar-se o gráfico, pode-se observar que a primeira semana do mês de agosto apresentou os maiores valores para preço do açúcar para a saca de 50kg. Após a primeira semana, os preços foram decaindo. O dia 10 do mês considerado apresentou o maior erro de previsão, no qual houve um decréscimo de preço, enquanto o preço estimado veio a crescer. Outro período com diferenças consideráveis foi do dia 22 ao 25. O valor do coeficiente de determinação foi de 0,968 para este período.

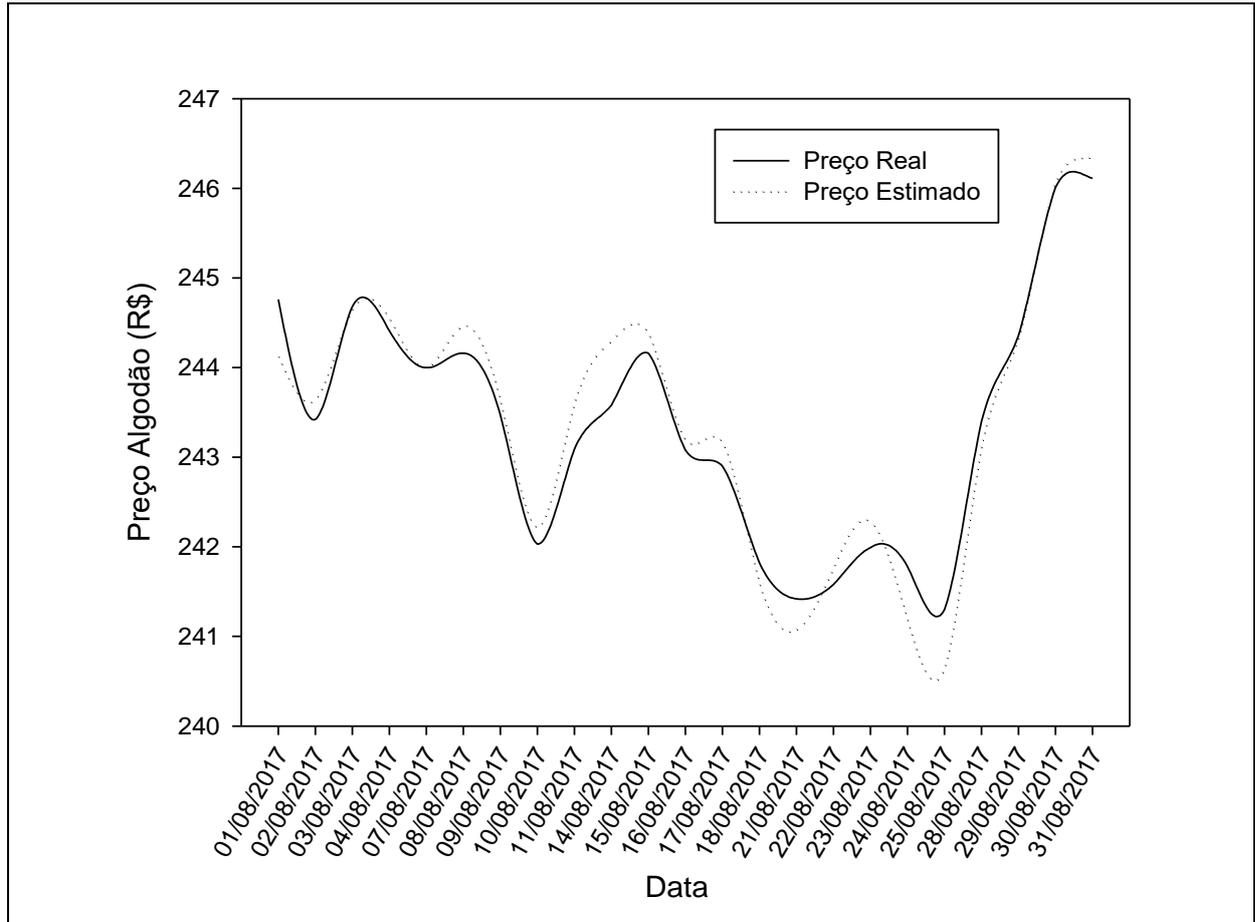


Figura 25 – Cenário de preços para o Algodão
 Fonte: elaborada através do software SigmaPlot

A Figura 25 demonstra o cenário para a *commodity* algodão. O comportamento dos preços da libra-peso de pluma do algodão é bastante variável ao longo dos dias como se pode observar no gráfico, sendo os períodos do início e final do mês os que demonstraram maiores valores de preço no mercado futuro. Os dias 14 e 25 apresentaram os maiores erros de previsão, contudo, o comportamento de decréscimo dos preços conseguiu ser previsto pela rede. O valor do coeficiente de determinação foi de 0,949 para este período.

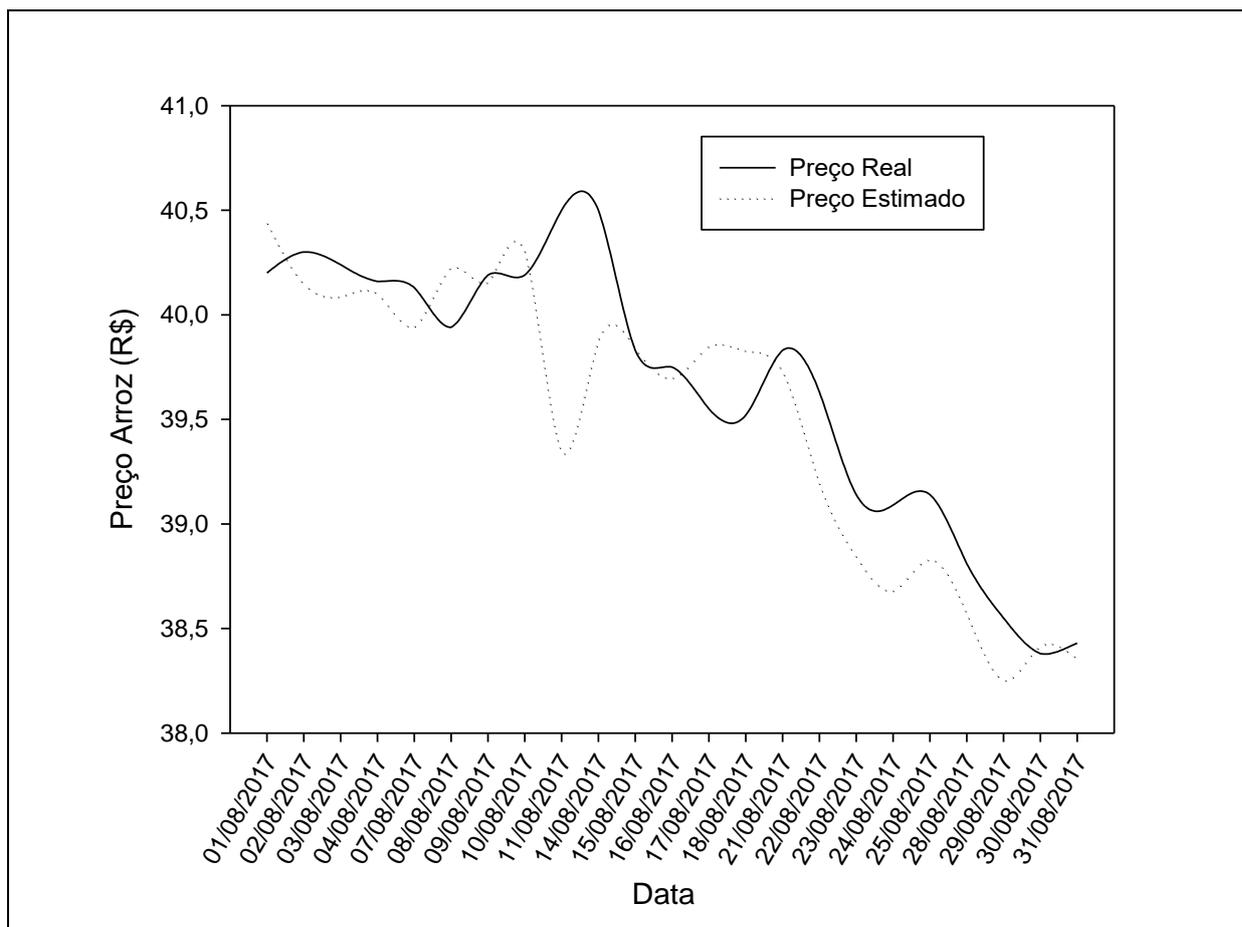


Figura 26 – Cenário de preços para o Arroz
 Fonte: elaborada através do software SigmaPlot

A Figura 26 demonstra as variações entre os preços estimados e os preços reais para a commodity arroz. Com relação ao comportamento dos preços, verifica-se que o período até o dia 10 de agosto apresentou os maiores valores para a saca de 50kg, após essa data, os valores vieram a decair, alcançando-se os menores valores nos últimos dias do mês. Observa-se maior erro de previsão no dia 11 de agosto, no qual o valor real demonstrou grande aumento, enquanto no comportamento previsto, o preço veio a decair. Do dia 16 ao 21 também houve uma convergência considerável de comportamento entre os preços reais e os previstos. O valor do coeficiente de determinação foi de 0,775 para este período.

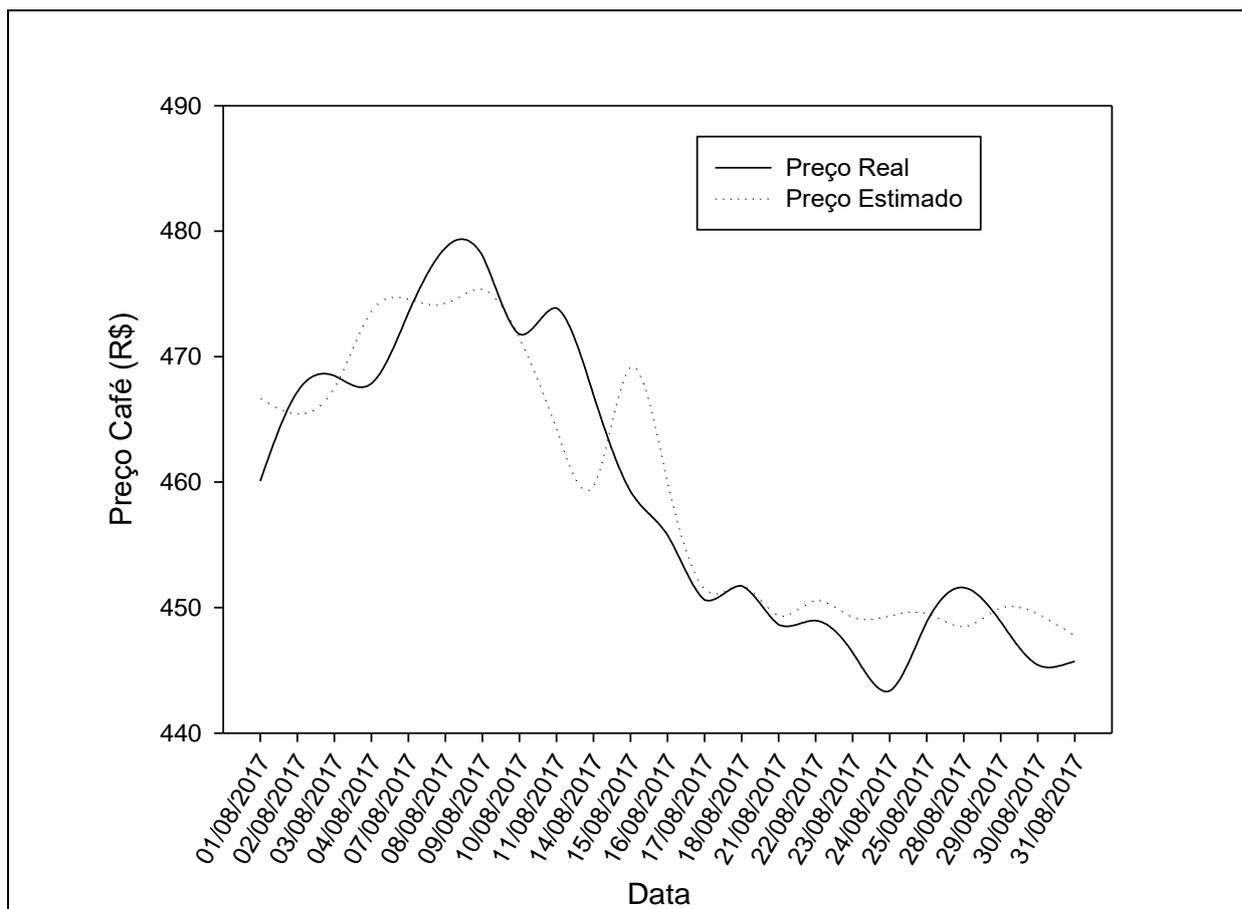


Figura 27 – Cenário de preços para o Café
 Fonte: elaborada através do software SigmaPlot

Com relação aos preços para a *commodity* café, verifica-se na Figura 27 que os valores mais altos para a saca de 60kg são negociados na primeira quinzena do mês. Apesar de diversas divergências de preços entre o cenário real e o previsto, a rede mostrou-se capaz de captar as grandes variações de preços observadas ao longo do mês. O valor do coeficiente de determinação foi de 0,849 para este período.

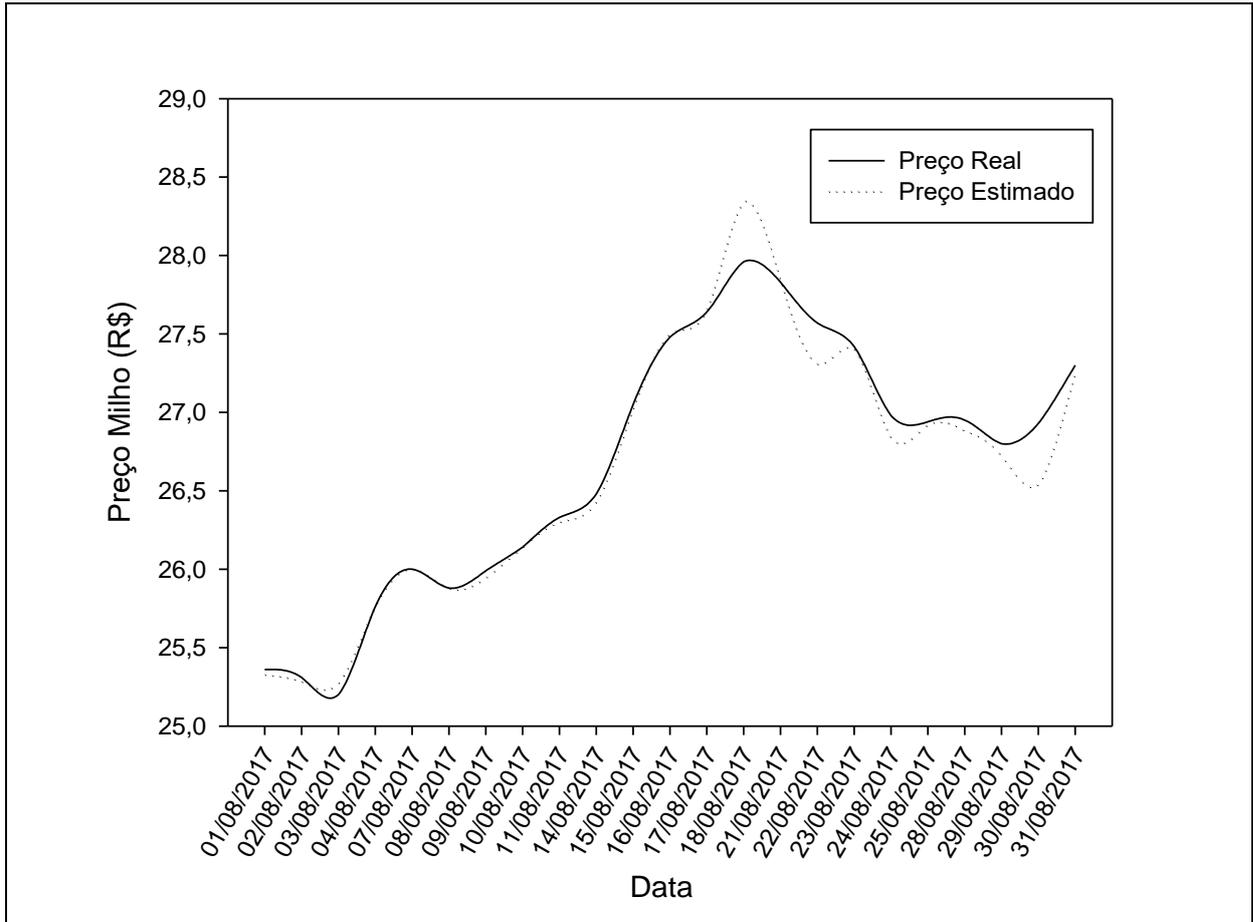


Figura 28 – Cenário de preços para o Milho
 Fonte: elaborada através do software SigmaPlot

A Figura 28 apresenta o cenário de preços para a *commodity* milho. O ápice dos valores negociados no mercado futuro para a saca de 60kg foi no dia 18 de agosto. Até o dia 17 deste mês, os valores previstos foram muito próximos aos reais, havendo maiores diferenças nos valores a partir do dia 18. Apesar disso, a rede mostrou-se capaz de acompanhar as variações dos preços. O valor do coeficiente de determinação foi de 0,974 para este período.

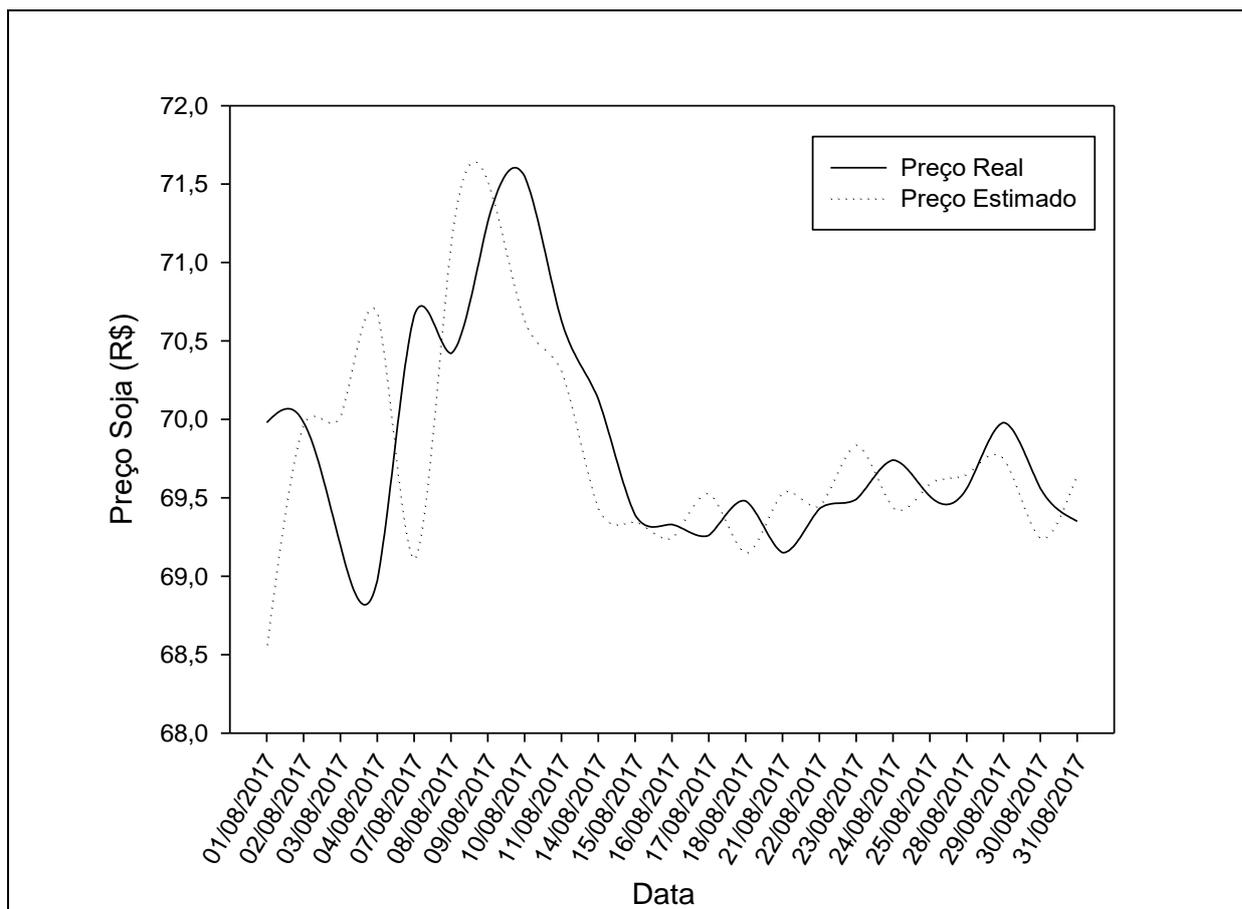


Figura 29 – Cenário de preços para a Soja
Fonte: elaborada através do software SigmaPlot

Na Figura 29 é apresentado o cenário de preços para o mês de agosto da commodity soja. O maior valor para negociação da saca de 60kg foi no dia 10 de agosto, enquanto o menor valor ocorreu no dia 4 de agosto. Com relação a previsão da rede, o comportamento predição mostrou-se um pouco atrasado como se pode ver no comportamento das curvas do gráfico. Apesar disso, pode-se captar o comportamento de altas e baixas dos preços ao longo do mês. O valor do coeficiente de determinação foi de 0,834 para este período.

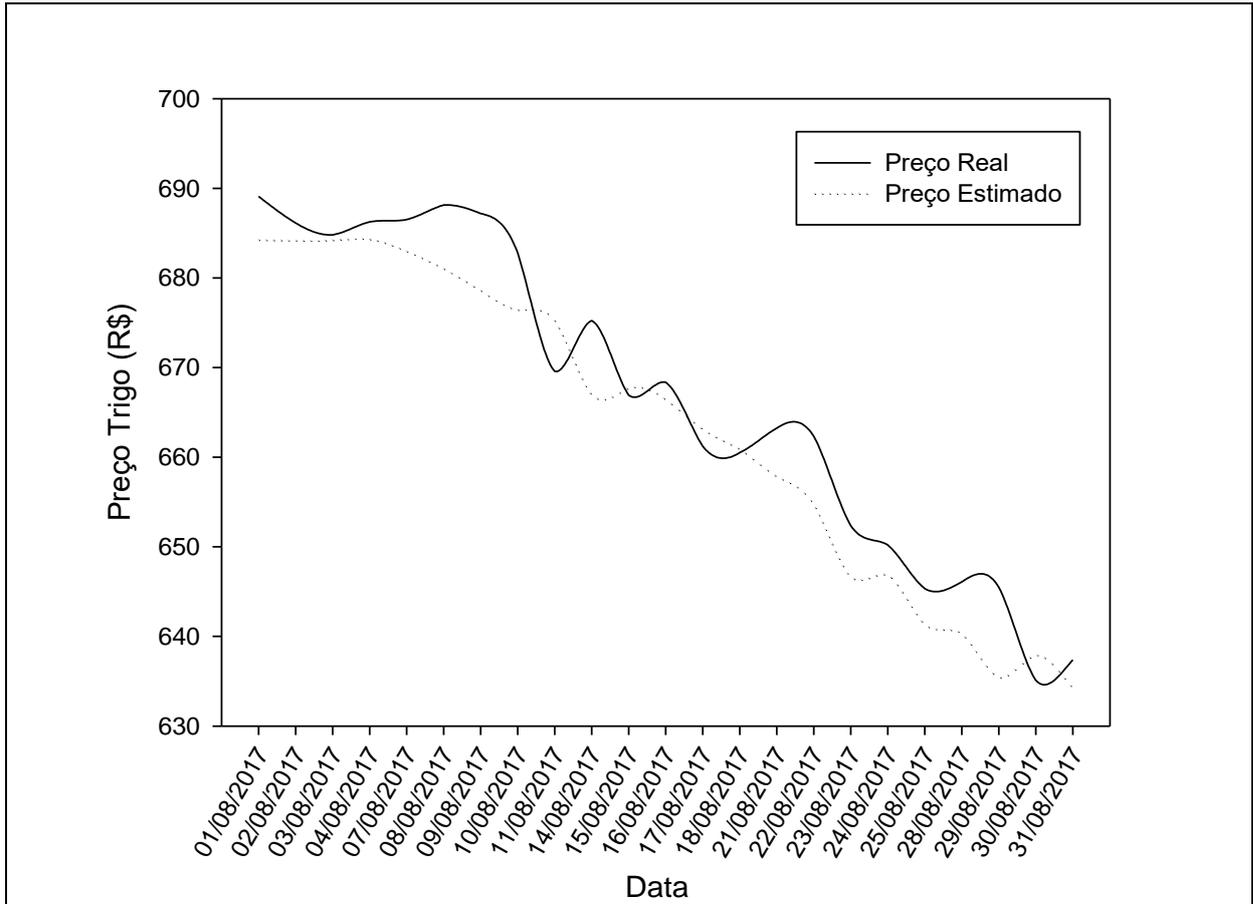


Figura 30 – Cenário de preços para o Trigo
 Fonte: elaborada através do software SigmaPlot

Observando-se a Figura 30, verifica-se que a arquitetura de rede escolhida conseguiu prever o comportamento de queda dos preços ao longo do mês. O ápice do valor do preço da tonelada do trigo no mercado futuro foi no início do mês, mais precisamente no dia 8 de agosto. Enquanto isso, percebe-se que o menor valor ocorreu no último dia do mês. O valor do coeficiente de determinação foi de 0,948 para este período.

5 CONSIDERAÇÕES FINAIS

O comportamento dos preços das *commodities* agrícolas varia no mercado devido à diversos fatores, os quais são complexos de controlar. Este estudo buscou, através da previsão de preços por meio das redes neurais artificiais, analisar a previsibilidade das redes no intuito de fornecer um auxílio aos investidores deste mercado dinâmico para melhor gerirem seus negócios e tomarem decisões de forma mais segura, reduzindo riscos.

Foram desenvolvidas redes capazes de prever o preço diário, no mercado futuro, das *commodities* açúcar, algodão, arroz, café, milho, soja e trigo com índice de desempenho acima de 0,85, ou seja, classificadas conforme Carmargo e Sentelhas (1997) como ótimas. Quanto à arquitetura das redes selecionadas, as variáveis de entrada utilizadas foram a data a ser prevista e preços de dias anteriores à saída, dados os quais mostraram-se suficientes para garantir redes com alto desempenho. Durante os testes, além do número de variáveis de entrada, também se alterou o número de neurônios, função de ativação e número de camadas.

Observou-se que as melhores arquiteturas encontradas variaram para cada *commodity*, pois o número de entradas oscilou de dois a cinco e o número de neurônios de 10 a 50. Já a função de ativação e o número de camadas manteve-se constante para todas as *commodities*, sendo a função que demonstrou os melhores resultados a tangente hiperbólica e o número de camadas ficou em duas.

Através da construção dos cenários, pôde-se observar na prática a funcionalidade das redes neurais para a previsão dos preços das *commodities*. Para o mês de agosto de 2017, foram previstas redes com coeficiente de determinação de: 0,968 para o açúcar; 0,949 para o algodão; 0,775 para o arroz; 0,849 para o café; 0,974 para o milho; 0,834 para a soja e 0,948 para o trigo. Tais valores apresentam o quanto as variações dos preços reais estão explicando as variações dos preços previstos. Apesar das redes demonstrarem maiores divergências nos valores de previsão dos preços quando se aumentou o período de previsão de um dia para um mês, elas mostraram-se capazes de captar as grandes variações de altas e baixas dos preços ao longo do período avaliado.

O método das redes neurais artificiais mostrou-se fácil e rápido de ser utilizado, obtendo-se resultados satisfatórios nas primeiras arquiteturas de redes testadas. Nesta pesquisa, conforme os resultados dos testes, optou-se por variar os parâmetros das redes de acordo com o comportamento de desempenho das redes, sem esgotamento das possibilidades. Apesar dos bons resultados em testes iniciais, buscou-se o melhor desempenho mesmo que com pequenas variações nos resultados, pois trata-se da previsão de preços, onde centavos de

diferença podem acarretar perdas significativas em grandes investimentos. Vale ressaltar que a escolha de um banco de dados, com um número vasto de observações de preços foi essencial para o aprendizado e, conseqüentemente, sucesso de predição das redes.

Ao se obter redes ótimas, foi possível construir cenários plausíveis para se apurar o comportamento dos preços diários das *commodities* agrícolas, no intuito de verificar e exemplificar o uso das RNAs como ferramenta estratégica no processo decisório. Assim, possíveis interessados em investir no mercado futuro das *commodities* agrícolas consideradas neste estudo, tem a possibilidade de observar o aumento e a queda dos preços nos períodos desejados, podendo tomar suas decisões de compra e venda com menores riscos, tendo em vista a alta previsibilidade das redes. Contudo, por se tratarem de redes que preveem preços diários com base em preços de dias anteriores, o erro de previsão cresce conforme se aumenta o período de tempo dos cenários, pois se trata de prever preços com base em previsões das próprias redes.

Os resultados desta pesquisa mostraram-se promissores, indo ao encontro de estudos como o de Coelho Júnior et al. (2013) e Gaio, Castro Jr. e Oliveira (2007), os quais também demonstraram sucesso no uso das redes neurais artificiais para a previsão de preços de *commodities*. Portanto, considerando os bons resultados encontrados e visando dar continuidade a este trabalho, tem-se como sugestões para estudos futuros: a complementação desta pesquisa através da construção de redes das demais *commodities* que apresentam banco de dados de preços mantidos pelo Cepea, tais como: bezerro, boi, citros, etanol, frango, leite, mandioca, entre outros e; a construção de um aplicativo para dispositivos móveis, que possa ser disponibilizado via *web*, no intuito de tornar as redes neurais úteis, aplicáveis e acessíveis aos interessados no mercado de comercialização de *commodities* agrícolas, com a intenção de tornar o processo de tomada de decisão mais fácil e seguro em um setor dinâmico, competitivo e tão importante para a economia brasileira.

REFERÊNCIAS

- AMARAL, A. Utilização de Sistemas de Inteligência Artificial no Processo Estratégico de Tomada de Decisão. 2010. Disponível em: < <http://assuntodeuniversitario.blogspot.com.br/2010/05/utilizacao-de-sistemas-de-inteligencia.html>>. Acesso em: 11 fev. 2017.
- ANDERSON; D.; SWEENEY, D.; WILLIAMS, T. **Estatística aplicada à administração e economia**. 2 ed. São Paulo: Pioneira Thomson Learning, 2007.
- ANSOF, I. **Estratégia Empresarial**. São Paulo: Mcgraw-Hill, 1977.
- ANSOF, I. **A nova estratégia empresarial**. São Paulo: Atlas, 1990.
- ARARIBOIA, G. **Inteligência Artificial**. Rio de Janeiro: Ed. LTC, 1988.
- ARAÚJO JR, C.; SILVA, L.; SILVA, M.; LEITE, H.; VALDETARO, E.; DONATO, D.; CASTRO, R. Modelagem e prognose do preço de carvão usando um sistema neuro-fuzzy. **Cerne**, v. 22, n. 2, p. 151-158, 2016.
- BERTONCINI, C.; BRITO, A.; LEME, E.; SILVA, I.; SILVA, T.; PERRI, R. Processo decisório: a tomada de decisão. **Revista FAEF**, Garça, v. 5, n. 3, p. 8-34, 2013. Disponível em: < http://faef.revista.inf.br/imagens_arquivos/arquivos_destaque/QjxDDqGcS5r3dHL_2013-5-3-12-8-34.pdf> . Acesso em: 8 fev. 2017.
- BM&FBOVESPA. BM&FBOVESPA S.A. – Bolsa de Valores, Mercadorias e Futuros, 2010. Disponível em: < http://ri.bmfbovespa.com.br/ptb/974/DFsBVMF122010_port.pdf>. Acesso em: 19 fev. 2017.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. 1 ed. Rio de Janeiro: LTC, 2000.
- BRANCO, A. **A produção de soja no Brasil: uma análise econométrica no período de 1994-2008**, 2008. Monografia (Bacharelado em Ciências Econômicas) – Faculdade de Ciências Econômicas do Centro de Economia e Administração da PUC, Campinas, 2008.
- BRESSAN, A. Previsão de preços com um modelo de redes neurais artificiais. **Reuna**, v. 1, n. 10, 1999.
- BRESSAN, A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE - eletrônica**, v. 3, n. 1, Art. 9, jan./jun, 2004.
- CAMARGO, A.P.; SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v.5, p.89-97, 1997.
- CAMPOS, E. Matérias-primas que afetam a inflação têm alta pelo 2º mês, aponta IC-Br. **Valor econômico**, 3 nov. 2016. Disponível em: <

<http://www.valor.com.br/brasil/4764413/materias-primas-que-afetam-inflacao-tem-alta-pelo-2-mes-aponta-ic-br>>. Acesso em: 22 fev. 2017.

CARAVANTES, G.; PANNO, C.; KLOECKNER, M. **Administração: teorias e processo**. São Paulo: Pearson, 2005.

CARVALHO, A.; LUDEMIR, A. **Fundamentos das Redes Neurais Artificiais: 11ª Escola de computação**. Imprinta Gráfica e Editora Ltda, 1998.

CASTRO, J. As commodities e seu impacto na economia do Brasil, 2016. **Nexo**, 31 mar. 2016. Disponível em: < <https://www.nexojornal.com.br/explicado/2016/03/31/As-commodities-e-seu-impacto-na-economia-do-Brasil>>. Acesso em: 18 fev 2017.

CAVALHEIRO, E.; VIEIRA, K.; ROSA, A.; ROHDE, L.; COSTA, C. Efficiency and predictability on international soybean oil prices. **Wseas transactions on business and economics**, v. 13, p. 444-456, 2016.

CEPEA. Centro de Estudos Avançados em Economia Aplicada - CEPEA-Esalq/USP: Pib do Agronegócio Brasileiro, 2016. Disponível em: <<http://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>>. Acesso em: 20 fev. 2017.

CEPEA. Centro de Estudos Avançados em Economia Aplicada: Sobre o CEPEA. Disponível em: < <http://www.cepea.esalq.usp.br/br/sobre-o-cepea.aspx>>. Acesso em: 6 mar. 2017.

CERTO, S. **Administração moderna**. 9. ed. São Paulo: Pearson, p. 123-145, 2005.

COELHO JR, L.; REZENDE, J.; BATISTA, A.; MENDONÇA, A.; LACERDA, W. Use of artificial neural networks for prognosis of charcoal prices in Minas Gerais. **Cerne**, Lavras, v. 19, n. 2, p. 281-288, abr./jun. 2013.

CONAB. Companhia Nacional de Abastecimento – Perspectivas para a Agropecuária, safra 2016/2017, 2016. Disponível em: < http://www.conab.gov.br/OlalaCMS/uploads/arquivos/16_09_13_09_06_46_perspectivas_da_agropecuaria_2016-17_digital.pdf>. Acesso em: 19 fev. 2017.

CORNELIUS, P. et al. Three decades of scenario planning in shell. California: **Management Review**, 48, 92-109, 2005.

DAS, T. L. Intelligent techniques in decision making: a survey. **Indian Journal of Science and Technology**, New Delhi, v. 9, n. 12, p. 1-6, 2016.

DISCONZI, C.; BIDARTE, M.; FERRAZ, R.; FLECK, C. Redes neurais artificiais: um estudo bibliométrico considerando as plataformas SPELL e Scopus. In: **XXXVII Encontro Nacional de Engenharia de Produção**, 2017, Joinville. Anais... Joinville, SC, 2017.

FELICIANI, A.; SOUZA, A.; SOUZA, F. Stochastic models of forecasting prices of soybeans in Brazil. **Custos e @gronegócio on-line**, v. 11, n. 1, jan./mar. 2015.

FERRAZ, R. **Sistema web e mobile para estimativa de evapotranspiração de referência utilizando redes neurais artificiais**, 2013. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2013.

FERREIRA, L.; MOURA, G.; BORENSTEIN, D.; FISCHMANN, A. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **Revista de Administração e Inovação**, São Paulo, v. 8, n. 4, p.6-26, out./dez. 2011.

FINOCCHIO, M. **Determinação da temperatura de enrolamentos de transformadores a seco e de suas perdas totais baseado em redes neurais artificiais**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Londrina, Londrina, 2010.

FORTULAN, M.; GONÇALVES FILHO, E. Uma Proposta de Aplicação de Business Intelligence no Chão-de-fábrica. **Gestão e Produção**, v.12, n.1, p.55-66, jan./abr. 2005.

FUCHS, K., FUMAGALLI, L. A. O uso da inteligência artificial (IA) na formulação da estratégia organizacional: um estudo sobre a aplicação da computação cognitiva em empresas. **Caderno PAIC**, v. 17, n. 1, 2016.

GAIO, L.; CASTRO JR, L.; OLIVEIRA, A. Previsão de preço futuro do boi gordo na BM&F: uma comparação entre modelos de séries temporais e redes neurais. **Organizações Rurais & Agroindustriais**, Lavras, v. 9, n. 2, p. 272-288, 2007.

GEMAN, H. *Commodities and commodities derivatives: modeling and pricing for agriculturals, metals and energy*. **Chichester: Wiley**, 2005.

GIL, A. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2010.

GODET, M. **Manual de prospectiva estratégica: da antecipação à ação**. Lisboa: Dom Quichote, 1993.

GODET, M. **The art of scenarios and strategic planning: tools and pitfalls**. New York: North-Holland, 65, 3-22, 2000.

GUIMARÃES, B. Quão importantes são as commodities para o Brasil? **Folha de São Paulo**, 10 nov. 2015. Disponível em: <http://aeconomianoseculo21.blogfolha.uol.com.br/2015/11/10/quao-importantes-sao-as-commodities-para-o-brasil/>. Acesso em: 18 fev. 2017.

HAIR, Jr., J. F.; ANDERSON, R. E.; TATHAM, R. L. BLACK, W. C. **Análise multivariada de dados**. 5ª ed. Porto Alegre: Bookman, 2005.

HAIR, J. et al. **Fundamentos de Métodos de Pesquisa em Administração**. Porto Alegre: Bookmann, 2005.

HARVEY, R.. L. **Neural Network Principles**. New Jersey: Prentice Hall, 1994.

HAYKIN, S. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001.

HULL, J. **Options, futures, and other derivatives**. Prentice Hall, 2006.

IBGE. Instituto Brasileiro de Geografia e Estatística – Séries Históricas e Estatísticas: Agropecuária, 2014. Disponível em: <http://seriesestatisticas.ibge.gov.br/lista_tema.aspx?op=0&no=1>. Acesso em 19 fev 2017.

IBGE. Instituto Brasileiro de Geografia e Estatística: Censo Agropecuário. Disponível em: <<http://www.ibge.gov.br/home/estatistica/economia/agropecuaria/censoagro/conceitos.shtm>>. Acesso em: 20 fev. 2017.

INFOMONEY. Mercado de commodities agrícolas é alternativa para pequeno investidor?, 2011. Disponível em: <<https://economia.uol.com.br/ultimas-noticias/infomoney/2011/10/24/mercado-de-commodities-agricolas-e-alternativa-para-pequeno-investidor.jhtm>>. Acesso em: 27 Dez. 2017.

KALDOR, N. Speculations and economic stability. **The review of Economic Studies**, v. 7, n. 1, p. 1-27, out, 1939.

KICH, J.; PEREIRA, M. Pensamento estratégico nas organizações. **Revista de Ciências da Administração**, v. 16, n. 39. p. 134-145, 2014.

LIMA, F.; KIMURA, H.; ASSAF NETO, A.; PERERA, L. Previsão de preços de commodities com modelos ARIMA-GARCH e redes neurais com ondaletas: velhas tecnologias – novos resultados. *Revista de Administração*, São Paulo, v. 45, n.2, p.188-202, abr./mai./jun. 2010.

LOURENÇO JR, A.; OLIVEIRA, L.; KILIMNIK, Z. O planejamento de cenários como aprendizado. São Paulo: **Future Studies Research Journal**, v. 2, n. 1, p. 03- 2, jan./jun. 2010.

MAKRIS, G.; POULIAKIS, A.; SIRISTATIDIS, C.; MARGARI, N.; TERZAKIS, E.; KOUREAS, N.; PERGIALIOTIS, V.; PAPANTONIOU, N.; KARAKITSOS, P. Image analysis and multi-layer perceptron artificial neural networks for the discrimination between benign and malignant endometrial lesions: artificial neural networks for endometrial cytology. **Diagnostic cytopathology**, fev. 2017.

MAPA. Ministério da Agricultura, Pecuária e Abastecimento - Produção agropecuária chega a R\$ 516,4 bilhões em 2016, 2016. Disponível em: <<http://www.brasil.gov.br/economia-e-emprego/2016/08/producao-agropecuaria-chega-a-r-516-4-bilhoes-em-2016-1>>. Acesso em: 20 fev. 2017.

MARCIAL, E.; GRUMBACH, R. **Cenários prospectivos: como construir um futuro melhor**. Rio de Janeiro: FGV, 2002.

MAXIMIANO, A. **Introdução à Administração**. Ed. Compacta. São Paulo: Atlas, 2009.

MENEZES, I. **Revisão da literatura empírica acerca das variáveis que impactam a precificação de commodities agrícolas: Soja, milho, café e boi gordo**, 2015. Monografia (Bacharelado em Ciências Contábeis) – Universidade de Brasília, Brasília, 2015.

MIETZNER, D.; REGER, G. **Scenario Approaches: history, differences, advantages and disadvantages**. Proceedings of the Eu-Us Seminar: New Technology Foresight, Forecasting & Assessment Methods, Seville, Spain, 3–14, mai. 2004.

MIRANDA, A., CERETTA, P., LOPES, L. Estratégias de mercado acionário utilizando previsão de redes neurais Em comparação com modelos autorregressivos. **Rev. Adm. UFSM**, v. 8, número 1, p. 42-59, Mar. 2015.

MORITZ, G.; PEREIRA, M. Planejamento de cenários: A evolução do pensamento prospectivo. **Revista de Ciências da Administração**, v. 7, n.13, jan/jul, 2005.

MORITZ, G.; PEREIRA, M. **Processo decisório**. Florianópolis: SEAD/UFSC, 2006.

MOURA, A.; ANDRADE, D.; KIKUCHI, W. Inteligência Artificial Aplicada no Auxílio a Tomadas de Decisões na Área de Saúde, 2005. Rio de Janeiro. *Anais...* Rio de Janeiro: II Simpósio de Excelência em Gestão e Tecnologia – SEGeT'2005. Disponível em: <http://www.aedb.br/seget/arquivos/artigos05/293_Inteligencia%20Artificial%20Aplicada%20no%20Auxilio%20a%20Tomadas%20de%20Decisoes%20na%20Area%20de%20Saude.pdf>. Acesso em: 11 fev. 2017.

NIKOLOPOULOS, C. **Expert systems**. New York: Marcel Dekker, Inc., 1997.

PALIWAL, M.; KUMAR, U. A. Neural networks and statistical techniques: A review of applications. **Expert Systems with Applications**, v. 36, n.1 p. 2-17, 2009.

PENEDO, A.; PACAGNELLA JR., A; OLIVEIRA, M. Previsão de preços do açúcar utilizando redes neurais artificiais. **Nucleus**, v. 4. n. 1-2, set. 2007.

PEREIRA, L. **Modelo de formação de preços de commodities agrícolas aplicado ao mercado de açúcar e álcool**, 2009. Tese (Doutorado em Administração) – Universidade de São Paulo, São Paulo, 2009.

PEREIRA, F.; BARROS, M.; OLIVEIRA, A.; GOMES, C.; COSTA, H. Cenários prospectivos: estudo bibliométrico de artigos indexados na base Scopus, 2015. Fortaleza. *Anais...* XXXV Encontro Nacional de Engenharia de Produção. Perspectivas Globais para a Engenharia de Produção, Fortaleza, 2015.

PERETTO, P. **An Introduction to the Modeling of Neural Network**. Cambridge: Cambridge University, 1992.

PINHEIRO, C.; SENNA, V. Previsão de Preços Através da Análise Espectral Multivariada: Evidências para Commodities da BM&Fbovespa. **Brazilian Business Review**, v. 13, n. 5, p. 133 - 162, set./out. 2016.

PINHEIRO, C.; SENNA, V. Multivariate analysis and neural networks application to price forecasting in the Brazilian agricultural Market. **Ciência Rural**, v.47, n.1, 2017.

PINHEIRO, C.; SENNA, V.; MATSUMOTO, A. Price forecasting for future contracts on agribusiness through neural network and multivariate spectral analysis. **Revista de Gestão, Finanças e Contabilidade**, v. 6, n. 3, p. 98-124, set./dez. 2016.

PRIMAK, Fábio Vinicius. Uma introdução simplista aos conceitos de Business Intelligence - Parte 2. 2009. **Oficina da Net**, 10 nov. 2009. Disponível em: <https://www.oficinadanet.com.br/artigo/2132/uma_introducao_simplista_aos_conceitos_de_business_intelligence_-_parte_2>. Acesso em: 11 fev. 2017.

REINKE, M. **Utilização de redes neurais artificiais aplicadas a mapeamento hidrogeológico**, 2008. Dissertação (Mestrado em Geologia), Universidade do Vale dos Sinos, São Leopoldo, 2008.

ROBBINS, S.; JUDGE, T.; SOBRAL, F. **Comportamento organizacional: teoria e prática no contexto brasileiro**. 14. ed. São Paulo: Pearson, 2010.

ROBINSON, S. et al. Knowledge-based improvement: simulation and artificial intelligence for identifying and improving human decision-making in an operations system. **Journal of the Operational Research Society**, Oxford, 2005.

ROMAN, D. J.; OSINSKI, M.; SELIG, P. M. Análise do processo decisório nas organizações de gestão social: estudo de caso da organização WSH. **Gestão e Desenvolvimento, Novo Hamburgo**, v. 13, n. 1, p. 130-143, 2016.

SANTOS, M.; RAMOS, I. Business Intelligence : tecnologias da informação na gestão de conhecimento. **FCA Editora de Informática**, Lisboa, p. 2-10, 2006.

SANTOS, M.; SOUZA, D.; PENEDO, A.; MARTINS, E. Aplicação de redes neurais no Brasil: um estudo bibliométrico. **Biblionline**, João Pessoa, v. 12, n. 2, p. 101 – 116, 2016.

SARTURI, G.; MASCENA, K. Evolução dos métodos de cenários, 2012. São Paulo. *Anais...* São Paulo: XV SemeAd, out. 2012.

SCHWARTZ, P. **The art of long view: planning for the future in a uncertain world**. New York: doubleday, 1996.

SILVA, A.; RAMOS, R.; SOUZA, L.; RODRIGUES, D.; MENDES, J. **SIG – Uma plataforma para introdução de técnicas emergentes no planejamento urbano regional e de transportes: uma ferramenta 3D para análise ambiental urbana: avaliação multicritério, redes neurais artificiais**. São Carlos: Editora dos Autores, 2004.

SOBREIRO, V.; ARAÚJO, P.; NAGANO, M. Precificação do etanol utilizando técnicas de redes neurais artificiais. **Revista de Administração**, São Paulo, v. 44, n. 1, p. 46-58, jan./fev./mar. 2009.

TEWELES, R.; HARLOW, C.; HERBERT, L. **O jogo das commodities: Quem ganha? Quem perde? Por quê?** Belo Horizonte: Brasimex Com Imp Exp Ltda, 1983.

UNCTAD. United Nations Conference on Trade and Development, 2014. Disponível em: <http://unctad.org/en/PublicationsLibrary/suc2014d7_en.pdf>. Acesso em: 15 fev 2017.

USDA. USDA - United States Department of Agriculture: Brazil, 2017. Disponível em: <<https://www.fas.usda.gov/regions/brazil>>. Acesso em: 19 fev. 2017.

VALENÇA, M. **Aplicando redes neurais: um guia completo**. Olinda: Livro Rápido, 2005.

VALENÇA, M. **Fundamentos das Redes Neurais**. 2. ed. Recife: Livro Rápido, 2010.

VALOR ECONÔMICO. Commodities agrícolas atraem investidores, 2012. **Valor Econômico**, 20 nov. 2012. Disponível em: <<http://www.valor.com.br/empresas/2910170/commodities-agricolas-atraem-investidores>>. Acesso em: 12 fev. 2017.

VENUGOPAL, V.; BAETS, W. Neural Networks and Their Applications in Marketing Management. **Journal of Systems Management**, v. 45, n. 9, p. 16-21, 1994.

WRIGHT, P.; KROLL, M.; PARNELL, J. **Administração estratégica: Conceitos**. São Paulo: Atlas, 2010.

ZAMPIERI, A., CASTRO, J. Bolsa sobre mais de 3% com commodities; dólar sai na casa de R\$ 3,25. **Valor econômico**, 3 jan. 2017. Disponível em: <<http://www.valor.com.br/financas/4824336/bolsa-sobe-mais-de-3-com-commodities-dolar-sai-na-casa-de-r-325>>. Acesso em: 22 fev. 2017.

APÊNDICES

APÊNDICE A – Matriz de pesos e bias da rede do açúcar

	Pesos w11			Pesos w21		B1	B2
1,9757	0,51107	-2,0356	-0,56363	0,27691	-0,37802	-2,9872	-0,34068
2,7464	0,70287	0,029532	0,55568	1,1195	0,12622	-3,0252	
-0,41521	0,37028	1,3186	1,9489	1,2623	0,6034	-2,9829	
2,1983	0,94192	0,48351	0,38779	-1,9073	0,053815	-1,9918	
0,093011	-0,95435	-0,020198	-2,1212	1,8591	-0,84284	2,1994	
-1,3319	-2,1423	1,4905	0,18476	0,29089	-0,29588	2,2309	
0,27929	0,48391	0,51778	-1,3525	-2,5181	-1,0946	-2,8513	
0,39883	-2,7137	-2,793	-0,16067	-1,367	1,8855	-6,2391	
-0,30098	4,5779	0,67891	-0,26246	0,000796	4,0999	-5,134	
0,30432	-1,5858	-1,917	-1,969	-0,55343	-0,15575	2,3229	
-0,22057	2,2477	0,20635	-0,6593	1,7872	2,3337	3,7965	
-1,6477	-0,7809	0,89421	0,83507	1,0207	0,16792	1,0346	
-0,80773	-0,97422	-2,2902	1,4829	0,0038266	0,46399	0,97836	
-1,4851	0,5221	1,5949	0,5713	1,8753	-0,1844	0,077031	
1,23	1,2142	-0,97226	1,745	1,0928	0,0057392	-1,0607	
1,0444	-1,4439	-1,255	-2,2695	0,50179	0,19972	-1,1476	
1,8248	1,2953	-1,7513	0,3315	1,0877	0,22315	-0,29632	
-0,75288	0,83749	-2,4218	-0,95729	1,5125	-0,60928	0,63504	
-1,0904	-2,01	-0,29818	0,07725	-2,0003	-0,19113	1,412	
-0,36498	2,6143	-1,047	-1,4034	0,49497	0,92512	0,049661	
1,0691	0,98671	-2,3754	-0,99314	0,53554	-0,72215	0,15608	
0,94778	0,99478	-0,37693	-2,4176	-1,5021	1,1744	1,4492	
0,31603	-1,6274	-1,7933	-0,46649	2,3263	1,1209	1,1897	
-1,4626	-0,48372	-0,72925	-0,6817	-1,8968	-0,076709	-0,099433	
1,4563	-2,4185	0,091137	-1,021	-1,1145	1,4303	2,7802	
0,91812	-0,67188	-0,46555	-0,88918	2,3526	-0,67079	0,80738	
-0,21512	0,82943	-0,65669	2,0411	-1,1381	0,53696	-1,3425	
-2,772	0,30937	-1,0557	-1,2194	0,72163	-0,14738	-0,68192	
-1,2487	-0,95233	-0,55641	-0,13932	2,8692	0,87365	-1,4146	
-1,7195	1,5312	-1,0061	-1,5393	-0,69059	-0,30643	-1,6563	
0,13644	-2,5723	-3,0417	-0,11592	0,92135	-4,7726	-5,0826	
1,7263	1,4099	-1,1773	-0,27793	0,47978	0,59304	1,7301	
0,40125	-1,2562	-0,91446	-0,41224	-1,5106	0,78457	-2,7986	
-1,8453	0,38099	1,5816	2,2157	0,55338	0,70975	-2,175	
-0,13226	2,1882	0,010969	-1,7972	-0,50307	0,20793	-2,287	
-2,156	1,2253	1,3032	-0,26586	0,71822	-0,069745	-2,308	
-0,71305	0,09021	2,0013	-1,9813	0,34869	0,25188	-2,4711	
-2,2144	0,53094	-1,362	1,3307	0,093531	-0,43955	-2,4214	
1,4806	1,0851	-1,5321	-0,8873	-0,91155	-1,0368	3,3868	
-0,71617	1,293	-1,9245	0,091047	1,6324	0,040523	-2,935	

APÊNDICE B – Matriz de pesos e bias da rede do algodão

	Pesos w11			Pesos w21	B1	B2
-0,0013432	-3,4118	-1,0188	-0,19818	-3,5799	-5,0418	-1,06
0,14997	-0,51754	-1,208	-3,3422	1,4568	-4,8224	
1,5709	2,8045	2,0223	-1,215	3,5587	-2,985	
-0,54587	-0,16293	0,14248	3,6375	-0,31088	-3,0707	
-0,062748	-0,62005	0,28291	-3,255	-0,025211	-0,2259	
0,0092586	1,3358	-0,27887	-0,31314	1,3699	0,55133	
1,4533	-0,77651	0,43755	-1,0751	0,045869	-0,042923	
1,2916	-0,84692	-0,1464	-0,41974	-0,037609	0,20907	
-0,28484	2,2125	-0,96991	1,8126	0,35012	-1,9541	
0,23242	0,60947	-1,3097	-2,1643	-1,8478	-3,4014	

APÊNDICE C – Matriz de pesos e bias da rede do arroz

Pesos w11		Pesos w21	B1	B2
-3,6856	-3,2557	-1,4359	8,0591	-0,32367
-2,4056	5,8453	0,31709	6,7732	
-3,014	7,836	3,8087	-6,2141	
-0,11399	7,4761	4,2286	8,3016	
7,2023	1,0381	-0,51252	-5,3075	
6,5257	3,115	0,33634	-5,6691	
0,59982	-4,147	-0,33786	-2,9964	
4,1214	3,7941	-0,090553	-4,7044	
6,6852	-0,74826	0,26651	-4,3031	
-3,2188	-6,7045	-0,057312	2,6865	
-1,5423	3,1845	0,22279	0,54459	
-4,6317	-3,9989	0,054548	2,7669	
2,5396	-5,7683	0,056883	-0,61329	
8,7942	2,4254	-0,0082095	-0,34004	
7,116	3,2215	0,015982	-1,2946	
0,62689	7,2941	0,030367	-0,58685	
-3,4984	-5,5303	-0,022771	0,33984	
0,27767	1,3343	1,6709	-1,7521	
4,6998	-4,6211	-0,030284	2,7884	
1,8977	4,2119	0,13745	2	
8,2378	0,87217	0,27249	6,668	
6,6913	2,3991	0,34825	4,3012	
-0,45964	-6,669	0,028105	-2,5977	
-9,4085	-0,59468	-1,1944	-5,9582	
6,9103	0,90467	-1,8668	4,664	
-4,6183	5,8866	-0,426	-5,9534	
-5,7443	-5,1133	-0,18604	-6,8845	
-7,3587	2,0082	0,1115	-7,8038	
5,5524	-5,279	0,064649	7,1502	
7,7873	-3,3004	1,6245	7,2673	

APÊNDICE D – Matriz de pesos e bias da rede do café

	Pesos w11			Pesos w21	B1	B2
0,029837	1,1394	-0,089624	-0,048679	-3,1237	0,43748	-2,691
-13,8514	6,21	-3,328	4,876	0,083372	-16,2715	
3,5482	4,5514	9,6566	-2,3341	2,3099	-18,2655	
-4,8595	4,7994	1,5461	1,9316	3,1296	4,4645	
-0,40422	0,38995	0,27245	-0,066718	-8,7821	5,5525	
-0,94955	5,9961	6,4956	-6,9346	-0,035699	2,319	
-7,913	6,0119	4,7832	0,26798	-2,4035	8,046	
-4,318	7,8526	11,3915	-9,0192	9,4488	16,1316	
-6,3777	-6,094	0,1794	1,0425	-0,66821	0,60724	
-0,014367	-0,53899	0,022976	0,018948	-10,374	-0,61743	

APÊNDICE E – Matriz de pesos e bias da rede do milho

	Pesos w11		Pesos w21	B1	B2	
	2,3188	1,3182	-2,6969	-0,29516	-3,824	0,74668
	0,54765	-2,0044	2,9547	-0,94826	-3,7255	
	-2,9093	2,5632	1,0511	-0,052006	2,6085	
	-0,38338	-3,4882	1,0526	-2,0013	3,0813	
	-3,1249	-0,87128	1,088	-0,11374	2,4113	
	-2,0504	2,7725	-1,7121	0,17271	1,563	
	2,6066	0,78821	2,498	0,04157	-1,2575	
	-0,29848	-2,2887	-2,1907	-0,087984	1,5332	
	0,64134	-3,1355	0,070688	-0,2204	-0,71628	
	1,1399	-1,5727	3,2299	0,013586	-0,23256	
	2,3067	-1,5517	2,4087	0,074633	0,31718	
	-2,7804	-2,2103	-0,65806	-0,07139	-0,36089	
	-3,1678	-1,3394	-1,7078	0,031414	-0,89821	
	1,8562	-3,429	1,597	-0,75825	1,5671	
	2,7909	-1,0757	2,1365	-0,079802	2,04	
	-3,4865	-1,0027	-0,99865	-0,10112	-2,2033	
	2,992	-1,5586	-0,47207	0,41161	2,1753	
	1,8769	2,8198	0,68845	0,11836	3,417	
	0,42351	-0,42209	3,6693	0,63156	3,6742	
	-0,77385	-3,6685	1,3712	0,51092	-3,7256	

APÊNDICE F – Matriz de pesos e bias da rede da soja

	Pesos w11			Pesos w21		B1	B2
-1,8318	1,4863	0,62617	1,2239	7,293	2,9581	-1,4956	
1,0612	-0,89844	-2,8185	1,4934	0,99107	-3,9875		
2,1545	-1,9808	0,39295	0,63509	1,3722	-4,7308		
1,148	0,60568	-2,4712	-2,3247	0,89362	-3,3327		
-1,3641	2,1355	-1,6197	-2,339	0,82089	3,4198		
0,53881	2,6574	1,3405	1,1646	-1,6829	2,4022		
0,26393	-2,1545	2,3522	-1,9003	0,78157	-2,8677		
0,8562	2,0946	-1,6085	-2,5136	-0,47204	-2,5636		
-2,3676	1,6285	-2,0721	0,58519	-0,61948	3,5878		
1,7597	2,8537	1,3933	-0,37399	-0,053456	-2,3589		
1,4451	4,4644	1,6485	-0,37166	-0,0032264	-1,1778		
0,36289	-1,5543	2,1392	2,695	-0,6452	1,9231		
1,6789	-1,709	0,62183	-2,8344	-0,11507	-1,9761		
-0,35004	-1,8341	-2,2078	0,50273	-5,7924	-2,3162		
-0,62358	-1,8762	1,6036	2,8504	-0,22934	3,5585		
-0,74995	-1,3432	-1,0504	2,9043	1,5681	1,5876		
6,2488	-0,98755	-3,6385	-2,3615	0,065943	-3,9535		
-0,5158	-0,036583	3,3025	-2,6808	-0,40144	-2,9366		
0,46798	2,9527	-0,16637	-1,9188	0,23847	-1,7385		
-1,9187	0,44473	0,064279	-0,98174	-0,51906	1,9411		
0,099471	4,1914	4,1045	0,29487	-0,044167	-1,0312		
3,9848	0,55462	0,54407	-1,6545	0,090805	-0,58005		
0,38637	0,1234	1,0683	-3,6364	0,53683	1,1195		
-2,3266	0,40388	1,9191	2,7832	-2,6735	2,9001		
2,4403	-0,79111	2,566	-2,1228	0,14264	-4,8856		
-0,15039	1,9624	0,8857	-1,0018	-1,7449	-8,1813		
0,73806	1,0104	-2,9005	2,2715	-1,011	1,0277		
-2,6204	0,51729	2,5912	1,8838	-0,13176	-0,29981		
2,5208	2,4958	-1,6044	2,4083	0,55775	0,42985		
-0,94223	-1,5799	2,0689	2,2503	0,19941	-1,1233		
2,462	0,42251	3,3308	0,98083	0,56716	1,2143		
0,94174	-1,4194	0,1944	-1,5381	-0,94747	0,37467		
2,7433	-1,1316	-2,3369	2,1152	0,42	0,89027		
-2,925	1,6979	-2,2618	-0,45776	-0,019633	-1,3012		
-1,4911	1,0723	0,42635	-2,2502	0,43841	-1,3752		
1,3608	1,7611	-2,7005	1,155	0,42206	1,3624		
0,86064	1,6427	0,54771	3,0599	0,58087	2,2579		
-0,3007	-0,93728	-2,6771	1,0579	2,8311	-2,0039		
-0,49794	-3,3887	-1,7185	0,80821	1,5214	-3,1495		

-0,27451	-2,0006	-0,018113	-1,2274	-1,4878	3,8709
-1,8719	-4,2814	-3,1641	0,66869	-0,85843	-2,3827
0,15002	1,4285	2,3395	1,168	5,0353	5,1199
0,84604	-0,36425	-0,15547	-2,7175	1,1265	3,1861
-2,472	-0,77297	2,4463	0,51714	0,38181	-3,2316
-1,2829	2,3276	-0,28806	1,3415	1,2335	-2,6333
-2,0795	-3,1379	-1,958	-0,50907	1,9299	-1,6483
2,0413	1,6927	-1,8418	-1,8215	-0,37614	3,4261
0,24131	-3,0145	1,5939	1,3994	-1,2481	3,5101
-1,6689	0,18779	-1,5301	1,4287	1,7373	-4,0223
-0,36058	-1,8991	3,1519	-0,40188	1,2687	-3,7464

APÊNDICE G – Matriz de pesos e bias da rede do trigo

	Pesos w11	Pesos w21	B1	B2
	4,2007	-6,6803	-0,080545	-7,0725
	1,1665	-9,6609	-0,28856	6,0223
	-2,5496	-6,218	0,96851	7,8806
	1,4844	7,4198	0,56693	-4,5602
	2,9812	6,6007	-1,0583	-5,2372
	-4,1276	-5,7815	0,56973	4,7747
	6,7052	3,3684	0,82391	-3,0442
	7,031	-3,0394	0,044147	-4,5646
	8,5545	0,87467	0,43018	-3,5371
	6,6047	2,2854	-1,3096	-2,9229
	2,8641	-6,9276	-0,028694	-2,2955
	-0,71153	6,13	0,10042	1,3085
	-6,6709	-1,2326	0,068584	1,2214
	-2,7441	-4,372	-1,4001	3,7158
	-1,0342	5,1389	0,11743	-0,23791
	4,2538	5,298	0,84556	-0,13651
	6,2509	4,3838	0,003411	1,92
	-3,4284	-7,001	0,1496	0,28639
	5,9069	6,2053	-0,56381	-0,2467
	5,8941	5,7918	0,015462	1,5094
	-0,41845	-6,2648	-0,092778	-3,0552
	-0,099592	-5,0249	-0,2752	-3,6102
	6,2415	-5,6819	0,056257	4,2895
	-6,6852	-2,8507	-0,11108	-4,7642
	5,8272	4,449	-0,1078	5,1629
	3,4271	-6,389	-0,047653	6,2748
	2,5038	-6,641	-0,70736	6,9619
	-5,1984	5,489	1,1914	-6,7621
	0,74014	-7,5009	-1,3008	7,2001
	-0,14366	6,7972	3,2948	7,3858