

PREVISÃO DO MERCADO FUTURO DO CAFÉ ARÁBICA UTILIZANDO REDES NEURAS E MÉTODOS ECONOMÉTRICOS

André Pacheco Miranda¹

Daniel Arruda Coronel²

Kelmara Mendes Vieira³

RESUMO

O mercado futuro do café arábica pode ser considerado como um dos que apresentam a maior margem de risco em relação aos produtos agrícolas, tais como os riscos trazidos pelas inconstâncias climáticas, o ciclo da cultura e as barreiras tarifárias. Esta afirmação remete às seguintes questões: Qual o comportamento do mercado futuro do café arábica com base em modelos econométricos lineares e modelos heurísticos? E qual modelo tem melhor previsão em relação ao mercado futuro do café? Com o intuito de responder ao problema de pesquisa, objetivou-se desenvolver um método heurístico e três modelos econométricos que utilizam, como variável de entrada, o retorno do preço diário do mercado futuro do café arábica com a sua correspondente defasagem, de um total de 2574 cotações de 23/03/2000 até 22/09/2010. O método heurístico conta com uma rede neural *multilayer perceptron*, treinada com o algoritmo de retropropagação de erro. Após o desenvolvimento e a modelagem das variáveis, os resultados dos dois modelos que obtiveram o melhor desempenho foram comparados, com o intuito de identificar qual modelo tem melhor previsão em relação ao mercado futuro do café arábica. Com os resultados, pode-se inferir que os dois modelos tiveram um desempenho satisfatório, mas, os três critérios de avaliação dos métodos utilizados demonstraram que a rede neural possui um poder de explicação maior do que os modelos econométricos no mercado futuro do café arábica.

Palavras-chave: Mercado Futuro; Café Arábica; Redes Neurais

1 INTRODUÇÃO

Segundo a Secretaria do Comércio Exterior (SECEX, 2011), o Brasil vem apresentando uma estagnação nas suas exportações de café desde 2002, entretanto a taxa geométrica do mercado mundial apresenta um crescimento periódico, no mesmo período, de 127%. Esse crescimento das exportações mundiais do café deve-se principalmente a países que, nas décadas de 1980 e 1990, mostraram-se originalmente importadores da *commodity* de países tradicionalmente produtores como o Brasil, porém foram redirecionando suas importações.

Junqueira (2005) relaciona a estagnação da produção de café brasileira a dois fatores que não podem ser impactados diretamente, tais como riscos trazidos pelas instabilidades edafoclimáticas e o ciclo da cultura. Já Castro *et. al*, (2005) relacionam-na com as fontes de risco que impactam diretamente na lucratividade da *commodity*, como a sobrevalorização cambial pelo governo e as barreiras econômicas que os principais importadores impõem.

Estes fatores são fontes de risco que impactam diretamente na renda, relacionadas principalmente à atuação do governo, sobre as quais o produtor não tem nenhuma participação direta. Portanto, a utilização da previsão do mercado futuro proporciona, na tomada de decisão do produtor e comerciante cafeeiro, uma forma de abstrair ganhos que não substituem a quebra das barreiras tarifárias empregadas ao café brasileiro, mas que podem aumentar a lucratividade desta *commodity* agrícola na manipulação de derivativos por meio de um sistema de previsão.

Sistemas para a previsão vão desde as mais simples estatísticas, presentes nas análises técnicas (ROBERT, 2007), lógica *fuzzy*, algoritmos genéticos (LAWRENCE, 1997), modelos econométricos ARCH, GARCH, EGARCH (COELHO *et. al*, 2008; OLIVEIRA *et. al*, 2010), modelos de Markov (HASSAN, 2005), dentre outros (LAWRENCE, 1997; CERETTA, *et. al*, 2010; OLIVEIRA, *et. al*, 2010).

Existe uma enorme variedade de aplicações para modelos de previsão do mercado à vista e futuro. Alguns utilizam como informações de entrada resultados da análise fundamentalista, outros baseiam-se apenas em informações básicas

como cotação da ação, cotação dos commodities e volume com o próprio retorno defasado das negociações. Outros ainda utilizam informações extraídas da análise técnica (LAWRENCE, 1997). Com base nesta diversidade de modelos e variáveis de entrada, questiona-se: Qual o comportamento do mercado futuro do café arábica com base em modelos econométricos lineares e nas redes neurais? E qual modelo tem melhor previsão em relação ao mercado futuro do café?

Visando atender aos problemas de pesquisa delineados neste estudo, objetivou-se desenvolver três modelos lineares e um não linear para o apoio à tomada de decisão dos comerciantes e produtores cafeeiros. Como variável de entrada, foi utilizado o preço negociado e o próprio retorno defasado do mercado futuro do café arábica em séries temporais.

O modelo não linear desenvolvido utiliza uma rede neural *perceptron* de múltiplas camadas (MLP), treinada com o algoritmo de retropropagação do erro (*backpropagation*) (HAYKIN, 2001; SCHLKOFF, 2001; NASCIMENTO JR. e YONEYANA, 2004; LUDWING JR. e MONTGOMERY, 2007; VALENÇA, 2009; SOBREIRO *et. al*, 2009; GALÃO *et. al*, 2011), tendo como saída desejada o dia seguinte à análise do mercado futuro do café arábica. Quanto aos modelos lineares de apoio à tomada de decisão, utilizaram-se os Autoregressivos (AR), o de Médias Móveis (MA) e os Autorregressivos de Médias Móveis (ARMA) (CAMPOS, 2008). O desenvolvimento dos três modelos econométricos tem como propósito cumprir com o principal objetivo do artigo, ou seja, identificar qual modelo tem o poder de previsão mais robusto e dinâmico em relação à rede neural no mercado futuro do café arábica.

Para desenvolver esta temática, este trabalho está estruturado em quatro seções, além desta introdução. Na seção 2, é descrito o referencial teórico, buscando corroborar considerações sobre os riscos que os produtores e comerciantes cafeeiros sofrem, trazendo breves conceitos sobre o mercado futuros. Na seção 3, apresentam-se os procedimentos metodológicos, demonstrando-se a modelagem matemática dos modelos lineares e não lineares. Na seção 4, os dados são analisados e discutidos e, na última seção, são apresentadas algumas considerações finais.

2 REFERENCIAL TEÓRICO

2.1 Mercado brasileiro de café: barreiras tarifárias e as imponderações do café brasileiro

Segundo a Organização das Nações Unidas para Agricultura e Alimento (FAO, 2011), o Brasil sempre deteve o título de maior exportador de café do mundo. No entanto, desde 1993, vem reduzindo a sua participação relativa no mercado de exportações mundiais, de 31% no ano de 1993, para em média 24% no ano de 2008. Entretanto, a taxa geométrica de crescimento do mercado de exportações mundiais do café, no período de 1992 a 2002, foi de 127% (NISHIJIMA; SAES; SAES, 2006).

Os países tradicionalmente consumidores do café brasileiro, nas décadas de 1980 e 1990, são os principais responsáveis pelo acréscimo da taxa geométrica de exportações mundiais. Os Estados Unidos e a Alemanha, grandes compradores de café do Brasil, aumentaram sua participação mundial em 2%, e Singapura ampliou sua fatia de 5% para 10%, direcionando-se a outros mercados (NISHIJIMA e SAES; SAES, 2006). Não obstante isso, o Brasil, nos últimos anos, vem apresentando uma estagnação nas suas exportações, em decorrência dessa troca de papéis no mercado mundial.

Essa situação de estagnação pode ser relacionada a três principais fatores, que não corroboram com a expansão do mercado de exportações do café brasileiro tais como os riscos trazidos pelas inconstâncias climáticas, o ciclo da cultura, a desvalorização cambial e as barreiras tarifárias. A produção brasileira de café é caracterizada por grandes volatilidades de um ano a outro em razão do ciclo anual da cultura composta por um ano de esgotamento e um de superávit (JUNQUEIRA, 2005). As inconstâncias climáticas de junho a agosto, meses em que se realiza a maior parte da colheita no país, contribuem ainda mais com as imponderações do café brasileiro, trazendo incertezas ainda maiores quanto ao ano de esgotamento e superávit da cultura (JUNQUEIRA, 2005). Em relação às afirmações anteriores, deve-se ressaltar que o ciclo anual e as intempéries climáticas transferem aos

produtores cafeeiros grandes riscos em relação a fatores que não podem ser impactados diretamente.

Outro risco que os comerciantes e produtores de café enfrentam está relacionado com a sobrevalorização cambial, pois, quando aumenta a valorização cambial, reduz-se a competitividade do café no mercado internacional e, ao mesmo tempo, reduz-se o preço dos produtos importados, o que, por sua vez, diminui o custo de insumos que empregam matéria-prima importada (CASTRO, *et. al*, 2005).

Outro fator que prejudica as exportações do café são as barreiras tarifárias aplicadas ao Brasil, as quais não proporcionam os mesmos benefícios tarifários para os países que fazem parte dos acordos de Sistemas Gerais de Preferência (SGP) (SAES, 2002), porque esses acordos proporcionam aos países participantes uma prioridade em relação à compra ou venda do café com tarifas mais baixas (SAES, 2002).

A participação do Brasil numa SGP, em relação ao café, traria um aumento considerável à competitividade em geral e, por consequência, um aumento na lucratividade na venda do café arábica para os Estados Unidos e União Europeia e na venda do torrado moído para os participantes da Área de Livre Comércio das Américas (ALCA) e de países da Ásia e África (SAES, 2002; VERISSIMO, 2003; NISHIJIMA e SAES; 2006; MARAGNO, *et. al*, 2006).

Segundo dados do Ministério do Desenvolvimento, Indústria e Comércio Exterior, Balança Comercial Brasileira, Dados Consolidados de 2011, o café é considerado como um dos principais produtos na pauta de exportação do país, sendo responsável por 3,3% de toda exportação brasileira e totalizando 3.942 Milhões de dólares (SECEX, 2011). A Tabela 1 demonstra a importância econômica do café nas exportações do agronegócio brasileiro.

Tabela 1- Principais Produtos Exportados no Brasil

	Valor	Part %
1 – Minérios	19.423	16,4
2 – Petróleos e combustíveis	14.861	12,6
3 – Complexo soja	12.717	10,7
4 – Material de transporte	11.827	10
5 – Produtos metalúrgicos	8.868	7,5
6 – Químicos	7.563	6,4
7 – Carnes	7.454	6,3
8 – Açúcar e etanol	5.797	4,9
9 – Máqs. e equipamentos	4.758	4
10 – Café	3.942	3,3

Fonte: SECEX, 2011.

A produção do café arábica representa 73,9% (31,89 milhões de sacas) da produção do país e tem como maior produtor o estado de Minas Gerais, com 67,1% (21,40 milhões de sacas) de café beneficiado. O *conillon* (robusto, torrado moído) participa na produção nacional com 26,1% de café beneficiado (SECEX, 2011).

Apesar destes importantes resultados, a não participação do Brasil em um acordo de preferências, com tarifas aplicadas pelos principais países compradores de café e seus acordos de preferência, que não compreendem o Brasil como: o NAFTA (EUA-Canadá e EUA-México); o acordo Antidrogas (Bolívia, Colômbia, Equador e Peru) e o CBI (países do Caribe); no caso da União Europeia o SGP (sistema geral de preferências), SGP específico para países subdesenvolvidos e ACP (países africanos ex-colônias da Europa), é o principal obstáculo para o crescimento das exportações de café e o aumento da lucratividade do produtor e comerciante cafeeiro brasileiro no quesito exportações (SAES, 2002; MARAGNO, *et. al*, 2006).

Levando-se em consideração os riscos trazidos pelas inconstâncias climáticas, o ciclo da cultura, a desvalorização do câmbio pelo governo e as barreiras tarifárias, constata-se que o produtor de café atua num mercado com múltiplas fontes de riscos. As fontes relacionadas a inconstâncias climáticas e ao ciclo da cultura são analisadas sob a ótica da produção. Já a desvalorização cambial e as barreiras tarifárias são fontes de risco que impactam diretamente na renda, relacionadas principalmente à atuação do governo, sobre as quais o produtor não tem nenhuma participação direta.

Assim, a utilização da previsão do mercado futuro do café arábica proporciona, na tomada de decisão do produtor e comerciante cafeeiro, uma forma de abstrair ganhos que não substituem a quebra das barreiras tarifárias empregados ao café brasileiro, mas que podem aumentar a lucratividade desta *commodity* agrícola na manipulação de derivativos por meio de um sistema de previsão.

2.2 Mercado futuro do café uma medida de contra risco

A previsão do mercado futuro, mais comumente chamada de “previsões de vendas futuras”, para Gaither e Frazier (2001), é o ponto mais primitivo dentre os planejamentos na administração de um investimento.

O comportamento não linear, aleatório e altamente complexo do mercado acionário proporciona aos preços surtos de otimismo e pessimismo, levando a volatilidade de todas as commodities a uma inconstância de mercado (FARHI, 2006), ou seja, uma volatilidade alta em um curto espaço de tempo é caracterizada como surtos de pessimismo. Já o mercado com menos volatilidade é caracterizado como um surto de otimismo.

Esta inconstância leva o produtor a desenvolver técnicas para a proteção contra o risco por meio da compra e venda de papéis de contratos futuros de derivativos no *timing* mais rentável. Para sobreviver no mercado futuro, em que os preços resultam do mercado à vista, o produtor e comerciante cafeeiro “lança mão” de quatro papéis de contratos futuros de derivativos: opções, contratos a termo, contratos futuros e swaps, os quais, para Ribeiro, Sousa e Rogers (2006), somente servem de proteção ou controle do risco de um comerciante e produtor cafeeiro.

Os contratos no mercado futuro do café podem ser fechados em março, maio, julho, setembro e dezembro. Esta periodicidade de um contrato futuro de café é proporcionalmente a mesma em todas as Bolsas de Mercadorias & Futuros (BM&F) do mundo, permitindo que os investidores, comerciantes e produtores cafeeiros, classificados em hedgers, especuladores e arbitradores, possam utilizar a barganha de comprar o contrato em um país e vender em outro, servindo-se das distorções de preços entre as bolsas envolvidas no mercado (RAPOSO, 2000).

O mercado futuro é frequentado por três agentes participantes: os hedgers, agentes que utilizam os mercados futuros e as opções para reduzir ou eliminar o risco associado ao preço de um ativo; os especuladores, que estão presentes no mercado à vista e futuro com o propósito de obter lucros com informações sigilosas altamente perigosas em relação ao risco; e os arbitradores, agentes que se aproveitam de discrepâncias nos preços de mercado para conseguir *traders*

lucrativos, característica que mais se enquadra com os produtores e comerciantes cafeeiros (RIBEIRO; SOUSA; ROGERS, 2006).

O mercado futuro do café é considerado como uma das melhores diversificações de carteira, de acordo com Junqueira (2005) e Ribeiro, Sousa e Rogers (2006). Mas, pelo fato de o café brasileiro ser uma das commodities agrícolas mais prejudicadas pelas barreiras tarifárias e desvalorização cambial, o mercado futuro do café tem uma margem de risco maior que a das *commodities* como o boi gordo (GAIO, 2007) e a soja (ASSAD, *et. al*, 2007). Por sua vez, necessita de métodos matemáticos e computacionais mais condizentes com a realidade do que a maioria das *commodities*.

Os modelos mais utilizados para a previsão de commodities são os econométricos lineares Autorregressivos (AR), os de Médias Móveis (MA) e os Autorregressivos de Médias Móveis (ARMA) ou não lineares, Autorregressivo Condicional Heterocedástico (ARCH), Autorregressivo Condicional Heterocedástico Generalizável (GARCH) e Autorregressivo Condicional Heterocedástico Exponencial EGARCH (COELHO, *et. al*, 2008; OLIVEIRA, *et. al*, 2010; SANTOS, 2008), e os métodos Heurísticos como Redes Neurais encontrados em Kim (2004), Hassan (2005), Phua (2000), Smith & Gupta (2000), Ceretta, *et. al*, (2010) e Oliveira, *et. al*, (2010), apenas para citar alguns exemplos.

Ribeiro, Sousa e Rogers (2006) analisaram a predição das variáveis médias mensais de preços do 1º e 2º vencimentos em aberto do contrato de café arábica BM&F; estoques das cooperativas; volume de exportações do café arábica; estoques das cooperativas e produção nacional, em um modelo VAR, com dados mensais de janeiro de 1996 a julho de 2005, e concluíram que grande parte das variâncias nos períodos iniciais é mais bem explicada pela própria variância defasada.

Pinto, *et. al* (2008), em seu estudo, verificou a previsão do preço de *commodities* com modelos lineares, e o método com melhor desempenho foi o ARMA, para uma série temporal de dados mensais do café, soja, cacau, cana e laranja, de 1997 até 2006, com previsão dos seis meses seguintes. Também se pode concluir que as previsões são de extrema importância para que os produtores

e investidores formem suas expectativas sobre o comportamento dos preços futuros das commodities.

Pinto, *et. al*, (2008), Bacci (2007), que utilizaram os métodos de Dupla Suavização Exponencial, de Análise de Tendência Quadrática e ARIMA (2, 2, 5) combinados com uma média aritmética simples dos resultados previstos, concluíram que estes são mais adequados para a previsão da demanda de café para os anos de 2000 até 2007 e dados anuais com os menores erros, melhores resultados estatísticos e melhor ajustamento.

Segundo Rezende *et. al*, (2006), corroborando com Bacci (2007), a combinação do método ARMA (2,2,5) com uma média aritmética simples dos resultados previstos tem uma previsibilidade mais robusta e precisa, diminuindo o risco da previsão, pois apresenta menor variabilidade dos erros.

Moura e Carrasco (2011) objetivaram encontrar um modelo econométrico dentre os dinâmicos de defasagem distribuída, capaz de prever o preço do café no Brasil, a fim de auxiliar os produtores e comerciantes nas tomadas de decisões sobre os investimentos de café. Utilizando dados do preço mensal do café arábica, taxa de câmbio, crédito rural, taxa de juros, PIB Brasil, PIB Estados Unidos, nos anos de 1997 até 2009, concluíram que os resultados da modelagem dos modelos que utilizaram o crédito rural e a taxa de juros como variáveis forneceram uma porcentagem menor de erro médio absoluto de previsão, MAPE, na ordem de 1,8%.

Já Muller, Moura, Lima (2009) desenvolveram a comparação dos modelos clássicos de Regressão Linear (MCRL) com modelos vetoriais de correção de erro (VEC) e modelos de volatilidade condicional bivariado (Bekk), com dados representativos de 1785 observações para o período de 2000 a 2005. Os autores concluíram que a estratégia que empregou o modelo Bekk foi a que menos proporcionou riscos na utilização do mercado futuro como diversificação de carteiras.

3 METODOLOGIA

3.1 Sistema de apoio à decisão

Neste trabalho, foi desenvolvida uma pesquisa positivista quantitativa, partindo de uma construção de quatro modelos de apoio à decisão, voltados, principalmente, aos comerciantes e produtores cafeeiros com pouco ou nenhum conhecimento de técnicas de análise do mercado.

A rede neural presente no sistema foi desenvolvida na linguagem Java. O sistema utiliza uma rede neural *perceptron* de múltiplas camadas para suas tomadas de decisão, pois, desta forma, o sistema assegura maior garantia de sua saída.

Os modelos AR, MA e ARMA foram desenvolvidos com base no software estatístico R. Para chegar às definições do melhor modelo linear, foram feitas baterias de testes na modificação dos parâmetros modificáveis (p, q) do modelo.

Os quatro modelos desenvolvidos aprenderão com o comportamento passado do preço da commodity agrícola analisada, com o propósito de fazer um prognóstico de comportamento futuro da commodity agrícola café arábica, fortalecer a decisão do usuário e melhorar a confiabilidade da análise.

O objetivo da construção dos modelos lineares e da rede neural, descrita neste trabalho, é construir um rastreador de tendências que apoie a tomada de decisões de um comerciante e/ou produtor cafeeiro no mercado futuro, ou seja, auxiliar a localização, o momento certo de compra e venda da commodity analisada. Com o intuito de garantir que a solução encontrada seja tão generalizável quanto possível, ao final dos testes entre modelos lineares, vão ser comparados os resultados do melhor modelo linear com a rede neural que obtiver a melhor previsibilidade.

3.2 Métodos Econométricos e modelagem matemática

Existe uma enorme variedade de aplicações para modelos de previsão do retorno no mercado futuro (LAWRENCE, 1997). Nesta seção, são apresentados três modelos lineares de previsão do retorno da Bolsa de Mercadorias & Futuros (BM&F) e seus desenvolvimentos a partir de uma série real.

O modelo Autorregressivo (AR) foi desenvolvido principalmente para se estimar o retorno de uma acurada *commodity*, para determinadas séries temporais lineares (MAIA, *et. al*, 2008). Os modelos AR de Box e Jenkins (1976; 1994) são definidos de maneira que os valores das séries no tempo t dependem dos valores passados. Mais especificamente, diz-se que Y (objeto a ser explicado) é explicado por X_1 e seus consequentes, transformando em um processo autorregressivo de ordem p , número de termos autorregressivos que satisfaz à seguinte equação:

$$Y_i = \sum_{i=1}^p \alpha_i X_{i-1} + \sum_{i=1}^p \beta_i T_{i-1} + \sum_{i=1}^p \gamma_i C_{i-1} + \varepsilon_i \quad (3.1)$$

Onde, α_i é a constante, $X_{i-1}, T_{i-1}, C_{i-1}$ são os parâmetros definidos para explicar Y_i , e ε_i é o ruído branco da equação, em modelos AR(p), os operadores autorregressivos são estacionários de ordem p , se $i > p$. A expressão 3.1 representa o efeito da magnitude do retorno de Y , ou seja, quanto maiores forem os parâmetros definidos, maior será o valor de Y .

Os modelos de Médias Móveis de ordem q , representados por MA(q), em que os operadores de médias móveis igual a 0, $j > q$ são considerados linearmente dependentes de um número finito, q , de ruídos brancos, ou seja, Y_t representa o modelo linear, porém com o somatório em q termos, o θ é o coeficiente de médias móveis, ε_t é o ruído branco e Y_t é a vazão diária no dia $t+1$, representam o operador de média móvel de ordem q para satisfazer à seguinte equação de diferenças (GALVÍNIO, *et. al*, 2002):

$$Y_t = 1 - \sum_{i=1}^q \theta_i X_{t-i} + \varepsilon_t \quad (3.2)$$

Assim, as expressões 3.1 e 3.2 são estacionárias se e somente as raízes da mesma forem unitárias. O θ determina o comportamento da variância condicional no sinal dos retornos positivos.

Os modelos ARMA (Autorregressivos de Médias Móveis) de ordem (p, q) são uma generalização dos modelos AR(p) e MA(q), que, com um número menor de parâmetros, formam uma classe de modelos muito úteis para descrever dados de séries temporais. Estes modelos são bastante populares em algumas áreas tais como Economia e Administração Financeira, onde é natural pensar no valor de alguma variável no instante t com função de valores defasados da mesma variável (MAIO, *et. al*, 2008).

Então, um processo autoregressivo e de médias móveis de ordem (p, q), denotado por ARMA(p, q), é definido por:

$$Y_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + e_t + \beta_1 e_{t-1} + \dots + \beta_q e_{t-q} \quad (3.3)$$

Sendo que e_{t-q} é o ruído branco e a média do processo é o μ .

Cabe salientar que as funções de autocorrelação ficam consideravelmente mais complicadas em processos de ARMA. De uma forma geral, para um processo ARMA (p, q) estacionário, a função de autocorrelação tem um decaimento exponencial ou oscilatório após a defasagem q (IQUIAPAZA, *et. al*, 2010).

3.3 Redes neurais artificiais

Uma rede neural artificial é um modelo formal para representar o neurônio biológico (JUDD, 1990). A seguir, são descritos alguns dos principais componentes de uma rede neural artificial presentes em Ludwing J.r. e Montgomery, (2007), Nascimento J.r. e Yoneyana. (2004) e Ceretta, *et. al*, (2010).

O neurônio matemático, similarmente ao natural, recebe um ou mais sinais de entrada e devolve um único sinal de saída, que pode ser distribuído como sinal de saída da rede, ou como sinal de entrada para um ou vários outros neurônios da camada posterior.

No neurônio matemático, as *sinapses* fazem a parte dos dendritos no neurônio biológico. O papel dos axônios é desempenhado no modelo matemático pelos *bias* (LUDWING J.R., MONTGOMERY, 2007; FARIA, *et. al*, 2008).

O corpo do neurônio biológico, onde são processados os estímulos, é responsável pela função de transferência e de ativação em um neurônio (VALENÇA, 2009). A função de ativação faz a soma ponderada dos sinais de entrada, e a função de transferência determina a saída do neurônio, em função da soma ponderada (SCHALKOFF, 2001).

Somente a função de ativação não fará o papel do corpo do neurônio. Para isso, é necessária a combinação com a fórmula de transferência (LUDWING J.R.; MONTGOMERY, 2007). As redes neurais artificiais *perceptron* de múltiplas camadas são redes extremamente precisas em suas respostas (LUDWING J.R.; MONTGOMERY, 2007). Estas redes estendem a rede neural original com o acréscimo de camadas ocultas que significam mais poder computacional para as redes neurais.

3.3.1 Retropropagação do erro com aprendizagem supervisionada

Há vários algoritmos que produzem o aprendizado para as redes neurais artificiais. Apenas para citar alguns exemplos, tem-se a retropropagação do erro com aprendizagem não supervisionada (LUDWING J.R.; MONTGOMERY, 2007) e o desenvolvimento da regra delta (VALENÇA, 2009). O utilizado no sistema é o algoritmo de retropropagação de erro com aprendizagem supervisionada.

O algoritmo funciona com um vetor de valores de entrada que inicia na primeira camada de neurônios. Dentro de cada neurônio, são realizados os cálculos de ativação e de transferência, repassando o resultado à entrada do neurônio na camada seguinte e prosseguindo até chegar à última camada de neurônios. Nesta camada, é calculada a diferença entre a saída desejada e a saída calculada pela rede neural.

A utilização de técnicas supervisionadas, como o cálculo do erro do neurônio de saída e a taxa de aprendizado, prossegue de trás para frente, do último neurônio para o primeiro, levando as redes neurais artificiais a um grande propósito, o de ajustá-las em sua precisão, isto é, se o erro não for aceitável, colocam-se novos pesos para as *sinapses* e *bias* do neurônio.

Em uma rede neural de múltiplas camadas, utiliza-se um valor de erro para definir uma parada aceitável. A rede neural artificial procurará aproximar-se desse valor ou até mesmo igualá-lo em alguns casos. O erro não pode ser inferior ao escolhido ou ocasionará uma parada forçada da rede e novos valores terão que serem escolhidos.

Para medir o desempenho do treinamento, diminui-se o valor desejado do valor calculado do neurônio. A diferença indica o quanto a rede aprendeu. Esse procedimento chama-se treinamento por supervisão (GUIMARÃES, 2008).

3.3.2. Treinamento, validação e verificação

A confiabilidade dos resultados obtidos pela rede neural depende da utilização correta, por exemplo, da ordem dos cálculos utilizados para o treinamento da rede e do ajuste dos *bias* e *sinapses* do neurônio. Quanto menor for o erro, mais próximas à correção das *sinapses* e *bias* estarão. Há três etapas para que a rede neural possa ser considerada validada: treinamento, validação cruzada e verificação.

O treinamento/aprendizado da rede neural leva em consideração uma regra formal, ou seja, a utilização de informações do supervisor da rede, que atualiza os parâmetros modificáveis da rede como os *bias* e as *sinapses*. A participação do supervisor pode ser classificada em métodos de treinamento.

Quanto à participação forte, o supervisor fornece um conjunto de entradas correlacionadas com um conjunto de saída desejada, ou seja, o supervisor apresenta os resultados almejados no vetor de saída desejada para que se tenha a mesma “correlação” de entradas posteriores, aumentando o aprendizado a cada entrada do treinamento. Este método corresponde ao algoritmo de *backpropagation* (retro-propagação).

O erro é retropropagado da saída para a entrada, fazendo com que a rede “imite” o supervisor, procurando sempre obter um erro menor (NASCIMENTO J.R; YONEYANA, 2004; SCHALKOFF, 2001). No treinamento, os valores recebidos no neurônio, para melhor refinamento da entrada, foram normalizados com a fórmula linear (VALENÇA, 2009).

A validação cruzada é um ponto muito importante para o treinamento, pois se pode ter uma certeza de parada, ou seja, é uma forma de descobrir se a rede neural não está supertreinada somente para a entrada correspondente, localizando exatamente quando a rede neural está extremamente precisa e treinada. Para isso, são comparados o erro médio quadrado (LUDWING J.R., MONTGOMERY, 2007; SCHALKOFF, 2001; GUIMARÃES, 2008), o erro médio global (GUIMARÃES, 2008; VALENÇA, 2009) e o erro padrão de predição (VALENÇA, 2009) do treinamento com o da validação, procurando obter uma variação muito baixa entre as duas etapas do treinamento.

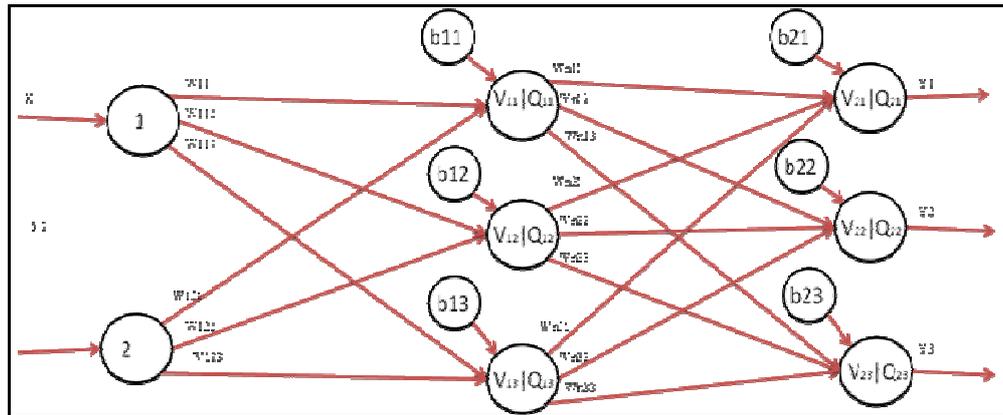
Para os erros, foram utilizados um critério de parada buscando sempre, um valor abaixo do erro aceitável de resultado entre 0,08 a 0,05 por ciclo no erro médio global, um valor entre 0,008 a 0,005 por ciclo no erro médio quadrático e um valor entre 0,008 a 0,005 por ciclo no erro padrão de predição do treinamento (VALENÇA, 2009).

O último quesito a ser avaliado é a verificação, Há uma comparação entre o Erro Médio Quadrado da Verificação e o Erro Médio Quadrado da Validação Cruzada. A partir do momento em que as entradas da rede neural resultam um erro na Validação Cruzada, afastando-se cada vez mais do erro da Verificação, a rede neural é considerada treinada até aquele exato momento (VALENÇA, 2009), e, nesta etapa, também são feitas comparações entre outras análises ou tipos de redes diferentes para uma confirmação do treinamento.

3.3.3 Topologias da rede neural

A topologia da rede neural é o número de neurônios nas camadas de entrada, nas camadas escondidas e na camada de saída. A topologia que se enquadra melhor ao problema somente é verificada no treinamento, com o método de tentativa e erro, como, por exemplo, redes com a topologia 2-3-3, como pode ser visto na Figura 1, a seguir.

Figura 1- Topologia Rede Neural Artificial MLP



Fonte: Organizado pelos autores.

3.4 Levantamento dos dados

As entradas da rede neural foram divididas em quatro categorias: saída desejada, treinamento, validação cruzada e verificação. Os modelos lineares não são compostos pelo conjunto de etapas do treinamento e validação cruzada, por isso não foram divididas as entradas, e utilizaram-se 2574 cotações disponíveis no site da Bolsa de Mercadorias & Futuros (BM&F), corridas do preço da saca de 60 kg do café arábica com os valores respectivos da cotação do dólar no dia, para determinar a previsão com base no dia anterior.

O treinamento da rede neural satisfaz 50% das cotações obtidas de um total de 2574 cotações de 23/03/2000 até 22/09/2010. A validação cruzada correspondeu a 25% do total, e a verificação correspondeu aos 25% restantes. A saída desejada foi desenvolvida a partir da previsão do dia anterior, como mostra a Expressão 3.4, a seguir.

$$Y_i = \sum_{i=1}^P \alpha_i X_{i-1} + \sum_{i=1}^P \beta_i T_{i-1} + \sum_{i=1}^P \gamma_i C_{i-1} + \varepsilon_i \quad (3.4)$$

em que:

X_{i-1} é o somatório da volatilidade do dia anterior, T_{i-1} é o somatório do tempo do dia anterior e C_{i-1} é o somatório da constante do dia anterior, e ε_i é o erro da equação.

As séries temporais não são de raiz unitárias, por isso os dados serão estacionados com a diferenciação da série com o log retorno, aplicando-se a fórmula para estimar Y com os valores defasados de X menos X multiplicados por \log , conforme Expressão 3.5, a seguir.

$$Y_i = \log \sum_{i=1}^p \alpha_i X_{i-1} - X_i + \varepsilon_i \quad (3.5)$$

O treinamento da rede neural foi realizado da seguinte forma: a camada de entrada, com três neurônios, recebeu, no primeiro neurônio, um vetor de cotações diárias do preço da commodity analisada. O segundo neurônio recebeu o tempo correspondente das cotações. E o terceiro neurônio recebeu um vetor de número um para melhor obtenção de um erro mais baixo.

A análise da validação cruzada utilizará a fórmula do Erro Médio Quadrático e do R^2 como um critério de parada aceitável, com entradas distintas do treinamento. Com isso, pode-se ter uma conclusão de que as sinapses e bias correspondem a uma correção entre a média de erro, os valores obtidos na rede neural serão aceitáveis e a ligação entre um nó e outro dos demais métodos com a saída desejada também.

O último estágio a ser concluído será a verificação. Nesta etapa, poderá ser constatado que os métodos não perderão sua precisão na troca de entradas, ou seja, seu Erro Médio Quadrado permanecerá entre os valores aceitáveis.

3.5 Análise entre modelos

Neste estágio, haverá a primeira comparação da previsão dos métodos utilizando o critério da comparação do AIC de cada método, onde n é o número de observações; K é o número de parâmetros; e $e'e$ é a soma dos quadrados dos resíduos, como mostra a Expressão 3.4 a seguir.

$$AIC = \log \left(\frac{e'e}{n} \right) + \frac{2K}{n} \quad (3.4)$$

Fonte: Alves, 2007.

Conforme Greene (2000), uma medida alternativa de ajuste sugerida é o critério de informação de Akaike, que é reportado no software R, segundo a Equação 3.4.

O Segundo critério a ser avaliado será a utilização do coeficiente de determinação ajustado ou corrigido pelos graus de liberdade, mais comumente chamado de R^2 ajustado;. Quanto mais próximo do valor 1 o R^2 ajustado, de acordo com a Expressão 3.5, a seguir, se encontrar, mais garantia de previsibilidade correta terá, ou seja, quando maior o R^2 ajustado, maior será o poder de explicação de X em Y e melhor treinado estará o método.

$$\bar{R}^2 = 1 - \frac{n-1}{n-k} (1 - R^2) \quad (3.5)$$

Fonte: Alves, 2007.

Onde: n é o número de observações; K é o número de parâmetros e R^2 é o coeficiente de determinação ajustado.

3.6 Testes Realizados

A análise dos dados foi realizada através do software R versão 2.13.2, utilizando os pacotes necessários dos modelos AR, MA e ARMA, e a análise dos resultados após a previsão foi auferida através de cinco testes: teste Anova; teste Fator de Influência da Variância (VIF); teste Breusch-Pagan (1979); teste White (1980), teste Durbin-Watson (1950).

O teste Anova foi desenvolvido para a escolha do melhor modelo adotado, a partir das variáveis brutas, empregando-se um teste f com a variância de cada modelo para descobrir qual modelo tem um domínio de explicação maior. O critério para solução do problema será a exclusão de variáveis problemáticas dos construtos iniciais.

O teste Fator de Influência da Variância (VIF) foi desenvolvido na amostra para descobrir se existe multicolinearidade entre as variáveis, ou seja, todas as variáveis, segundo o teste VIF, deveriam ser independentes entre si, e o discernimento para solução do problema foi a eliminação de variáveis problemáticas dos construtos iniciais.

Para verificar a heterocedasticidade do resíduo da amostra, foram desenvolvidos dois testes já citados anteriormente, o teste Breusch-Pagan (1979) e o White (1980), por meio dos quais serão verificados os resíduos com a variância não constante, ou seja, uma rejeição de H_0 com os resíduos homocedásticos. O critério para recurso do problema será a exclusão de variáveis problemáticas dos construtos primitivos.

O último teste a ser analisado foi o de Durbin-Watson (1950), que avaliará a autocorrelação das variáveis e construtos, ou seja, em um modelo, pressupõe-se que o termo de erro de qualquer variável não é influenciado pelo termo de erro de suas conseqüentes, nem o influencia. Para uma rejeição de H_0 , os resíduos deverão ser não autocorrelacionados, e o critério para solução do problema será a exclusão de variáveis problemáticas dos construtos iniciais.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

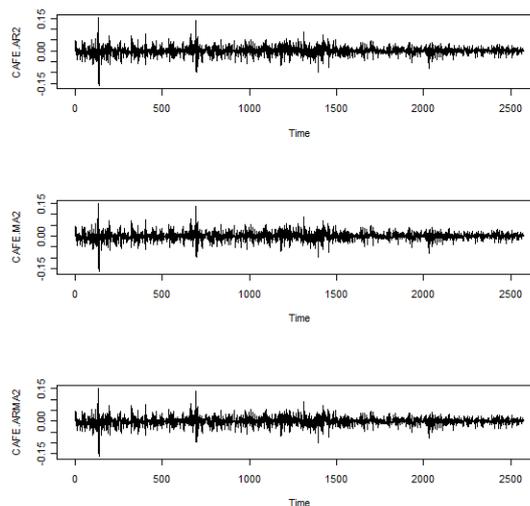
Nesta seção, serão analisados os resultados obtidos na modelagem da série do mercado futuro do café arábica de todos os métodos separadamente, com o intuito de obter o menor AIC para os métodos econométricos AR (p, q), MA (p, q) e ARMA (p, q), proporcionando a escolha do modelo mais ajustado em relação à predição do mercado futuro. No caso da rede neural, vai-se analisar o menor erro médio quadrático entre a modelagem dos valores de saída desejada, treinamento e validação, com a finalidade de escolher a rede neural que obtiver a variação mais baixa entre a entrada e o valor desejado do mercado futuro do café arábica.

Para que a modelagem da série dos modelos econométricos esteja de acordo com estudos empírico realizados na área, é preciso seguir três passos: verificar se a série apresenta raiz unitária com o teste de Durbin e Watson; identificar a dependência no log-retorno com o teste Ljung-Box de autocorrelação conjunta e o teste gráfico de autocorrelação parcial ACF; e verificar a normalidade no erro com o teste Jarque-Bera. Após esta verificação e identificação da série, será feita a comparação entre os modelos distintos.

4.1 Modelos lineares

Como já foi mencionado anteriormente, para que as séries do café arábica dos três modelos econométricos não tenham problemas de raiz unitária, foi feita a diferenciação da série original com o log retorno, como mostra a Figura 2, a seguir, onde os índices de retornos se desenvolvem ao longo do tempo, ao redor de um valor estável zero, e apresentam uma forma de equilíbrio constante. Pode-se concluir que os retornos dos índices são estacionários, corroborando com Farias (2008), que utilizou esta mesma técnica do log retorno e o teste de Durbin e Watson para detectar a estacionariedade entre as entradas.

Figura 2- Série log retorno diária (CAFE) com Raiz Unitária da entrada dos modelos AR (p, q), MA (p, q) e ARMA(p, q)



Fonte: Organizado pelos autores.

Na Figura 2, são apresentadas as três entradas iguais dos modelos econométricos já com raiz unitária, pois foi aplicada a diferenciação da série original com o log retorno. Para o critério de seleção dos modelos AR, MA e ARMA, foi utilizado o critério do AIC dos resultados da predição, como mostra a Tabela 2, a seguir, onde foi considerado o menor valor para a melhor significância dos parâmetros.

Tabela 2- Critério de Seleção da distribuição do modelos

Modelos	Valor de AIC
AR(p,0)	-12837.23
MA(0,q)	-12835.80
ARMA(p, q)	-12856.31

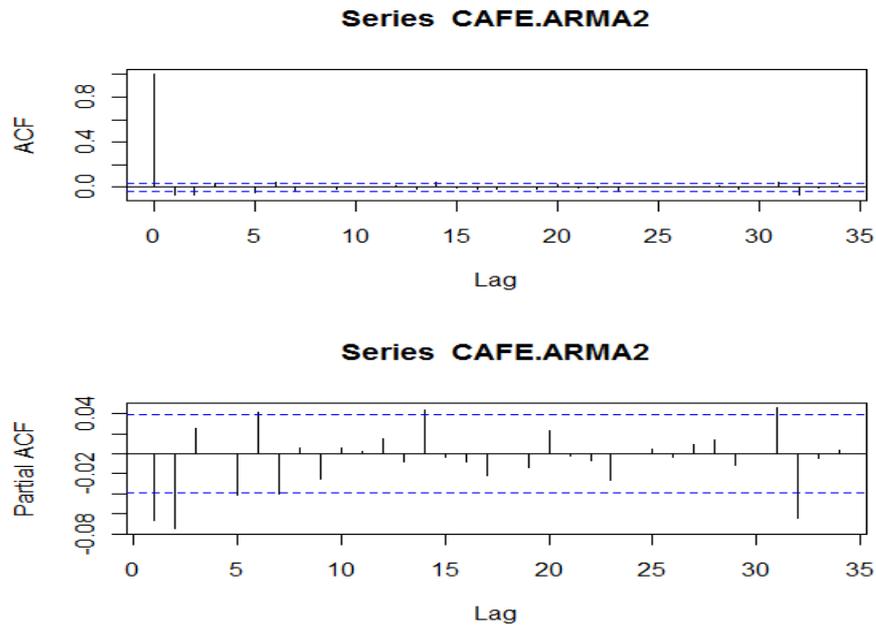
Fonte: Organizado pelos autores.

A Tabela 2 demonstra a comparação entre os modelos econométricos, a partir da qual se pode concluir que, entre os modelos menos complexos como o AR(p, 0) e o MA(0,q), contraintuitivamente, o modelo que obteve melhor ajuste foi o AR(p,0), mas o que mais se destacou entre os três foi o ARMA (p, q), que obteve melhores resultados entre os modelos econométricos com -12856.31 de AIC, corroborando com Bacci (2007), e Ceretta e Righi (2010).

Para que a modelagem do modelo esteja de acordo com estudos empíricos realizados, é preciso seguir três passos: identificar graficamente até que ponto a série tem autocorrelação parcial dos log retornos do modelo; identificar a defasagem da série, segundo o critério significância dos parâmetros; identificar a defasagem da série, segundo o teste Box-Ljung, que identifica a dependência do log retorno e o teste Jarque-Bera, que identifica a normalidade no resíduo.

A Figura 3, a seguir, ilustra o primeiro teste para identificar até que ponto a série tem autocorrelação parcial dos log-retornos do modelo ARMA (p, q), representada pela letra p. O teste gráfico ACF mede a correlação de X em Y. Na Figura 3, a seguir, pode-se perceber que, a partir do zero, há três lag's fora do demarcado, levando-se em consideração de zero até dez, no gráfico ACF e o ACF parcial, pode-se inferir um valor igual a três no ARMA(3, q).

Figura 3- Teste ACF da função de autocorrelação dos log retornos



Fonte: Organizado pelos autores.

Para o primeiro critério de seleção da defasagem da série, representada pela letra q ARMA(3, q), foi utilizada a significância dos parâmetros, como pode ser observado na Tabela 3, a seguir, onde todos os valores de p-valor ($Pr(>|t|)$) foram significativos e menores que 0,05 para um modelo ajustado com os erros padrões robustos.

Tabela 3- Parâmetros e significância dos coeficientes com os erros padrões robustos

	Estimate	Std. Error	t value	Pr(> t)
ar1	1,4461490	0,1215852	-11,894	< 2e-16
ar2	0,6335098	0,1177754	-5,379	7,49e-08
ar3	0,1229233	0,0197713	-6,217	5,06e-10
ma1	1,3800282	0,1217623	11,334	< 2e-16
ma2	0,4609476	0,1131724	4,073	4,64e-05

Fonte: Organizado pelos autores.

Para o segundo critério de seleção da defasagem da série representada pela letra q ARMA(3, q), foi utilizado o teste Box-Ljung, que identifica a dependência do log retorno (KUMAR, *et. al*, 2010). Neste teste foram considerados a presença de um valor menor que 0,5 de p -value na rejeição de H_0 como não tendo correlação nas estatísticas sobre resíduos padronizados, a saída do teste para p -value foi 3.944e-06, menor que 0,5, então válidos para o teste de normalidade dos resíduos. Pode-se concluir que houve a rejeição de H_0 , pois obteve um valor de 0.948, maior que 0,5, para 5% de significância.

Com estes critérios, pode-se perceber que o modelos ARMA(3,2) obtiveram um melhor desempenho entre os vários testados, corroborando com Maio (2008) e Pinto, *et. al* (2008), pois todos os parâmetros foram significativos, com menor AIC e p -value menor do que 0,5 nos resíduos padronizados e maior que 0,5 no teste da normalização dos resíduos.

4.2 Redes neurais

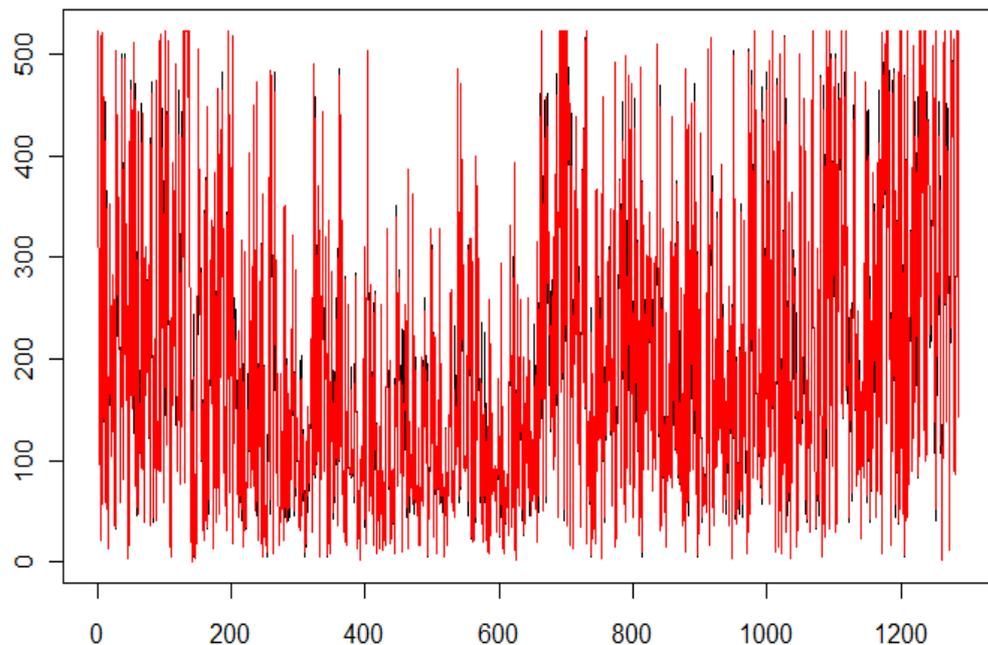
A rede neural desenvolvida neste trabalho constituiu-se de um aprendizado supervisionado. O aprendizado ocorreu no seguimento das quatro grandes etapas do desenvolvimento de uma rede neural: a modificação da taxa de aprendizado; a escolha da topologia da rede neural; a escolha do erro desejado; e o desenvolvimento do AIC e R^2 da rede que mais se destacou segundo critérios já mencionados anteriormente.

A taxa de aprendizagem por interação foi escolhida a partir dos testes feitos na etapa do treinamento da rede neural. Neste processo, ocorreu uma comparação entre os valores escolhidos com os resultados dos erros obtidos. Os critérios utilizados foram o menor erro por interação, menor erro global, menor erro médio quadrático e menor tempo de execução.

Com os testes realizados, concluiu-se que a taxa de aprendizado por interação 15 teve o melhor custo-benefício entre as testadas, com o menor erro médio global no ciclo 5000, o menor erro por interação na posição 15 do vetor de saída do erro e com o segundo menor tempo de execução total. A posição 15 do vetor de saída do erro foi escolhida aleatoriamente. Os resultados foram dispostos na Figura 4, onde é

mostrada a taxa em que ocorreu menor erro médio global, menor erro médio quadrático e menor erro na interação escolhida na comparação da saída calculada pela rede neural, em preto, e com a saída desejada, em vermelho.

Figura 4- Gráfico do retorno da melhor taxa de aprendizado.



Fonte: Organizado pelos autores.

A rede neural conta com uma topologia 5-4-1, pois foi a melhor resposta no treinamento dentre as 10 diferentes topologias testadas, variando entre 2 a 14 neurônios na camada oculta. A melhor situação correspondeu a cinco neurônios na camada de entrada, quatro neurônios na camada oculta e um neurônio na camada de saída. Nessa etapa, também foram observados quantos ciclos seriam necessários para que a predição ocorresse em um erro médio quadrático aceitável, como mostra a Tabela 4, a seguir, com os resultados mais relevantes do Erro Médio Quadrático na Saída da rede neural.

Tabela 4- Tabela da Topologia da MLP

	5-4-1	5-5-1	5-6-1	5-10-1
Ciclo 100	0,0035	0,0042	0,0089	0,0040
Ciclo 500	0,0034	0,0043	0,0075	0,0041
Ciclo 1000	0,0036	0,0049	0,0059	0,0062
Ciclo 8000	0,0038	0,0041	0,0095	0,0039
Ciclo 10000	0,0040	0,0045	0,0065	0,0085

Fonte: Organizado pelos autores.

Na Tabela 4, pode-se observar que um ótimo resultado do erro médio quadrático foi obtido no ciclo 500, com oito neurônios na camada oculta. É o menor erro entre os ciclos testados e topologias, comprovando um dos objetivos do trabalho, qual seja, o de mapear as oscilações da BOVESPA.

O valor do erro desejado por interação foi escolhido a partir da aproximação do erro obtido com o erro desejado, e o critério utilizado foi de menor valor do erro calculado sem danificar os resultados. A seguir, na Tabela 5, os resultados dessa comparação.

Tabela 5- Erro Desejado

	EMQ	EMG	EP
Erro Desejado 0,70	0,0053	0,0619	0,0829
Erro Desejado 0,50	0,0068	0,0694	0,0801
Erro Desejado 0,30	0,0034	0,0459	0,0722
Erro Desejado 0,09	0,0207	0,0701	0,1964

EMQ = Erro Médio Quadrático

EMG = Erro Médio Global

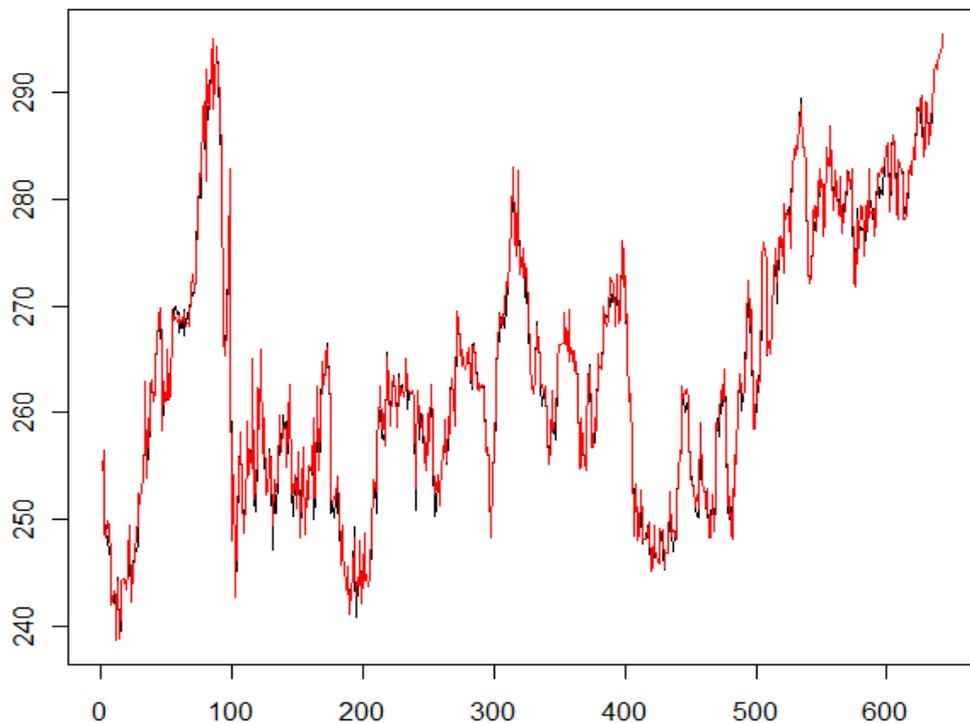
EP = Erro Padrão de Previsão

Fonte: Organizado pelos autores.

Concluiu-se que o valor do erro desejado 0,30 teve o melhor custo-benefício entre os valores comparados, com a melhor aproximação do erro desejado e o menor erro propiciado pelo esforço da rede neural para alcançá-lo.

Levando-se em consideração o treinamento inteiro, a rede neural com 500 ciclos topologia 5-4-1, taxa de aprendizagem 15 e erro desejado de 0,3 foi considerada a mais satisfatória no conjunto do treinamento e validação cruzada.

Figura 5- Gráfico da Validação da Rede Neural



Fonte: Organizado pelos autores

Na Figura 5, é esboçada a variação dos Ciclos e Topologias escolhidos com uma entrada diferente da do treinamento. Na validação da rede neural, a melhor taxa entre as testadas foi a 15, com o Ciclo 500 e Topologia 5-4-1, que obteve menor variação em relação à Saída Desejada e o menor Erro Médio Global do que as demais. Também pode-se observar que a Saída Desejada, em vermelho no gráfico, teve pouca variação entre a Saída calculada pela Rede Neural, em preto, no gráfico.

4.3 Análise da previsão

Nesta subseção, será analisada a predição da série do Mercado Futuro do café arábica da Rede Neural em comparação com a do modelo ARMA(3, 2), que obteve um melhor desempenho do que as modificações dos modelos AR(p) e MA(q) feitas por Rezende *et. al* (2006) e Pinto *et. al* (2008), que obtiveram o mesmo resultado. O intuito desta sessão é de comparar os resultados do erro médio quadrático, o erro médio global e o R² ajustado obtido dos dois modelos para fins de ranquear o método mais explicativo e confiável na predição.

Neste caso, foi analisada a predição do retorno do preço do café arábica com base no passado, como mostra a Expressão 3.3, já mencionada. Para confrontar os resultados do EMG e EMQ das duas predições do modelo ARMA e rede neural, a análise da série temporal foi feita com entradas distintas do treinamento e validação da rede neural com o objetivo principal de validar os dois métodos, encontrando o menor EMG, EMQ e R². A Tabela 6, a seguir, mostra o modelo ARMA e a rede neural com seus respectivos EMG, EMQ e R².

Tabela 6- Comparação do EMQ, EMG e R² dos métodos

	ARMA	Rede Neural
EMG	0,0958	0,0459
EMQ	0,0071	0,0034
R ²	0,1588	0,2348

Fonte: Organizado pelos autores.

Analisando os resultados das três equações dos dois modelos na Tabela 5, pode-se perceber que a rede neural obteve um melhor desempenho nos três critérios de avaliação adotados neste trabalho, tendo-se em mente que o desempenho apresentado pelo EMQ e EMG da rede neural obteve uma melhora satisfatória do que o modelo ARIMA. O R² da Rede Neural demonstrou uma superação do poder explicativo que a variável X exerce em relação à variável Y, comparativamente ao modelo ARIMA (3,2), corroborando com os estudos de

Campos, Mendes, Aguirre, (2008), que compararam os modelos ARIMA, Rede Neuro-Fuzzy, Rede Neural Artificial e propuseram as mesmas conclusões.

5 CONCLUSÕES

Para atender aos objetivos deste trabalho, foram utilizados vários métodos de previsão existentes na literatura. Realizaram-se testes entre os parâmetros modificáveis destes métodos e experimentos a fim de determinar o melhor ajuste dos parâmetros de suavização nos modelos de médias móveis (MA), ajustes da linha de tendência nos modelos de projeção (AR), a melhor ordem p , q no modelo ARIMA, ou o menor erro na modificação da taxa de aprendizado, topologia, erro desejado e ciclo da rede neural.

Este estudo obteve resultados positivos na predição de oscilações do mercado futuro do café arábica. Pode-se perceber que o desempenho do modelo ARMA foi também satisfatório, e, levando-se em consideração a complexidade dos dois modelos analisados e os resultados positivos obtidos, é possível concluir que os dois modelos mostram um poder computacional satisfatório.

Três critérios de avaliação foram realizados na comparação dos dois modelos. O primeiro critério levou em consideração o valor do Erro médio Quadrático obtido do modelo ARMA e da rede neural, e, nesta comparação, pode-se perceber que o EMQ da rede neural obteve um valor relativamente mais baixo do que o do modelo ARMA, fazendo, assim, com que o primeiro critério de validação seja a favor da rede neural. O segundo critério de avaliação foi o Erro Médio Global dos modelos, onde se pode perceber que a Rede Neural também obteve um melhor desempenho, levando-se em consideração o menor valor com 0,0459 em relação ao modelo ARMA, com 0,0958. O terceiro método de avaliação foi a comparação do poder de explicação entre as variáveis dos modelos, no qual se pode perceber que a rede neural foi superior, obtendo um resultado de 0,2348 do R^2 ajustado contra 0,1588 do modelo ARMA.

Mas, como já foi mencionado anteriormente, o modelo ARMA não obteve resultados insatisfatórios e, levando em consideração a complexidade dos dois algoritmos, pode-se perceber que o modelo menos complexo tem um poder

satisfatório em alguns casos. Porém, para o mercado futuro do café arábica, pode-se concluir que o modelo mais complexo, rede neural, apresenta resultados ainda mais satisfatórios que os modelos lineares.

Como trabalho futuro, espera-se desenvolver um método com mais critérios de avaliação entre os dois modelos, que possam trazer resultados mais concretos. Também se sugere comparar várias *commodities* como o boi gordo e a soja, levando-se não somente em consideração o retorno do preço do mercado futuro do café arábica, mas também a volatilidade do retorno do preço do mercado à vista e /ou futuro, com outros modelos da família GARCH como o I-GARCH, o T-GARCH e o E-GARCH.

ABSTRACT

The future market of arabica coffee can be considered as one which has the highest risk, such as climate risk, the crop cycle and tariff barriers concerning other agricultural products. This statement refers to the following questions: What is the behavior of Arabica coffee in future market based on econometric, linear and heuristic methods? And which method has the best prediction concerning the future of coffee? With the aim of answering it we tried to develop a heuristic method and three econometric models that use as input variable, the return of daily price of the future market of arabica coffee with its corresponding lag, with a total of 2574 quotes from March 23rd 2000 to September 22nd 2010. The heuristic method has a neural network multilayer perceptron, trained with the error backpropagation algorithm. After the development and the variable modeling, the results of the two models which got the best performance were compared to identify which model has better prediction concerning the future market of arabica coffee. Through the results it can be seen that both models had a satisfactory performance, but the three criteria evaluation of methods used showed that the neural network has a better explanation than the econometric models in futures market of arabica coffee.

Keywords: Future Market; Arabica Coffee; Neural Network

NOTAS

¹ Mestrando em Administração pela Universidade Federal de Santa Maria (UFSM).

² Professor Adjunto do Programa de Pós-Graduação em Administração e Doutor em Economia Aplicada pela Universidade Federal de Viçosa (UFV).

³ Professora Adjunta do Programa de Pós-Graduação em Administração da UFSM e Bolsista de Produtividade do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS

ALVES, J. S. Análise comparativa e teste empírico da validade dos modelos CAPM tradicional e condicional: o caso das ações da Petrobrás. *Rev. Ciênc. Admin.*, Fortaleza, v. 13, n. 1, p. 147-157, 2007.

ASSAD, E. D. *et al.*. Sistema de previsão da safra de soja para o Brasil. *Pesquisa Agropecuária brasileira*, Brasília, v.42, n.5, p.615-625. 2007.

BACCI, L. A. *Combinação de métodos de séries temporais para previsão da demanda de café no Brasil*. Dissertação (Mestrado em Engenharia de Produção). Departamento de Engenharia . Itajubá – MG. 2007.

BOX, G. E. P.; JEANKINS, G. M. *Time Series Analysis: forecasting and control*. San Francisco: Holden-day. 1976.

BOX, G. E. P.; JEANKINS, G. M. *Time Series Analysis: Forecasting and Control*. Englewood Cliffs NJ: Prentice-Hall, New York. 1994.

CAMPOS, R. J.. *Previsão de séries temporais com aplicações a séries de consumo de energia elétrica*. Dissertação submetida à banca examinadora do Programa de Pós-Graduação Mestre em Engenharia Elétrica da Universidade Federal de Minas Gerais. Belo Horizonte. 2008.

CASTRO, E. R.; TEIXEIRA, E. C.; LIMA, J. E.. Efeito da desvalorização cambial na oferta, no preço de insumos e na relação entre os fatores na cultura do café. *Revista de Economia e Sociologia Rural*, Rio de Janeiro, vol. 43, nº 03, p. 421-441, 2005.

CERETTA, P. S; RIGHI, M. B; SCHLENDER, S. G. Previsão do preço da soja: uma comparação entre os modelos ARIMA e redes neurais artificiais. *Revista Informações Econômicas*, Instituto de Economia Agrícola. São Paulo. v.40, n.9. p 15-27. 2010.

COELHO, L. *et. al.*; Podemos prever a taxa de cambio brasileira? Evidencias empírica utilizando inteligência computacional e modelos econométricos. *Revista Gestão de Produção*, São Carlos, v.15, n. 3. 2008.

FARIAS, H. P.; SÁFADI, T.. Causalidade Entre as Principais Bolsas de Valores do Mundo. *RAM - Revista de Administração Mackenzie*, V. 11, N. 2, São Paulo – SP. 2010.

FARHI, M.. O impacto dos ciclos de liquidez no Brasil: Mercados financeiros, taxa de câmbio, preços e política monetária. *Revista Política Econômica em Foco*. Campinas – SP, n. 7. 2006.

GAIO, L. E.; JÚNIOR, L, G. C; OLIVEIRA, A. R.. PREVISÃO DE PREÇO FUTURO DO BOI GORDO NA BM&F: UMA COMPARAÇÃO ENTRE MODELOS DE SÉRIES TEMPORAIS E REDES NEURAI. *Organizações Rurais & Agroindustriais*. Lavras. v. 9, n. 2, p. 272-288. 2007.

GAITHER, N.; FRAZIER, G. *Operations management*. Ohio: South-Western, 2001.

GALÃO, O. F. *et. al.*. *Econometric analysis*. New Jersey: Prentice Hall, 2000.

GALVÍNCIO, J. D.; SOUSA, F. A. S.; SOUSA I. F.. USO DE MODELOS AUTO-REGRESSIVO E MÉDIAS-MÓVEIS PARA GERAÇÃO DE VAZÕES MÉDIAS MENSIS NA BACIA HIDROGRÁFICA DO ALTO SÃO FRANCISCO. *XII Congresso Brasileiro de Meteorologia*. Foz de Iguaçu-PR, 2002.

HAYKIN, S. *Redes Neurais: princípios e prática*, 3ª Edição, São Paulo. Bookman. 2001.

HASSAN, M. D. R. ; BAIKUNTH, N.. *Stock Market Forecasting Using Hidden Markov Model: A New Approach*. Proceedings of the 2005 5th International Conference on Intelligent Systems Design and Applications (ISDA'05). IEEE Computer Society. 2005.

IQUIAPAZA, R. A. ; BRESSAN, A. A. ; AMARAL, H. F. . Previsão Não-linear de Retornos na BOVESPA: Volume Negociado em um Modelo Auto-Regressivo de Transição Suave. *ANPAD - RAC*, Curitiba, v. 14, n. 1, art. 8, pp. 149-171, Jan./Fev. 2010.

JUDD, J. S, *Neural Network design and Complexity of Learning*. MIT Press, USA, 1990.

JUNQUEIRA, F. Z. . *Contratos futuros de café como alternativa para diminuir o risco de uma carteira*. Universidade de São Paulo. São Paulo. 2005.

KIM, K. ; LEE, W. B. . *Stock market prediction using artificial neural networks with optimal feature transformation*. *Neural Computing & Applications*. Springer-Verlag, 13: 255-260, 2004.

KUMAR, U.; RIDDER, K. . GARCH modelling in association with FFTeARIMA to forecast ozone episodes. *Journal Institute for Technological Research, Elsevier*. Belgica. 2010.

LAWRENCE, R. *Forecasting stock prices using neural networks*. Department of Computer Science, University of Manitoba, December 1997.

LUDWING J.R., O; MONTGOMERY, E. . Redes Neurais: Fundamentos e Aplicações com Programa em C. *Revista Ciência Moderna*. Rio de Janeiro:, 2007.

MAIA, M.; ALVES, T. S; *Métodos Bayesianos de estimação e comparação de modelos na família GARCH*; Trabalho de conclusão de curso - Estatística – UFPR; Curitiba, 2008.

MARAGNO, R. C. ;KALATZIS, A. E. G.; PAULILLO, Luiz Fernando de O. A nova economia institucional: aspectos que influenciam na relação comercial Brasil – União Européia. *XIII SIMPEP*. Bauru – São Paulo. 2006.

MOURA, A. F. M. ; GUTIERREZ, C. E. C.. Quebra estrutural, modelagem e previsão do preço do café brasileiro. In: ANPCONT, 2011, Vitória. *V Congresso Anpcont - "Contabilidade e desempenho no novo ciclo de desenvolvimento"*., 2011.

NASCIMENTO J.R., L C.; YONEYANA, T. *Inteligência Artificial em Controle de Automação*. São Paulo: FAPESP, 2004.

NISHIJIMA, M.; SAES, M. S.. ANÁLISE ECONÔMICA DAS BARREIRAS TARIFÁRIAS AO CAFÉ SOLÚVEL BRASILEIRO. *XLIV Congresso da Sociedade Brasileira de Economia e Sociologia e Rural Questões Agrárias, Educação no Campo e Desenvolvimento*. Fortaleza. 2006.

OLIVEIRA, A. C. S.; SOUZA, A. A.; LACERDA, W. S.; Aplicação de Redes Neurais Artificiais na Previsão da Produção de Álcool. *Revista Ciência e Agrotecnologia*, Lavras-MG. V. 34, n. 2, p. 279-284, mar./abr. 2010.

PHUA, P.K.H.; MING, D.; LIN, W.. Neural Network With Genetic Algorithms For Stocks Prediction. *Fifth Conference of the Association of Asian-Pacific Operations Research Societies*, 5th - 7th July, Singapore, 2000.

PINTO, P. A. L. A.; PEREIRA, E. S.; OLIVEIRA, M. C.; DOS SANTOS, José Márcio; MAIA, Sinézio Fernandes. APLICAÇÃO DO MODELO ARIMA À PREVISÃO DO PREÇO DAS COMMODITIES AGRÍCOLAS BRASILEIRAS. *XLVI Congresso da Sociedade Brasileira de Economia Administrativa e Sociologia Rural*. Rio Branco – Acre. 2008.

RAPOSO, L. R. *Análise da Relação Volatilidade de Preço-Volume nos Mercados Brasileiros de Futuros Agropecuários*. Tese de Doutorado apresentado na Universidade de Viçosa. Minas Gerais. 2000.

REZENDE, M. L.; BACCI, L. A.; MEDEIROS, A. L.; MONTEVECHI, José Arnaldo Barra. Combinação de métodos de séries temporais para previsão da demanda de café no Brasil. *XIII SIMPEP*. São Paulo. 2006.

RIBEIRO, K. C. S.; SOUZA, A. F.; ROGERS, P.. Preços do café no brasil: variáveis preditivas no mercado à vista e futuro. *Revista de Gestão USP*, São Paulo, v. 13, n. 1, p. 11-30. 2006.

ROBERT E. D.; MAGEE, J. W.H.C.. *Technical Analysis of Stock Trends*. American Management Association, 2007.

SAES, M. S. M.; NAKAZONE, D. Estudo da competitividade de cadeias integradas no brasil: impactos das zonas de livre comércio. *Documento Elaborado*. Campinas - SP. 2002.

SAES, M. S. M. . O agronegócio café do Brasil no mercado internacional. *Revista FAE Business*. Curitiba. n. 9. 2004.

SANTOS, D. G.. *Estimação de Volatilidade em Séries Financeiras: Modelos Aditivos Semi Paramétricos e GARCH*. Dissertação de Mestrado em Economia – UFRGS, Porto Alegre. 2008.

SCHALKOFF, R. J.. *Artificial neural networks*. SAGE Publication - Progress in Physical Geography. New York: McGraw-Hill, 2001.

SECEX, Secretaria de Comércio Exterior; DEPLA, *Balança Comercial Brasileira - Dados Consolidados* é uma publicação do Departamento de Planejamento e Desenvolvimento do Comércio Exterior. 2011.

SMITH, K. A.; GUPTA, J. N. D. Neural networks in business: techniques and applications for the operations researcher. v. 27, *Oxford: Computers & Operations Research*, Elsevier. 2000.

SOBREIRO, V. A.; ARAÚJO, P. H. S. L. . NEGANO, M. S. Precificação do Etanol Utilizando Técnicas de Redes Neurais Artificiais. *Revista de Administração*. São Paulo. v.44, n.1. Nicolau Reinhard. 2009.

VALENÇA, M. *Fundamento das redes neurais: exemplos em Java*. 2ª Edição. Olinda: Livro Rápido – Elógica, 2009.

VERISSIMO, V. C., Agricultura e Meio Ambiente: Estudo de impactos da ALCA em Café e Maçã e Seus Sistemas de Produção Agrícola. *Congresso International Development Research Centre - IDRC-CRDI*. Uruguai. 2003.