

**DETERMINANTES DO COMPORTAMENTO DOS PREÇOS DO CAFÉ
BRASILEIRO: UMA ABORDAGEM DE REDES NEURAIS ARTIFICIAIS**

**DETERMINANTS OF BRAZILIAN COFFEE PRICE BEHAVIOR: AN ARTIFICIAL
NEURAL NETWORKS APPROACH**

Eunice Henriques Pereira Vilela¹
Antonio Sérgio Torres Penedo²

RESUMO: Buscando oferecer uma alternativa para a gestão de riscos aos produtores e gestores que precisam realizar negociações em um mercado inerentemente instável, este trabalho teve como objetivo elaborar e validar um modelo de previsão para o comportamento de preços do café brasileiro através do uso de Redes Neurais Artificiais (RNAs). Para a definição da estrutura das RNAs foram testados e avaliados diferentes combinações de variáveis, totalizando doze arranjos com diferentes grupos de variáveis. Os resultados desses modelos foram avaliados por métricas de erro e o modelo com melhor resultado preditivo submetido ao processo de validação. Os resultados indicam que o modelo composto pelas variáveis custos com máquinas, mão de obra, fertilizantes, defensivos, despesas financeiras, juros, câmbio, imposto, consumo, exportação, estoques e produção de café no Brasil na configuração com 13 neurônios na primeira camada escondida e 1 neurônio na segunda camada escondida apresentou a melhor capacidade preditiva, com um MSE de 0,0958 e um R^2 0,8394.

PALAVRAS-CHAVE: Cafeicultura; Redes Neurais Artificiais; Gestão de Riscos.

ABSTRACT: *Seeking to offer an alternative for risk management to producers and managers who need to conduct negotiations in an inherently stable market, this work aimed to develop and validate a forecasting model for price behavior of Brazilian coffee through the use of Artificial Neural Networks (ANNs). To define the structure of the ANNs, different combinations of variables were tested and evaluated, totaling twelve arrangements, the definition of which was made in order to merge different groups of variables. The results of these models were evaluated using error metrics and the model with the best predictive result submitted to the validation process. The results indicate that the model composed of the variables costs with machines, labor, fertilizers, pesticides, financial expenses, interest, foreign exchange, tax, consumption, exports, stocks and coffee production in Brazil in the configuration with 13 neurons in the first hidden layer and 1 neuron in the second hidden layer showed the best predictive capacity, with an MSE of 0.0958 and an R^2 0.8394.*

KEYWORDS: *Coffee production; Artificial Neural Networks; Risk management.*

1- Doutora em Administração pela Universidade Federal de Uberlândia (UFU). Mestre em Administração pela Universidade Federal de Uberlândia (UFU). Bacharel em Ciências Econômicas pela Universidade Federal de Uberlândia (UFU). Endereço: Av. João Naves de Ávila 2121 Campus Santa Mônica - Uberlândia-MG CEP 38400-100. E-mail:eunice.hvilela@gmail.com.

2- Professor Adjunto II da Universidade Federal de Uberlândia (UFU). Doutor em Engenharia de Produção pela Universidade Federal de São Carlos (UFSCar). Mestre em Administração pela Universidade de São Paulo (USP). Graduado em Engenharia Mecânica pela Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP). Endereço: Av. João Naves de Ávila 2121 Campus Santa Mônica - Uberlândia-MG CEP 38400-100. E-mail:drpenedo@gmail.com.

1. INTRODUÇÃO

A cafeicultura representa uma atividade de elevada relevância socioeconômica no desenvolvimento brasileiro, com importante participação na pauta de exportações do país (MAPA, 2018). Em 2018 foram produzidas 61,66 milhões de sacas de café (ABIC, 2019), que representam cerca de 35% da produção mundial. A cafeicultura, contudo, caracteriza-se como uma atividade de elevado risco por tratar-se de uma cultura altamente dependente de fatores fisiológicos, tratamentos culturais e ambientais. Berhane et al. (2019) definem o mercado de café como inerentemente instável e marcado por grandes flutuações de preço, sendo a volatilidade dos preços uma grande preocupação para as partes interessadas nesse mercado.

Sua produção e comercialização necessitam, portanto, de instrumentos que minimizem o risco e auxiliem no processo de tomada de decisão dos produtores, compradores e investidores em geral (BRESSAN; 2004). Entre as principais ferramentas que podem ser utilizadas para avaliar e gerenciar os riscos nesse setor destacam-se a análise e a previsão do comportamento dos preços.

Gutierrez e Almeida (2013) afirmam que o conhecimento do comportamento dos preços é extremamente útil na tomada de decisões dos produtores com relação ao planejamento da produção e à manutenção e formação de estoques, possibilitando que estes aproveitem de maneira mais eficiente as fases de baixa e de alta nos preços para a maximização dos lucros. Por essa razão, cada vez mais, a previsão de preços dos produtos agrícolas tem se tornado objeto de interesse dos profissionais do mercado e dos acadêmicos.

Diversas pesquisas realizadas sobre previsão de preços de *commodities* agrícolas como Bressan (2004), Lima, Góis e Ulises (2007), Sobreiro, Araújo, Mendonça e Nagano (2008), Lima et al. (2010), Ferreira, Borenstein e Fischmann (2011), Miranda, Coronel e Vieira (2013), Tibulo e Carli (2014), Pinheiro e Sena (2017) e Lopes (2018) utilizaram métodos estatísticos e computacionais em busca do melhor modelo de previsão.

Entre os principais métodos estatísticos e econométricos utilizados para previsão de comportamento de variáveis, destacam-se o modelo ARIMA e o modelo de Redes Neurais Artificiais (RNAs). Contudo, vários estudos (CHURCH; CURRAM, 1996; KOHZADI ET AL., 1996; CAO; LEGGIO; SCHNIEDERJANS, 2005; CO; BOOSARAWONGSE, 2007; WANG; ELHAG, 2007; CERETTA; RIGHI; SCHLENDER, 2010) ao comparar o desempenho das Redes Neurais com métodos econométricos como o ARIMA na previsão de séries temporais concluíram que os resultados das RNAs são mais preditivos que os demais.

Assim, buscando oferecer uma alternativa para a gestão de riscos aos produtores e gestores que precisam realizar negociações em um mercado inerentemente instável bem como contribuir para o aprofundamento teórico dessa questão, este trabalho tem como objetivo elaborar e validar um modelo de previsão para o comportamento de preços do café brasileiro através do uso de Redes Neurais Artificiais (RNAs).

Para compor o modelo de previsão são utilizadas variáveis relacionadas aos custos de produção nos principais municípios produtores de café no Brasil, variáveis macroeconômicas que podem afetar os preços das *commodities* agrícolas, variáveis relativas ao mercado brasileiro de café (produção, exportação, consumo e estoques) e variáveis relativas ao mercado mundial de café.

Os dados foram coletados no Levantamento de Custos de Produção do Café Arábica, feito pela Companhia Nacional de Abastecimento (CONAB), no IPEA Data e no *Internacional Coffee Organization* (ICO), referentes ao período de 2007 a 2018. Optou-se por analisar os preços à vista, presumindo que o modelo seja empregado por um agente que possui a *commodity*. Em relação à variedade de café, o objeto de estudo foi o Café Arábica, que corresponde a cerca de 70% do volume total das exportações de café brasileiras (CECAFE, 2019).

A fim de verificar quais variáveis proporcionariam maior capacidade de previsão, foram construídos e treinados modelos de Redes Neurais Artificiais com doze arranjos, que se diferenciam pelas variáveis que compõem as entradas do modelo. A definição dos arranjos foi feita buscando mesclar combinações dos diferentes grupos de variáveis e, através da aplicação do teste de VIF (*Variance Inflation Factor*), variáveis que apresentavam alta multicolinearidade foram excluídas dos arranjos. Os resultados desses modelos foram então avaliados por métricas de erro e o modelo com melhor resultado preditivo foi validado.

Além desta introdução, este artigo apresenta um referencial teórico no próximo tópico. O terceiro tópico destaca os procedimentos metodológicos aplicados na estruturação do modelo de Redes Neurais Artificiais. O quarto tópico apresenta a discussão de resultados, e por fim, no último tópico são apresentadas as considerações finais do trabalho.

2. Referencial Teórico

2.1. Formação de Preços de *Comodities* Agrícolas

Atualmente, a maior parte do café produzido no mundo é comercializada como *commodity*. Estas compõem a maior parcela da pauta de exportação de muitos países em desenvolvimento, representando quase a totalidade de suas exportações e assim constituem-

se como principal fonte de renda e receitas. No Brasil, as exportações de *commodities* agrícolas estão entre os principais geradores de receitas para o país (SECEX, 2019).

Na definição de Ferraz, Kupfer e Haguenaer (1995), *commodities* são bens homogêneos ou indiferenciados, produzidos e comercializados em grande escala por processos contínuos, e estocados com relativa facilidade. Nesse sentido, Geman (2005) as define como um ativo físico que possui características padronizadas, de ampla negociação em diversas localidades, que pode ser transportado e armazenado por um longo período de tempo. Sendo um tipo de produto no qual não há diferenças qualitativas entre os mercados onde é negociado, não existe assim preferência, em termos de qualidade, por parte dos compradores do produto.

Devido à padronização, Copeland, Weston e Shastri (1988) sugerem que os mercados de *commodities* são sujeitos a maior número de negociações e, portanto, a uma maior liquidez. Isso se deve ao fato de que quando há padronização, espera-se que as partes negociantes conheçam as características das mercadorias negociadas.

No tocante à produção das *commodities* agrícolas, há um grau relativamente baixo de industrialização no produto final, o que indica que tal valor da *commodity* surge da natureza, e não por processos transformativos ou esforços especializados agregados. Assim, os produtores de *commodities* utilizam a tecnologia para reduzir os custos relacionados à produção em busca de competitividade frente à forte concorrência ocasionada pela ausência de diferenciação (REIS; GOOD; RICHARDZ, 2014).

O fato de serem bens homogêneos confere às *commodities* outra de suas características principais, que é a de serem transacionadas em bolsas de mercadorias em um mercado específico, ou internacionalmente em bolsa de valores (REIS; GOOD; RICHARDZ, 2014). Assim, as variações nos preços das *commodities* são resultantes de forças econômicas de oferta e demanda (FERRAZ; KUPFER; HAGUENAUER, 1995).

Dias e Silva (2015) explicam que a relação entre oferta e demanda internacionais de café é um dos principais determinantes da cotação de preços. Quando há redução mundial da safra de café, por fatores climáticos ou econômicos ocorre também elevação dos preços. Em contrapartida, o aumento da produção provoca queda de preços. Entretanto, os autores ponderam que a oferta e a demanda do café dependem em grande parte de variáveis internas e externas como produção interna, taxa de câmbio, preço do café do principal concorrente e também do ânimo dos mercados.

Nesse sentido, Barreto e Zugaib (2016) afirmam que os principais fatores envolvidos na determinação dos preços do café estão relacionados aos movimentos de oferta e demanda, particularmente a produção, consumo e o estoque. No entanto, ponderam os autores, fatores exógenos, como os movimentos especulativos no mercado, também podem ter um efeito profundo sobre o impacto dos fatores fundamentais na formação dos preços.

Outro ponto que deve ser levado em conta, de acordo com Dias e Silva (2015) é a elasticidade, que mede a forma como os compradores e vendedores reagem, mudando as quantidades ofertadas e demandadas diante de uma mudança de preços. Trata-se assim da sensibilidade de compradores e vendedores diante de mudanças das condições de mercado que afetam as quantidades ofertadas e demandadas (VARIAN, 2006).

Além da oferta e demanda Williams e Wright (2005) destacam a utilização da estocagem para estabilizar o preço das *commodities*, a fim de lidar com a volatilidade associada à produção agrícola. Isso se dá porque as *commodities* em geral não são expostas a uma perda significativa de valor, no sentido de qualidade, enquanto estiverem armazenadas. Bjornson e Carter (1997) afirmam que o armazenamento de *commodities* é uma das principais decisões de investimento que os produtores tomam e envolve riscos consideráveis, pois seus preços tendem a ser voláteis. Por outro lado, os retornos para detentores de estoque podem ser altos em relação ao risco.

Assim, o comportamento de preços das *commodities* está diretamente relacionado ao volume de estoque. Uma vez que quanto maior o estoque disponível para vendas, maior a oferta do produto, que, por sua vez, leva a uma tendência de queda nos preços. Em contrapartida, estoques baixos significam um maior risco de escassez da mercadoria, de modo que os vendedores tendem a elevar seus preços para aumentar seus retornos e reduzir a demanda pelo bem. Seguindo esta mesma lógica, os estoques também representam uma forma de reduzir variações nos preços das mercadorias (CORSINI; RIBEIRO, 2008).

No entanto, outros fatores como a variação da taxa de câmbio e da taxa de juros, os impostos e a oscilação da renda nos países produtores e consumidores (MARQUES; MELLO, 1999), também podem ser incluídos como influenciadores do aumento de risco para os produtores de *commodities*. Assim, estes devem ser fatores considerados ao se buscar estimativas para o comportamento de preços de tais produtos.

2.2. A Cafeicultura no Brasil

Devido à sua importância para a economia brasileira, a cultura do café foi durante muitos anos marcada por políticas protecionistas por parte do Estado que visavam principalmente à sustentação dos preços (LIMA et al., 2008). Até 1990 os preços do café eram regulados pelo Instituto Brasileiro do Café (IBC) com objetivo de aumentar a demanda e reduzir a oferta sempre que a produção se excedia (NOGUEIRA; AGUIAR, 2011).

Entretanto, na década de 1990 iniciou-se um processo de desregulamentação do setor. Desde então, o setor cafeeiro no Brasil vive uma fase de mudança e reestruturação tanto no que se refere à produtividade quanto em competitividade. Essas mudanças, por serem muito recentes, sugerem que este ainda vive um momento de transição.

O processo de desregulamentação foi marcado por dois fatores principais, um em âmbito internacional e outro em âmbito nacional (NOGUEIRA; AGUIAR, 2011). O primeiro ocorreu em 1889, com a suspensão dos Acordos Internacionais do Café (AICs), que mantinham os preços do produto artificialmente elevados através da utilização de cotas de exportação por país produtor. O segundo fator foi a extinção do Instituto Brasileiro do Café (IBC) que, vigente entre 1952 e 1990, era responsável pela formulação das políticas externas e internas e pela regulação das exportações, dos estoques e das torrefações (SANTOS ET AL., 2009). A partir de então, o mercado cafeeiro viu-se livre da intervenção governamental, estabelecendo uma nova realidade após décadas de intervencionismo (ORTEGA; JESUS, 2011).

Esse processo deixou o setor cafeeiro brasileiro sob forte influência dos mercados globais provocando uma profunda crise e aumentando a instabilidade do setor. A suspensão dos AICs suscitou uma guerra de preços no mercado internacional de café, que proporcionou um crescimento da oferta do produto devido à liberação dos estoques por vários países e, conseqüentemente, a redução dos preços e queda na produção (SANTOS et al., 2009).

O novo contexto criado a partir da desregulamentação estimulou também um maior grau de integração dos vários mercados regionais de café, tanto entre si como em relação aos principais mercados internacionais provocando um aumento da competitividade do mercado (NOGUEIRA; AGUIAR, 2011).

Contudo, por mais que o setor cafeeiro brasileiro tenha passado vários anos sob forte regulamentação estatal, é importante destacar que essa regulamentação não estimulava a melhoria da qualidade do produto vendido no mercado doméstico, uma vez que o preço era fixo, e não havia remuneração maior para produtos de melhor qualidade (NOGUEIRA;

AGUIAR, 2011). Ademais, o fato de a cultura do café ser altamente dependente de fatores fisiológicos, tratos culturais e ambientais, a caracteriza como uma atividade de alto risco.

Por essa razão, a volatilidade dos preços é uma grande preocupação para as partes interessadas no mercado mundial de café. Em países exportadores, como o Brasil, a volatilidade é uma fonte de incerteza em relação às receitas de exportação e receitas fiscais bem como dos rendimentos dos produtores, e sua negociação exige, portanto, a adoção de ferramentas de gestão de risco.

2.3. Gestão de Riscos e Previsão de Preços no Agronegócio

A cadeia produtiva do agronegócio apresenta uma complexidade inerente devido aos diversos fatores envolvidos em sua produção e comercialização, esta diversidade acarreta inúmeros riscos e incertezas ao setor (RODRIGUES et al., 2018). A eliminação desses riscos, contudo, não é viável e nem desejável, uma vez que poderia também limitar a possibilidade de maiores rendimentos (MOREIRA; PROTIL; SILVA, 2014), dessa forma faz-se fundamental que os produtores utilizem ferramentas para a gestão de riscos.

O conceito de risco está relacionado à probabilidade de insucesso de determinado empreendimento, em função de acontecimento eventual, incerto, cuja ocorrência não depende exclusivamente da vontade dos interessados. Neste contexto, o risco é usado como um potencial de perdas. No entanto, correr riscos também pode gerar um resultado positivo (HOPKIN, 2018).

Schouchana (2015) afirma que são vários os riscos aos quais os produtores do agronegócio ficam expostos, dentre eles, destaca: os riscos do próprio negócio, como efeitos climáticos (geada, seca, excesso de chuvas); a oferta e demanda desequilibradas - que afetam diretamente os preços; e os riscos que atingem toda a economia, como o câmbio e a taxa de juros. Em decorrência desses riscos, o preço de venda no ato da comercialização foge ao controle do produtor. Dependendo da oscilação de preços, o produtor pode não cobrir seus custos ou não obter a margem de lucro esperada, dificultando honrar compromissos adquiridos (RODRIGUES et al., 2018).

Assim, o setor convive constantemente com o risco de preço, que significa a possibilidade de os preços oscilarem de forma contrária a seus interesses (MICELI, 2019). De acordo com Rodrigues et al. (2018), uma gestão moderna do agronegócio, deve incorporar instrumentos para gerenciamento de riscos com o objetivo de amenizar tais

incertezas e conferir uma estabilidade mínima ao produtor. Os produtores precisam, portando, gerenciar melhor as vantagens da relação retorno-risco, buscando otimizar seus lucros.

Tendo em vista esse comportamento, o planejamento da comercialização da safra é fundamental para que o produtor possa utilizar ferramentas para se proteger de possíveis oscilações bruscas nos preços. Os instrumentos potenciais para lidar com o risco das *commodities* agrícolas, de modo geral, incluem mercados futuros e de opções (ICO, 2014).

Esses mercados fazem parte de um processo que busca integrar produção, processamento, comercialização, consumo e financiamento (MICELI, 2019). Sua função é promover a fixação antecipada do preço da mercadoria, para proteger os agentes econômicos contra a oscilação dos preços (SCHOUCHANA, 2015).

Hull (1996) define os contratos futuros como compromissos de compra ou venda de um determinado ativo numa data pré-estabelecida e a um preço (cotação) que reflete as forças de oferta e demanda que atuam naquele momento. Nesses mercados, os produtores podem comprar insumos ou vender sua produção antecipadamente visando fixar o preço desejado e se proteger contra oscilações.

Entretanto, a CNA (2018) apurou que, no Brasil, 64% dos produtores de café não realizam a venda futura da produção. Entre as razões que “justificam” esse comportamento, destaca-se o desconhecimento e o fato da movimentação nesses mercados ainda gerar insegurança entre os produtores. De modo que, grande parte dos produtores acaba se sujeitando a negociações sem ter a oportunidade de comparar as ofertas do mercado com alguma estimativa de preço do café.

Assim, uma das tarefas cruciais para o gerenciamento de riscos é a previsão de preços dos produtos agrícolas, fator importante para todo o processo de tomada de decisão (RODRIGUES et al., 2018). No caso da cafeicultura, Gutierrez e Almeida (2013) afirmam que, se o produtor tiver uma previsão do preço que será pago por seu produto na época da safra, é possível analisar que tipo de investimentos poderá fazer e qual será o melhor período para sua produção garantindo uma rentabilidade maior.

A análise do comportamento de preços, como elemento do mecanismo de troca, reveste-se de fundamental importância para os participantes do mercado agrícola, sejam eles compradores, vendedores ou estejam em busca de proteção (RIBEIRO; SOSNOSKI; OLIVEIRA, 2010). Assim, as decisões tomadas pelos produtores, mesmo antes da realização da colheita, requerem o conhecimento desse comportamento.

O conhecimento do comportamento dos preços para a tomada de decisão dos produtores com relação ao planejamento da produção, à manutenção e formação de estoques, permite também uma utilização de forma mais eficiente das fases de baixa e de alta nos preços para a maximização dos lucros (GUTIERREZ; ALMEIDA, 2013).

Todavia, como explicam Pinheiro e Sena (2017), o fato de as atividades agrícolas serem caracterizadas por movimentos cíclicos, elevada volatilidade e sofrerem influência de vários fatores do mercado constitui-se num obstáculo para sua previsibilidade. A previsão dos preços passa a ser uma das principais ferramentas para execução do planejamento e avaliação das atividades agrícolas uma vez que é fator de decisão dos investimentos.

Bressan (2004) destaca que diversas técnicas de previsão podem auxiliar a tomada de decisões por parte dos agentes envolvidos em atividades que necessitam de planejamento, avaliação de políticas e redução da incerteza. Por essa razão, cada vez mais, a previsão de preços dos produtos agrícolas tem se tornado objeto de interesse dos profissionais do mercado e dos acadêmicos.

3. Aspectos Metodológicos

Nesta seção são descritos os procedimentos metodológicos utilizados para a construção do modelo de RNAs para previsão de preços do café arábica no mercado físico brasileiro. As Redes Neurais Artificiais (RNAs) se diferenciam dos modelos tradicionais de previsão por serem modelos não-paramétricos, que envolvem algoritmos de aprendizado. Os algoritmos buscam imitar a estrutura de interconexões do cérebro humano, com o intuito de incorporar o padrão de comportamento de uma série temporal de modo a prever, da maneira mais eficiente possível, valores futuros dessa série (TURBAN, 1993). Seu uso vem se destacando como uma das principais técnicas utilizadas para predição e modelagens em ambientes dinâmicos, nos quais as variáveis mudam constantemente (SILVA et al., 2018).

Esses modelos, de acordo com Chatfield (1996) podem ser interpretados como uma classe de modelos que permite ao analista ajustar grande número de parâmetros e testar diferentes configurações para um ajuste. Essas configurações permitem alternativas para um ajuste adequado da rede em termos do número de camadas da rede e do número de neurônios em cada camada (BRESSAN, 2004), criando uma rede com alta capacidade de aproximação (YAMAN; ELATY; TAMAN, 2017).

DETERMINANTES DO COMPORTAMENTO DOS PREÇOS DO CAFÉ BRASILEIRO

No entanto, Göçken, Özçalıcı, Boru, e Dosdoğru (2016) afirmam que a definição do conjunto de variáveis de entrada da RNA pode ser considerada um dos principais problemas na estruturação da rede porque a escolha das variáveis de entrada afeta diretamente a precisão da previsão. Os autores destacam ainda que o número de neurônios na camada oculta é de extrema importância para a RNA. Assim, neste trabalho serão testadas diferentes combinações de variáveis e números de neurônios.

Para tanto, foi utilizada uma série de dados anuais com variáveis relacionadas aos custos de produção do café nos principais municípios produtores do Brasil, variáveis macroeconômicas que podem afetar os preços das *commodities* agrícolas (PIB brasileiro, Taxa de Juros, Taxa de Câmbio, Impostos), variáveis relativas ao mercado brasileiro de café (produção, exportação, consumo e estoques) e variáveis relativas ao mercado mundial de café. Os dados foram coletados no Levantamento de Custos de Produção do Café Arábica, feito pela Companhia Nacional de Abastecimento (CONAB), no IPEA Data e no *Internacional Coffee Organization* (ICO). As variáveis utilizadas nesse trabalho são descritas na Tabela 1:

Tabela 1: Definição das variáveis utilizadas

Variável	Composição	Mensuração
Preço	Preço pago ao produtor pela saca de café arábica	Preço/saca 60kg
Máquinas	Operação com máquinas próprias + Aluguel de máquinas	Custo/saca 60kg
Mão de Obra	Mão-de-obra temporária + Mão-de-obra fixa	Custo/saca 60kg
Fertilizantes	Fertilizantes	Custo/saca 60kg
Defensivos	Defensivos/ Agrotóxicos	Custo/saca 60kg
Financeiras	Total das Despesas Financeiras	Custo/saca 60kg
PIB	Produto Interno Bruto Brasileiro	PIB anual real a preços de mercado
Juros	Taxa SELIC	Taxas de juros efetivas
Consumo Brasil	Consumo Interno de Café no Brasil	Em mil sacas de 60 kg
Exportações Brasil	Exportações de Café no Brasil	Em mil sacas de 60 kg
Estoques Brasil	Estoques de Café no Brasil	Em mil sacas de 60 kg
Produção Brasil	Produção Total de Café no Brasil	Em mil sacas de 60 kg
Consumo Mundo	Consumo de Café no Mundo	Em mil sacas de 60 kg
Exportações Mundo	Exportações de Café no Mundo	Em mil sacas de 60 kg
Estoques Mundo	Estoques de Café no Mundo	Em mil sacas de 60 kg
Produção Mundo	Produção Total de Café no Mundo	Em mil sacas de 60 kg
Imposto	Imposto sobre Circulação de Mercadorias (ICMS)	Média Anual do ICMS
Câmbio	Taxa de câmbio efetiva real para exportações	Média ponderada das taxas de câmbio com 24 parceiros comerciais

Fonte: Elaborado pelos autores

Os dados utilizados são dados anuais, referentes ao período de 2007 a 2018 de nove municípios produtores de café arábica, entretanto devido a existência de dados faltantes para alguns municípios em determinados anos o número de dados da amostra total compreende

97 valores. Optou-se por analisar os preços à vista presumindo que o modelo seja empregado por um agente que possui a commodity e também pelo elevado volume de negociações que ocorrem nesse mercado no Brasil. Em relação à variedade de café, o objeto de estudo foi o café arábica tipo 6, que corresponde por cerca de 70% do volume total das exportações de café brasileiras (CECAFE, 2019).

A definição dos passos para elaboração do modelo de RNAs foi realizada com base nas recomendações de Hair et al. (2005) e a estruturação e validação do modelo foi realizada no software Matlab 8.5.0.197613 R2015a. Para identificar qual combinação de variáveis proporcionaria o melhor modelo para previsão de preços do café diversos arranjos foram testados, cada qual com uma combinação diferente de variáveis que comporiam as entradas nos modelos de Redes Neurais Artificiais. Foi utilizado o teste de VIF para verificar se havia multicolinearidade entre as variáveis incluídas nos arranjos, sendo assim, excluídas algumas variáveis de modelos que apresentaram tal problema. As combinações de variáveis testadas estão apresentadas na Tabela 2:

Tabela 2: Variáveis Incluídas no Arranjo

	1	2	3	4	5	6	7	8	9	10	11	12
Máquinas	o	o	o	o	o				o	o	o	
Mão de Obra	o	o	o	o	o				o	o	o	
Fertilizantes	o	o	o	o	o				o	o	o	
Defensivos	o	o	o	o	o				o	o	o	
Financeiras	o	o	o	o	o				o	o	o	
PIB	o	o			o	o	o	o	o			
Juros	o	o	o	o	o	o	o	o	o			
ICMS	o	o	o	o	o	o	o	o	o			
Câmbio	o	o	o	o	o	o	o	o	o			
Consumo Brasil			o	o							o	
Consumo Mundo									o	o		
Exportação Brasil		o	o	o			o	o			o	
Exportação Mundo									o		o	
Produção Mundo				o	o	o		o	o	o		o
Produção Brasil		o	o				o	o				
Estoques Brasil		o	o	o							o	o
Estoques Mundo					o	o		o	o	o		o
VIF médio	2,3	3,5	3,7	4,6	3,2	3,4	3,2	7,8	8,0	2,4	2,0	2,7

Fonte: Elaborado pelos autores

A partir desses arranjos, foram estruturados os modelos de RNAs para previsão de preços do café. Hair et al. (2005) definem cinco aspectos fundamentais envolvidos para a

utilização de um modelo de Redes Neurais para previsão, sendo estes: (i) preparação dos dados, (ii) definição da estrutura do modelo, (iii) estimativa do modelo, (iv) avaliação dos resultados do modelo e (v) validação do modelo.

Inicialmente os dados passaram por uma fase de pré-processamento, na qual foi realizada a normalização dentro de uma escala de valores definida entre 0 e 1. Esse processo é fundamental para evitar problemas computacionais (LAPEDES; FARBER, 1988), para atender às necessidades do algoritmo (SHARDA; PATIL, 1992) e para facilitar o aprendizado da rede (SRINIVASAN et al, 1994).

Após a normalização os dados foram separados em duas categorias: os de treinamento e os de teste. Os primeiros servem para que a rede "aprenda" as regras associadas ao processo, e os dados de teste são utilizados para verificar o desempenho no referente às condições reais de utilização e a capacidade de generalização (FINOCCHIO, 2014). Neste trabalho a amostra foi dividida com 70 observações para a base de treinamento e 27 para a base de teste.

O tipo de rede utilizada foi o *Multilayer Perceptron* (MLP) ou Rede de Múltiplas Camadas. O método de aprendizagem é o *feed forward backpropagation*, sendo utilizado como padrão (*target*) o preço da saca de café arábica tipo 6 de 60 kg no mercado físico. Foi adotada uma rede com duas camadas intermediárias, sendo a função de transferência escolhida para a primeira camada a função *losing* e para a camada escondida a função *pureling*. A função de adaptação utilizada foi a LEARNINGDM, que é uma função de aprendizado gradiente descendente para pesos. E a função de treino de rede TRAINLN, que é responsável por aplicar o treinamento em uma rede neural. A medida de desempenho de rede adotada é a MSE – *Mean Square Error* (Erro Quadrado Médio).

O último passo dessa fase é definir a quantidade de neurônios da primeira camada escondida da Rede Neural. Na segunda camada escondida a quantidade de neurônios é definida automaticamente pelo *software*. O método comumente utilizado para definição do número de neurônios da rede é o modelo de Kolmogorov, definido pela equação: $n = 2 \cdot n_1 + 1$, onde n_1 representa o número de variáveis de entradas da rede.

Como neste trabalho são testados modelos de RNA com arranjos de variáveis diferentes e assim, com números de entradas diversos, optou-se por testar o desempenho de todos os modelos com combinações de neurônios diversas. Essas combinações foram obtidas através da aplicação do método de Kolmogorov nos doze arranjos de variáveis testados, e a

partir dos resultados desse cálculo, todos os arranjos foram testados com o número de neurônios obtidos. A Tabela 3 apresenta o cálculo dos números de neurônios utilizados:

Tabela 3: Número de Neurônios obtido através do método de Kolmogorov

Arranjo	1	2	3	4	5	6	7	8	9	10	11	12
Número de variáveis	9	12	12	12	11	6	6	8	13	8	9	3
Número de neurônios	19	25	25	25	23	13	13	17	27	17	19	7

Fonte: Elaborado pelos autores com base nos resultados do método de Kolmogorov.

Assim, todos os arranjos de variáveis foram testados em estruturas de rede com 7, 13, 17, 19, 23, 25 e 27 neurônios na primeira camada escondida e 1 neurônio na segunda camada escondida. Portanto, foram testados 84 modelos de RNAs buscando encontrar aquele que apresentasse melhor capacidade preditiva.

Após essa definição foi realizada a estimação do modelo. Nesta fase, seguindo o algoritmo de treinamento escolhido são ajustados os pesos das conexões buscando o melhor ajuste do modelo sem supertreinar a rede à amostra, ou seja, busca-se um modelo generalizável. A etapa seguinte consiste em determinar o nível de previsão obtido nas variáveis de saída, para avaliar os resultados obtidos com a Rede Neural.

Baseado em Ferreira, Borenstein e Fischmann (2011), foram utilizadas duas métricas para avaliação dos resultados: o erro quadrado médio (MSE) e o coeficiente de determinação (R^2). Como parâmetros para definir a rede que apresenta melhor capacidade preditiva, Schalkoff (1997) sugere que se procure alcançar os menores valores possíveis de erro quadrado médio (MSE), e valores próximos de 1 para o coeficiente de determinação (R^2) que indicam que a rede apresenta elevada capacidade preditiva.

A última etapa metodológica consiste na validação do modelo, cujo objetivo é garantir que a solução encontrada é a melhor possível e que ela seja tão generalizável quanto possível (FERREIRA; BORENSTEIN; FISCHMANN, 2011). Assim, os 27 dados que compõem a amostra de validação, relativos às variáveis que compunham o arranjo com menor MSE, foram fornecidos a rede para validação dos resultados.

4. Resultados e Discussão

DETERMINANTES DO COMPORTAMENTO DOS PREÇOS DO CAFÉ BRASILEIRO

Nesta seção são inicialmente apresentadas as estatísticas obtidas na etapa de treinamento de cada arranjo de variáveis testado e posteriormente, apresentados os resultados obtidos na etapa de validação do modelo selecionado.

Os resultados do erro quadrado médio (MSE) e do coeficiente de determinação (R^2) para todos os arranjos de rede treinados são apresentados nas Tabelas 4 e 5:

Tabela 4: MSE para diferentes configurações de rede neural

Arranjo	Número de Neurônios						
	7	13	17	19	23	25	27
1	0,033	0,032	0,042	0,050	0,027	0,029	0,036
2	0,009	0,010	0,009	0,010	0,020	0,009	0,011
3	0,023	0,007	0,011	0,009	0,009	0,018	0,009
4	0,011	0,010	0,017	0,020	0,012	0,008	0,016
5	0,004*	0,009	0,012	0,012	0,006	0,020	0,015
6	0,037	0,012	0,020	0,016	0,014	0,014	0,011
7	0,017	0,016	0,010	0,017	0,013	0,017	0,013
8	0,020	0,014	0,010	0,010	0,022	0,010	0,010
9	0,017	0,017	0,014	0,013	0,017	0,021	0,010
10	0,022	0,016	0,023	0,013	0,022	0,024	0,029
11	0,008	0,018	0,024	0,013	0,015	0,012	0,012
12	0,023	0,016	0,015	0,016	0,016	0,016	0,016

Fonte: Elaborado pelos autores com base nos resultados

*Menores erros de previsão

Tabela 5: R^2 para Diferentes Configurações de Rede Neural

Arranjo	Número de Neurônios						
	7	13	17	19	23	25	27
1	0,719	0,740	0,663	0,585	0,788	0,803	0,687
2	0,933	0,940	0,934	0,925	0,865	0,931	0,919
3	0,837	0,952	0,928	0,933	0,940	0,860	0,928
4	0,930	0,929	0,869	0,875	0,911	0,945	0,880
5	0,974*	0,937	0,915	0,912	0,955	0,839	0,935
6	0,680	0,909	0,851	0,887	0,891	0,895	0,920
7	0,864	0,880	0,927	0,869	0,900	0,889	0,903
8	0,847	0,895	0,920	0,923	0,862	0,929	0,927
9	0,880	0,873	0,907	0,916	0,884	0,878	0,928
10	0,834	0,894	0,814	0,912	0,840	0,811	0,775
11	0,939	0,864	0,809	0,909	0,889	0,930	0,910
12	0,829	0,876	0,881	0,876	0,873	0,880	0,871

Fonte: Elaborado pelos autores com base nos resultados

*Menores erros de previsão

Comparando os resultados de MSE e R^2 obtidos pelos arranjos de variáveis, observa-se que aquele que apresentou o melhor desempenho preditivo foi o arranjo 5, na configuração com 7 neurônios na primeira camada escondida. Esse modelo era composto pelas variáveis Custos com Máquinas, Custos com Mão de Obra, Custos com Fertilizantes, Custos com Defensivos, Despesas Financeiras, PIB, Juros, Câmbio, Imposto, Produção Mundial e Estoques Mundiais de Café. O segundo melhor resultado preditivo também foi obtido através dessa configuração de variáveis, porém na estrutura com 23 neurônios na camada escondida.

Esses resultados fornecem indícios de que as variáveis relacionadas ao mercado mundial de café teriam uma maior influência sobre os preços que as variáveis do mercado interno, como produção e estoques. Todavia, ao se comparar os resultados preditivos do arranjo 5 com o arranjo 3, que se diferencia deste por incluir as variáveis Consumo, Exportação e Estoques e Produção de café no Brasil, observa-se que em algumas configurações de neurônios o modelo 3 apresentou um desempenho superior.

Com relação aos custos de produção do café, observa-se que os arranjos 6, 7, 8 e 12, que não incluem estas variáveis apresentaram desempenho preditivo consideravelmente inferior aos demais. Como base nesse desempenho pode-se afirmar que os custos de produção influenciam significativamente o preço do café pago aos produtores no mercado físico brasileiro, sendo um bom indicador para a previsão do comportamento desses preços.

As variáveis macroeconômicas PIB, Taxa de Juros, Impostos e Taxa de Câmbio foram incluídas na maioria dos modelos, com exceção dos arranjos 10, 11 e 12. Esses quando comparados com os modelos que incluíam combinações de variáveis semelhantes como, por exemplo, os arranjos 3, 4 e 5 apresentaram desempenho preditivo inferior, indicando assim que as variáveis macroeconômicas também não apresentam influência significativa sobre os preços do café pago aos produtores brasileiros.

Com base nesses resultados e considerando que os modelos arranjos de variáveis 3 e 5 apresentaram desempenhos preditivos semelhantes, optou-se por realizar a validação dos modelos que apresentaram MSE inferior a 0,0085 para testar sua capacidade preditiva. Assim, foram validados o arranjo 5, nas configurações com 7 e 23 neurônios na primeira camada escondida, o arranjo 3 na configuração com 13 neurônios, o arranjo 4 com 25 neurônios, o arranjo 11 com 7 neurônios e o arranjo 2 com 17 neurônios. O MSE e o R^2 da validação desses modelos estão apresentados na Tabela 6:

Tabela 6: Resultados da Validação dos Modelos com Melhor Desempenho no Treinamento

Arranjo	5	5	3	4	11	2
Nº de Neurônios	7	23	13	25	7	17
MSE	0,6716	0,588	0,0958*	0,4259	0,0968	0,1205
R ²	0,6431	0,6441	0,8394*	0,6265	0,7843	0,7579

Fonte: Elaborado pelos autores com base nos resultados

**Menores erros de previsão*

Como pode ser observado na tabela 6, na etapa de validação o modelo que apresentou melhor desempenho preditivo, com um MSE de 0,0958 e um R² de 0,8394, foi o arranjo de variáveis 3, na configuração com 13 neurônios na primeira camada escondida e 1 neurônio na segunda camada escondida. Esse modelo era composto pelas variáveis Custos com Máquinas, Custos com Mão de Obra, Custos com Fertilizantes, Custos com Defensivos, Despesas Financeiras, Juros, Câmbio, Imposto, Consumo, Exportação e Estoques e Produção de café no Brasil. Assim, as previsões geradas por esse modelo foram separadas por município produtor e calculados o MSE e R² para cada município, como apresentado na Tabela 7:

Tabela 7: MSE e R² para a Validação do Modelo 3

Município Produtor	MSE	R ²
Venda Nova do Imigrante	0,1796	0,2871
Cristalina	0,1193	0,6906
Franca	0,0906	0,6746
Guaxupé	0,1011	0,9581
Londrina	0,0848	0,6652
Luís Eduardo Magalhães	0,0705	0,9660
Manhuaçu	0,0709	0,9387
Patrocínio	0,0830	0,9999
São Sebastião do Paraíso	0,0458	1,0000

Fonte: Elaborado pelos autores com base nos resultados

Observa-se que há uma variação na capacidade preditiva do modelo de acordo com o município produtor. Esse comportamento indica que podem existir fatores intrínsecos aos municípios que influenciam os preços, e não foram incluídos nos modelos, ou que, nesses municípios variáveis que foram incluídas nos modelos não apresentam tanta influência sobre os preços do café nessas regiões.

Como apresentado na tabela 7, o município no qual a previsão feita pela RNA apresentou maior MSE foi Venda Nova do Imigrante, sendo este também o município com menor R^2 , seguido por Cristalina e Guaxupé. Todavia apesar de no município de Guaxupé a previsão ter apresentado um MSE de 0,1011, maior que a média dos demais municípios, o R^2 calculado para esse município foi de 0,9581, indicando uma alta correlação entre o preço previsto e o preço praticado.

Em relação aos melhores desempenhos, estes foram obtidos nos municípios de São Sebastião do Paraíso, Luís Eduardo Magalhães e Manhuaçu, ambos com MSE menor que 0,08 e R^2 superior à 0,90. Em contrapartida, os maiores erros ocorreram no município de Venda Nova do Imigrante. Neste município, o modelo consegue prever uma tendência de elevação dos preços entre 2016 e 2017, porém não prevê uma queda de 2017 para 2018. Todavia, apesar do distanciamento entre os preços previstos e praticados nos primeiros anos da previsão, é possível observar uma aproximação entre esses valores em 2018.

Para os municípios de Cristalina e Franca as previsões apresentaram comportamentos semelhantes, com uma grande aproximação entre os preços praticados e os previstos em 2016, uma incapacidade de prever a elevação dos preços em 2017, e um acerto na previsão de queda dos preços em 2018, porém com um distanciamento entre a previsão e o preço real.

Nos demais municípios, os preços previstos e os praticados seguiram a mesma tendência de comportamento. No entanto, com exceção de Londrina onde os preços reais apresentaram variações mais bruscas que as previstas pela RNA, em todos os municípios as previsões da Rede Neural Artificial apresentaram variações de maior magnitude na tendência de comportamento de preços. Observa-se também que o ajuste de magnitude entre os preços previstos e praticados é maior no ano de 2016 e 2017 e aumenta em 2018, isso pode indicar que nesse ano algum fator externo aqueles incluídos no modelo influenciou o comportamento dos preços do café arábica no mercado físico brasileiro, prejudicando assim a capacidade de previsão das RNAs.

5. Considerações Finais

Dada a importância do café para a economia brasileira, bem como seu papel fundamental para o desenvolvimento regional e a necessidade crescente de alternativas para gerenciamento de riscos nesse setor, este trabalho apresentou a definição e validação de um

modelo de Redes Neurais Artificiais para precificação do Café Arábica no mercado físico brasileiro.

A concepção do modelo passou pelas fases de preparação dos dados, definição da estrutura, estimativa, avaliação dos resultados e validação do modelo. Para a definição da estrutura foram testadas e avaliadas diferentes arranjos de variáveis, com diferentes configurações no número de neurônios incluídos na primeira camada oculta da rede neural.

A fim de verificar quais variáveis proporcionariam maior capacidade de previsão, foram construídos e treinados modelos com doze arranjos de variáveis, cuja definição foi feita buscando mesclar combinações dos diferentes grupos de variáveis. Os resultados desses modelos foram então avaliados por métricas de erro e o modelo com melhor resultado preditivo deveria passar pelo processo de validação. Todavia, através da avaliação dos resultados obtidos na fase de treinamento verificou-se que dos 84 modelos testados 6 apresentavam resultados semelhantes nas medidas de erro utilizadas. Optou-se, portanto, por validar esses modelos e analisar os resultados obtidos na validação para verificar qual o melhor modelo para previsão do comportamento de preços do café.

Com um MSE de 0,0958 e um R^2 0,8394, o modelo que apresentou melhor desempenho preditivo foi o arranjo de variáveis 3, na configuração com 13 neurônios na primeira camada escondida e 1 neurônio na segunda camada escondida. Esse modelo era composto pelas variáveis Custos com Máquinas, Custos com Mão de Obra, Custos com Fertilizantes, Custos com Defensivos, Despesas Financeiras, Juros, Câmbio, Imposto, Consumo, Exportação e Estoques e Produção de Café no Brasil.

Os resultados obtidos demonstraram através das estatísticas MSE e R^2 que o modelo apresenta uma alta capacidade preditiva, podendo, portanto, afirmar-se que a prática do uso de Redes Neurais Artificiais pode ser agregada ao processo decisório referente ao comportamento dos preços café, como uma alternativa no cotidiano dos produtores para a gestão de riscos na comercialização de seus produtos, bem como na busca por melhores rendimentos. Assim, considera-se que o objetivo definido pfoi atingido.

Como limitações deste trabalho destaca-se que, ao buscar um modelo generalizável, é possível que elementos e características intrínsecas aos municípios produtores não tenham sido incluídas nos modelos testados. Dessa forma, uma opção para estudos futuros é a divisão da amostra da pesquisa por regiões e a inclusão de arranjos de variáveis específicos para cada região analisada.

Referências

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE CAFÉ - ABIC. Produção dos Cafés do Brasil cresce 56% em volume e apenas 34% em faturamento bruto nos últimos dez anos. 2019. Recuperado em <http://abic.com.br/producao-dos-cafes-do-brasil-cresce-56-em-volume-e-apenas-34-em-faturamento-bruto-nos-ultimos-dez-anos/>.

BARRETO, R. C. S.; ZUGAIB, A. C. C. Dinâmica do mercado internacional de café e determinantes na formação de preços. **Economia & Região**, 4(2), 7-27, 2016. DOI: <https://doi.org/10.5433/2317-627X.2016v4n2p7>

BERHANE, T.; ADAM, M.; AWGICHEW, G.; HAILE, E. Modeling Coffee Price using Jump Diffusion Model: The case of Ethiopia. **International Journal of Computing Science and Applied Mathematics**, 5(1), 5-9, 2019. DOI: <https://doi.org/10.12962/j24775401.v5i1.3816>

BJORNSON, B.; CARTER, C. A. New evidence on agricultural commodity return performance under time-varying risk. **American Journal of Agricultural Economics**, 79(3), 918-930, 1997. DOI: <https://doi.org/10.2307/1244432>.

BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE-eletrônica**, 3(1), 1-20, 2004. DOI: <https://doi.org/10.1590/S1676-56482004000100005>.

CAO, Q.; LEGGIO, K. B.; SCHNIEDERJANS, M. J. A comparison between Fama and French's model and artificial neural networks in predicting the Chinese stock market. **Computers & Operations Research**, 32(10), 2499-2512, 2005. DOI: <https://doi.org/10.1016/j.cor.2004.03.015>.

CERETTA, P. S.; RIGHI, P. B.; SCHLENDER, S. G. Previsão do preço da soja: uma comparação entre os modelos ARIMA e redes neurais artificiais. **Informações Econômicas**, 40(9), 15-27, 2010.

CHATFIELD, C. Model uncertainty and forecast accuracy. **Journal of Forecasting**, 15(7), 495-508, 1996. DOI: [https://doi.org/10.1002/\(SICI\)1099-131X\(199612\)15:7<495::AID-FOR640>3.0.CO;2-O](https://doi.org/10.1002/(SICI)1099-131X(199612)15:7<495::AID-FOR640>3.0.CO;2-O).

CHURCH, K. B.; CURRAM, S. P. Forecasting consumers' expenditure: A comparison between econometric and neural network models. **International journal of forecasting**, 12(2), 255-267, 1996. DOI: [https://doi.org/10.1016/0169-2070\(95\)00631-1](https://doi.org/10.1016/0169-2070(95)00631-1).

CO, H. C.; BOOSARAWONGSE, R. Forecasting Thailand's rice export: Statistical techniques vs. artificial neural networks. **Computers & industrial engineering**, 53(4), 610-627, 2007. DOI: <https://doi.org/10.1016/j.cie.2007.06.005>.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. Acompanhamento da safra brasileira de café, Safra 2018, 5(4), 1-84, dezembro de 2018. Recuperado em <http://www.conab.gov.br>

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. Série Histórica - Custos - Café Arábica - 2003 a 2018

CONFEDERAÇÃO NACIONAL DA AGRICULTURA E PECUÁRIA DO BRASIL – CNA. Safra 2017/2018 bate recorde de produção e compromete receita bruta dos produtores. 2018. Disponível em <https://www.cnabrazil.org.br/boletins/safra-2017-2018-bate-recorde-de-producao-e-compromete-receita-bruta-dos-produtores>. Acesso em: 10 de dezembro de 2019.

CONSELHO DOS EXPORTADORES DE CAFÉ DO BRASIL- CECAFÉ Relatório mensal de exportações - Novembro de 2019. Disponível em de <https://www.cecafe.com.br/publicacoes/relatorio-de-exportacoes/>. Acesso em: 10 de dezembro de 2019.

COPELAND, T. E., WESTON, J. F., & SHASTRI, K. Financial theory and corporate policy (Vol. 3, pp. 464-471). Reading, MA: Addison-Wesley, 1998.

CORSINI, F. P.; RIBEIRO, C. D. O. Dinâmica e previsão de preços de commodities agrícolas com o filtro de Kalman. *Anais: XIX ENEGEP-Encontro Nacional de Engenharia de Produção*, Rio de Janeiro, 2008.

DIAS, L. D. O.; SILVA, M. D. S. D. Determinantes da demanda internacional por café brasileiro. *Revista de Política Agrícola*, 24(1), 86-98, 2015.

FERRAZ, J. C.; KUPFER, D.; HAGUENAUER, L. **Made in Brazil**: desafios competitivos para a indústria. Rio de janeiro: Campus, 386, 1995.

FERREIRA, L., M., G. L.; BORENSTEIN, D.; FISCHMANN, A. A. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. *RAI Revista de Administração e Inovação*, 8(4), 6-26, 2011.

FINOCCHIO, M. A. F. **Noções de Redes Neurais Artificiais**. Universidade Tecnológica Federal do Paraná, 2014.

GEMAN, H. **Commodities and Commodity Derivatives**. Chichester, U.K.: John Wiley & Sons, 2005.

GÖÇKEN, M.; ÖZÇALICI, M.; BORU, A.; DOSDOĞRU, A. T. Integrating metaheuristics and artificial neural networks for improved stock price prediction. *Expert Systems with Applications*, 44, 320-331, 2016. DOI: <https://doi.org/10.1016/j.eswa.2015.09.029>

GUTIERREZ, C. E. C.; ALMEIDA, F. M. Modelagem e Previsão do Preço do Café Brasileiro. *Revista de Economia*, 39(2), 2013. DOI: <https://doi.org/10.5380/re.v39i2.23476>.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise Multivariada de Dados**. Bookman Editora, 2009.

VILELA, E. H. P.; PENEDO, A. S. T.

HOPKIN, P. Fundamentals of risk management: understanding, evaluating and implementing effective risk management. **Kogan Page Publishers**, 2018.

HULL, J. **Introdução aos mercados futuros e de opções**. São Paulo: BM&F, 1996.

INTERNATIONAL COFFEE ORGANIZATION - ICO. World coffee trade (1963–2013): a review of the markets, challenges and opportunities facing the sector. London: International Coffee Organization, 2014.

KOHZADI, N.; BOYD, M. S.; KERMANSHAHI, B.; KAASTRA, I. A comparison of artificial neural network and time series models for forecasting commodity prices. **Neurocomputing**, 10(2), 169-181, 1996. DOI: [https://doi.org/10.1016/0925-2312\(95\)00020-8](https://doi.org/10.1016/0925-2312(95)00020-8).

LAMOUNIER, W. M.; LEITE, C. A. M. Tendências e ciclos nos preços do mercado spot de café. **Simpósio de Pesquisa dos Cafés do Brasil**, Vitória, 24-27, 2001.

LAPEDES, A. S.; FARBER, R. M. How neural nets work. **Neural information processing systems**, 442-456, 1998.

LIMA, A. L. R.; REIS, R. P.; ANDRADE, F. T. D.; CASTRO JUNIOR, L. G. D.; FARIA, J. M. Custos de Produção: O Impacto da Produtividade nos Resultados da Cafeicultura nas Principais Regiões Produtoras do Brasil. **Anais: Congresso da Sociedade Brasileira de Economia, Administração e Sociologia Rural**, Rio Branco, 2008.

LIMA, F. G.; KIMURA, H.; ASSAF NETO, A. E.; PEREIRA, L. C. J. Previsão de preços de commodities com modelos ARIMA-GARCH e redes neurais com ondaletas: velhas tecnologias – novos resultados. **Revista de Administração**, 45, 188-202, 2010. DOI: [https://doi.org/10.1016/S0080-2107\(16\)30537-4](https://doi.org/10.1016/S0080-2107(16)30537-4).

LIMA, R. C.; GÓIS, M. R.; ULISES, C. Previsão de preços futuros de commodities agrícolas com diferenciações inteira e fracionária, e erros heteroscedásticos. **Revista de Economia e Sociologia Rural**, 45(3), 621-644, 2007. DOI: <https://doi.org/10.1590/S0103-20032007000300004>.

LOPES, L. P. Predição do preço do café Naturais Brasileiro por meio de modelos de statistical machine learning. **Sigmae**, 7(1), 1-16, 2018.

MICELI, W. M. **Derivativos de Agronegócios: gestão de riscos de mercado**. Saint Paul Editora, 2019.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO – MAPA, 2018. Café. Disponível em <http://www.agricultura.gov.br/assuntos/politica-agricola/cafe>. Acesso em: 16 de outubro de 2019.

MIRANDA, A. P.; CORONEL, D. A.; VIEIRA, K. M. Previsão do mercado futuro do café arábica utilizando redes neurais e métodos econométricos. **Revista Estudos do CEPE**, 38, 66-98, 2013.

MOREIRA, V.; PROTIL, R.; SILVA, C. L. Gestão dos riscos de mercado do agronegócio no contexto das cooperativas agroindustriais. **Anais: Congresso da Sociedade Brasileira de Economia, Administração e Sociologia Rural**, Campo Grande, 2014.

NOGUEIRA, F. T. P.; AGUIAR, D. R. Efeitos da desregulamentação na extensão e no grau de integração do mercado brasileiro de café. **Revista de Economia**, 37(3). DOI: <https://doi.org/10.5380/re.v37i3.27532>

ORTEGA, A. C.; JESUS, C. M. Território café do Cerrado: transformações na estrutura produtiva e seus impactos sobre o pessoal ocupado. **Revista de Economia e Sociologia Rural**, 49(3), 771-800, 2011. DOI: <https://doi.org/10.1590/S0103-20032011000300010>.

PINHEIRO, C. A. O.; SENNA, V. Previsão de preços através de redes neurais e análise espectral: evidências para o mercado futuro das commodities açúcar e soja. **Custos e@gronegócio on-line**, 13(4), 103-128, 2017.

REIS, L. S.; GOOD, K. J.; RICHARTZ, F. A volatilidade nos preços das commodities e o comportamento dos custos na indústria têxtil. **Anais: Congresso Brasileiro de Custos-ABC**, 2014.

RIBEIRO, C.O.; SOSNOSKI, A. A. K. B.; OLIVEIRA, S. M. Um modelo hierárquico para previsão de preços de commodities agrícolas. **Revista Produção Online**, 10(4), 719-733, 2010. DOI: <https://doi.org/10.14488/1676-1901.v10i4.225>.

RODRIGUES, L. S.; REZENDE, S.; MOURA, M.; MARCACINI, R. M. Agribusiness time series forecasting using perceptually important events. **Latin American Computing Conference**, São Paulo, 2018. DOI: <https://doi.org/10.1109/CLEI.2018.00040>.

SANTOS, V. E. D.; GOMES, M. F. M.; BRAGA, M. J.; SILVEIRA, S. D. F. R. Análise do setor de produção e processamento de café em Minas Gerais: uma abordagem matriz insumo-produto. **Revista de Economia e Sociologia Rural**, 47(2), 363-388, 2009. DOI: <https://doi.org/10.1590/S0103-20032009000200003>.

SCHOUCHANA, F. **Gestão de riscos no agronegócio**. Editora FGV, 2015.

SECRETÁRIA DE COMÉRCIO EXTERIOR – SECEX. Estatísticas de Comércio Exterior, 2019. Disponível em <http://www.mdic.gov.br/index.php/comercio-externo/estatisticas-de-comercio-externo>. Acesso em: 18 de dezembro de 2019.

SHARDA, R.; PATIL, R. B. Connectionist approach to time series prediction: an empirical test. **Journal of Intelligent Manufacturing**, 3(5), 317-323, 1992. DOI: <https://doi.org/10.1007/BF01577272>.

SILVA, F. F.; SILVA, F. F.; MATIAS, I.O.; SOUZA, C. L. M. Um comparativo de Redes Neurais Artificiais e modelos tradicionais de séries temporais: uma previsão do preço do petróleo. **Linkscienceplace - Interdisciplinary Scientific Journal**, 4(4), 225-238, 2018.

VILELA, E. H. P.; PENEDO, A. S. T.

SOBREIRO, V. A.; ARAÚJO, P. H. D. S. L.; NAGANO, M. S. Precificação do etanol utilizando técnicas de redes neurais artificiais. **Revista de Administração-RAUSP**, 44(1), 46-58, 2009.

SRINIVASAN, D.; LIEW, A. C.; CHANG, C. S. A neural network short-term load forecaster. **Electric Power Systems Research**, 28(3), 227-234, 1994. DOI: [https://doi.org/10.1016/0378-7796\(94\)90037-X](https://doi.org/10.1016/0378-7796(94)90037-X).

TIBULO, C.; CARLI, V. D. C. Previsão do preço do milho, através de séries temporais. **Scientia Plena**, 10(10), 2014.

TURBAN, E. **Decision support and expert systems: management support systems**. Prentice Hall PTR, 1993.

VARIAN, H. R. **Microeconomia-princípios básicos**. Elsevier Brasil, 2006.

WANG, Y. M.; ELHAG, T. M. A comparison of neural network, evidential reasoning and multiple regression analysis in modelling bridge risks. **Expert Systems with Applications**, 32(2), 336-348, 2007. DOI: <https://doi.org/10.1016/j.eswa.2005.11.029>.

WILLIAMS, J. C.; WRIGHT, B. D. **Storage and commodity markets**. Cambridge university press, 2005.

YAMAN, M. A.; ELATY, M. A.; TAMAN, M. Predicting the ingredients of self compacting concrete using artificial neural network. **Alexandria Engineering Journal**. 56, 523-532, 2017. DOI: <https://doi.org/10.1016/j.aej.2017.04.007>.