

Previsão de Preços Através da Análise Espectral Multivariada: Evidências para Commodities da BM&Fbovespa

Carlos Alberto Orge Pinheiro [†]
Universidade do Estado da Bahia - UNEB

Valter de Senna ^Ω
Faculdade de Tecnologia Senai-Cimatec

RESUMO

Esta pesquisa teve como proposta realizar previsões dos preços de um grupo de commodities através do modelo espectral de análise multivariada e compará-las com aquelas obtidas por modelos clássicos de previsão e de redes neurais. A escolha das commodities etanol, boi gordo, milho, café e soja deu-se por conta do destaque na pauta de exportações no ano de 2013. O modelo espectral multivariado demonstrou-se adequado, quando comparado com os demais, ao permitir melhores desempenhos preditivos. Os resultados obtidos no período fora da amostra, mediante o uso das medidas de erro e do teste estatístico, confirmam isso. A pesquisa pode auxiliar os profissionais do mercado na formulação e aplicação de políticas direcionadas ao setor agrícola por conta da relevância da previsão dos preços como instrumento de planejamento bem como na análise do comportamento do mercado financeiro para aqueles que necessitam de proteção a oscilações dos preços.

Palavras-chave: Análise espectral. Previsão. Commodities.

Recebido em 26/05/2015; revisado em 21/08/2015; aceito em 23/10/2015; divulgado em 05/09/2016

**Autor para correspondência:*

[†]. Mestre em Modelagem Computacional e Tecnologia Industrial pela Faculdade de Tecnologia Senai Cimatec e Doutorando no mesmo Programa.

Vínculo: Professor DE pela Universidade do Estado da Bahia - UNEB.

Endereço: Rua Silveira Martins, 2555, Cabula, Salvador-BA-Brasil. Cep. 41.150-000.

E-mail: carlos.orge@terra.com.br

^Ω Pós-Doutor em Probabilidade e Estatística pela University of Southampton.

Vínculo: Professor do Programa de Modelagem Computacional e Tecnologia Industrial da Faculdade de Tecnologia Senai Cimatec.

Endereço: Av. Orlando Gomes, 1845 - Piatã, Salvador – BA – Brasil. Cep. 41.650-010.

E-mail: vsenna@terra.com.br

Nota do Editor: Esse artigo foi aceito por Bruno Felix.



Este trabalho foi licenciado com uma Licença [Creative Commons - Atribuição 3.0 Não Adaptada](http://creativecommons.org/licenses/by/3.0/).

1 INTRODUÇÃO

Nos últimos anos, a agricultura no Brasil se desenvolveu destacando-se como atividade de alto valor econômico e social com tendência de crescimento acentuado (CAMPOS, 2007). O desenvolvimento dos mercados interno e externo contribuiu para o caráter dinâmico da agricultura, com a incorporação de tecnologias produtivas para satisfazer às exigências desses mercados. Para Oranje (2003), a produtividade da agricultura pode ser observada por meio da competitividade dos preços, explicada, pela opção dos importadores por escolherem, entre os diferentes exportadores, aqueles cujos preços não são elevados.

Assim, a análise de preços reveste-se de singular importância para os participantes do mercado agrícola, sejam eles compradores, vendedores ou pessoas que necessitem de proteção contra oscilações dos preços. As decisões tomadas pelos produtores, mesmo antes da realização da colheita, presumem o conhecimento do comportamento dos preços (RIBEIRO; SOSNOSKI; OLIVEIRA, 2010). Além delas, as decisões referentes ao conjunto de produção e à adoção de políticas de financiamento como alternativa de assegurar preços são baseadas em tendências.

Como as atividades agrícolas são caracterizadas por apresentarem movimentos cíclicos, sofrendo influência de vários fatores do mercado e apresentando elevadas oscilações, conforme descrito por Oliveira e Aguiar (2003), isso acaba se constituindo num obstáculo para sua previsibilidade. Portanto, a previsão dos preços passa a ser um dos principais entraves para execução do planejamento e avaliação das atividades. A previsão de preços tem sido cada vez mais objeto de interesse dos profissionais do mercado e dos acadêmicos, pois através dela é possível reduzir a incerteza no processo de decisão para aqueles que negociam no mercado.

Schwager (1995) explica que com a previsão é possível auxiliar os envolvidos nos mercados de commodities (mercadoria padronizada de baixo valor agregado) agrícolas tanto como os *hedgers*, que lidam com transações físicas de produtos, buscando proteção de futuras oscilações de preços, quanto os especuladores que querem assumir riscos em razão de possíveis ganhos. Com isso, todos os participantes do mercado de commodities necessitam de informações sobre os preços, os quais são fundamentais para a rentabilidade de suas atividades.

Pesquisas (Bressan, 2004; Lima, Góis e Ulises, 2007; Sobreiro et al., 2008; Arêdes e Pereira, 2008; Lima et al., 2010; Ceretta, Righi e Schlender, 2010; Ferreira et al., 2011; Miranda, Coronel e Vieira, 2013; Tibulo e Carli, 2014) sobre commodities agropecuárias fazem uso de modelos de previsão avaliando o comportamento dos preços a partir da utilização de dados da commodity em análise. Portanto, utilizam modelos estruturados para realização de previsões de preços da commodity com base nos dados da série temporal em estudo.

No trabalho realizado por Aguiar e Borestein (2012), os autores argumentam sobre a importância de utilizar outros dados que possam influenciar os preços das commodities em análise, com o intuito de monitorar as flutuações dos seus preços. Com base nessa perspectiva, a pesquisa realiza a previsão dos preços de um grupo de commodities agropecuárias, mediante o modelo de Análise Espectral Singular Multivariada (AESM), em razão da relevância das informações sobre o comportamento dos preços que são fundamentais para aqueles que negociam no mercado agropecuário. Em seguida, visando avaliar o desempenho preditivo, os resultados obtidos na pesquisa são comparados com modelos já utilizados em previsão de preços de commodities agropecuárias.

A escolha pelo modelo AESM é dada por um par de motivos: i) o modelo captura estruturas das séries temporais que representam o comportamento abrangente da série temporal levando em consideração os efeitos do conjunto analisado e ii) evidências empíricas (Patterson et al., 2011, Hassani e Mahmoudvand, 2013) sugerem que as previsões realizadas com base no modelo AESM apresentam melhor desempenho quando comparadas com aquelas dos modelos que só levam em conta a série temporal em análise.

O artigo foi organizado em cinco seções. Na próxima seção é apresentada a fundamentação teórica de modelos aplicados para séries temporais com sazonalidade. Na seção 3 são descritos a metodologia e modelos de previsão utilizados na pesquisa. Na seção 4 os dados e os resultados dos testes de normalidade, normalidade multivariada, linearidade, estacionaridade, testes preditivos e resultados empíricos são apresentados. As conclusões e sugestões para próximas pesquisas são expostas na seção 5.

2 FUNDAMENTAÇÃO TEÓRICA

Na literatura de séries temporais é possível distinguir duas estratégias clássicas de modelagem. A primeira delas refere-se aos modelos de suavização exponencial enquanto a segunda caracteriza a metodologia de Box-Jenkins. Os modelos de suavização exponencial, também definidos como modelos de alisamento ou amortecimento, são técnicas desenvolvidas

para um fim específico e não requerem fundamentação probabilística. Utilizam a ideia de distribuição de pesos no decorrer do período, com o objetivo de considerar ponderações variantes no tempo. Dentre os modelos de suavização exponencial, o algoritmo sazonal Holt-Winters(HW) é indicado para séries temporais com padrão de comportamento mais complexo, que além de apresentarem sazonalidade, consideram tendência e ruído (MORETTIN; TOLOI, 2006).

Levando em conta que, por intermédio da suavização, um processo de médias móveis é pouco intuitivo para representar o comportamento de uma particular série temporal e, considerando que a aplicação dos modelos autorregressivos é comum em diferentes áreas do conhecimento, podem-se utilizar os termos autorregressivos e de médias móveis simultaneamente com o objetivo de melhoria. Assim, tal combinação caracteriza o modelo definido pela literatura como *Autoregressive Moving Average Model* (ARMA).

Outra possibilidade é tornar a série temporal estacionária por meio de um processo de diferenciação, ou seja, tomar diferenças sucessivas da série temporal original. Com isso, é dada a formação do modelo *Autoregressive Integrated Moving Average* (ARIMA). Esse modelo fundamenta-se na construção de métodos ajustados em suas propriedades probabilísticas.

Em algumas situações, as séries temporais podem apresentar flutuações periódicas, a exemplo dos fenômenos meteorológicos que, quando avaliados trimestralmente, costumam apresentar correlações mais elevadas ao serem usadas defasagens múltiplas de quatro, conforme as estações do ano ou em dados econômicos que exigem defasagens múltiplas de doze, de acordo com os meses do ano (ESQUIVEL, 2012). Com isso, é adequado considerar uma periodicidade estocástica para avaliar o comportamento da série temporal. Quando o modelo ARIMA leva em consideração essa periodicidade, ele passa a ser conhecido como *Seasonal Autoregressive Integrated Moving Average* (SARIMA).

Dadas as restrições do modelo ARIMA em manter a variância do erro constante ao longo do

tempo, Engle (1982) sugeriu um modelo para realizar previsões. Definido por *Autoregressive Conditional Heteroskedasticity* (ARCH), a sua modelagem introduz a variância condicional do erro determinada pela defasagem ao quadrado dos erros. A ideia é que se possa medir a persistência de choques sobre a variância através de um coeficiente. Quanto mais próximo for da unidade, a indicação é que impactos de choques nos preços

levam algum tempo para se dissiparem. Outra possibilidade é dada pelo modelo ARCH generalizado ou *Generalized Autoregressive Conditional Heterocedasticity* (GARCH) proposto por Bollerslev (1987).

Se para os modelos clássicos descritos o sinal (tendência e periodicidade) da série temporal é estudado em termos de unidades de tempo, para os modelos espectrais a extração das informações sobre a série temporal é realizada em termos de unidades de frequência. A base dos modelos espectrais reside no fato de que qualquer função no tempo pode ser definida pela superposição de ondas senoidais de diferentes frequências. Na literatura, os modelos espectrais, quando comparados com os modelos clássicos, decompõem a série temporal em várias componentes com características de periodicidade mais simples, apresentando vantagens na eliminação do ruído da série original, de acordo com Marques e Antunes (2009), os quais, assim como Vityazev, Miller e Prudnikova (2010), investigam a estrutura das séries temporais com mais detalhes quando comparados com as Transformadas de Fourier e de Wavelet.

Além desses modelos de previsão, outro que não requer parâmetros da série temporal em análise é o modelo de Redes Neurais Artificiais (RNA) o qual mediante um capturador automático aproxima equações sem que seja necessário deduzi-las. Além de não requerer parâmetros da série, o modelo se diferencia dos modelos clássicos e de suavização exponencial de previsão por ser um modelo que opera com algoritmo de aprendizado. Tal algoritmo busca 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 eficiente, valores futuros (TURBAN, 1993).

A construção do modelo RNA envolve desde a modelagem adequada da rede neural até as transformações utilizadas para transmitir os dados à rede e aos métodos utilizados para interpretar os resultados obtidos. Esses aspectos são dados pela modelagem, transformação e interpretação e são fundamentais na utilização do modelo para realização das previsões.

2.1 DESEMPENHO DAS PREVISÕES DE MODELOS CLÁSSICOS E ESPECTRAIS

Pesquisa realizada por Hassani (2007) — ao confrontar os resultados de previsão entre o modelo de análise espectral, cuja análise é univariada, e alguns modelos clássicos — verificou que o modelo espectral apresentou melhor desempenho. O autor, além de utilizar o método espectral, fez uso do modelo de médias móveis, do modelo ARIMA e do algoritmo sazonalHW, também empregados por Brockwell e Davis (2002), para a previsão da série

temporal morte accidental nos Estados Unidos na década de setenta. A pesquisa revelou que o modelo espectral gerou previsões mais precisas que aquelas obtidas pelos modelos clássicos.

Ainda em relação ao modelo espectral, Menezes et al. (2014), ao confrontarem os resultados de previsão para dados do consumo de energia elétrica de uma distribuidora que atende parte do estado do Rio de Janeiro, confirmaram melhor desempenho da análise espectral em relação ao modelo ARMA e o algoritmo sazonal HW. Esquivel (2012), ao utilizar dados temporais meteorológicos e financeiros, cujas séries apresentam diferentes características, concluiu que o modelo espectral de análise univariada produziu resultados de previsão tão bons ou superiores àqueles obtidos pelo modelo SARIMA e o algoritmo sazonal HW.

Em outra pesquisa, Hassani, Heravi e Zhigljavsky (2009) utilizam o modelo ARIMA e o algoritmo sazonal HW para previsão de oito indicadores de produção industrial para Alemanha, França e Reino Unido. Assim, demonstraram o melhor desempenho para previsões obtidas pelo modelo AESM quando comparado com aqueles obtidos pelos modelos clássicos. Em Patterson et al., (2011), ao utilizarem dados sobre índices mensais de produção industrial no Reino Unido, os autores verificaram que tanto o modelo espectral de análise univariada como o modelo AESM apresentaram melhor desempenho de previsão quando comparados com o modelo ARMA.

Mesma conclusão sobre o desempenho de previsão dos modelos espectrais univariado e multivariado em relação ao modelo ARIMA e ao algoritmo sazonal HW é obtida por Hassani Heravi e Zhigljavsky (2009) ao investigarem séries temporais de consumo de energia elétrica e gás na Alemanha, França e Reino Unido. Utilizando as mesmas séries, Hassani e Mahmoudvand (2013) demonstram que o modelo AESM apresentou melhores desempenhos quando comparado com o modelo espectral de análise univariada.

Em relação às pesquisas com commodities agropecuárias, para realizar previsões dos preços para boi gordo, café e soja, Bressan (2004) fez uso do modelo clássico ARIMA e do modelo RNA. Os resultados apresentados pelo autor indicam ganhos na maioria dos contratos analisados, demonstrando o potencial de utilização dos modelos como ferramenta de decisão em negociações com destaque para operações fundamentadas nas previsões obtidas através do modelo ARIMA.

Lima, Góis e Ulises (2007) realizaram previsões para os preços do açúcar, café, boi gordo, milho e soja usando os modelos ARMA e ARIMA. O poder de previsão de cada

modelo foi comparado, e para os autores na maioria das situações o modelo ARIMA demonstrou melhor poder de previsão.

Visando avaliar a potencialidade da utilização de modelos de previsão para séries temporais preços do trigo, no estado do Paraná, Arêdes e Pereira (2008) utilizaram os modelos ARIMA, SARIMA e ARCH a fim de avaliar suas potencialidades de previsão. De acordo com os resultados obtidos pelos autores, todos os modelos foram eficazes na previsão do preço do trigo, dado que os preços previstos foram próximos aos preços observados.

Para a commodity soja, Lima et al. (2010) investigaram o comportamento dos preços com base no modelo ARIMA-GARCH e RNA, explicando que os resultados de previsão dos preços foram particularmente satisfatórios. Ceretta, Righi e Schlender (2010) compararam o modelo ARIMA com RNA, aplicados à série temporal preços da soja, concluindo não existir superioridade de desempenho preditivo entre os modelos. Para avaliar a aplicação do modelo RNA, Sobreiro et al. (2008) utilizam os preços da commodity açúcar. Os resultados obtidos demonstram que a aplicação obteve uma aproximação significativa comparada às cotações reais, o que para os autores evidencia a importância do modelo como alternativo na estimação dos preços.

Ferreira et al. (2011) realizam pesquisa para previsões dos preços das commodities soja, boi gordo, milho e trigo com base no modelo RNA. Os resultados obtidos pelos autores evidenciam a possibilidade do uso das redes neurais como uma estratégia de precificação. Ainda em relação ao modelo RNA utilizado para previsão de preços do café, Miranda, Coronel e Vieira (2013), ao avaliarem as previsões realizadas, concluíram que o modelo quando comparado com ARMA demonstrou-se eficaz na previsão do preço do café, uma vez que os preços previstos foram próximos aos observados.

Para a previsão do milho, Tibulo e Carli (2014) fazem uso do modelo ARIMA e do algoritmo sazonal HW. Os autores concluem que o algoritmo sazonal HW aditivo apresentou melhores resultados para previsões do preço do milho em comparação ao modelo ARIMA.

Essas pesquisas sobre previsão de preços para commodities agrícolas apresentam diferentes metodologias para identificar padrões da série temporal e realizar previsões. No entanto, ao investigarem o comportamento da série temporal em análise, os modelos citados não levam em consideração as séries temporais dos preços das outras commodities, deixando de avaliar o comportamento abrangente das séries e os efeitos do conjunto. Isso acaba

justificando a aplicação do modelo AESM pelo fato de ele se propor a representar o comportamento abrangente da série temporal em análise.

3 METODOLOGIA

Com o objetivo de avaliar a contribuição do modelo AESM na previsão dos preços, além de explorar sua aplicação em séries temporais de commodities agropecuárias, a pesquisa irá utilizar o algoritmo sazonal HW, os modelos SARIMA, ARIMA-GARCH e RNA. Para identificação das características das séries temporais, serão aplicados testes estatísticos para a normalidade, conforme Anderson-Darling (AD) e Shapiro-Wilk (SW), além de Doornik-Hansen-Omnibus (DHO) para a normalidade multivariada. Também serão utilizados na pesquisa os testes de McLeod e Li (1983) e Tsay (1986) para linearidade e de Dickey-Fuller Aumentado (DFA) e Kwiatkowski-Phillips-Schmidt-Shin (KPSS) para analisar a estacionariedade das séries.

Um aspecto importante da pesquisa é poder confrontar as previsões dos modelos, fora do período da amostra e avaliar seu desempenho através das medidas Erro Quadrático Médio (EQM) e Erro Quadrático Acumulado (EQA), além de verificar a significância preditiva entre as previsões realizadas. Essa verificação é obtida pela aplicação do teste estatístico proposto por Diebold e Mariano (1995), definido nesta pesquisa como teste DM. A seguir são descritos os modelos de previsão utilizados, além das medidas de erro.

3.1 MODELO AESM

As suas primeiras pesquisas foram feitas com dados atmosféricos. Para isso, as séries temporais estavam associadas ao clima e representadas por localidades ou regiões num mapa (KEPPENNE; GHIL, 1993, PLAUT; VAUTARD, 1994). Semelhante ao modelo espectral de análise univariada, o modelo AESM é definido em dois estágios: decomposição e reconstrução. O estágio de decomposição é dado por dois passos: incorporação e decomposição em valor singular. A incorporação pode ser considerada como um mapeamento que transfere um conjunto M de séries temporais unidimensionais $Y_i^{(i)} = (y_1^{(i)}, \dots, y_{N_i}^{(i)})$, com $i = 1, \dots, M$, para uma matriz multidimensional $[X_1^{(i)}, \dots, X_{K_i}^{(i)}]$ com vetores $X_j^{(i)} = (y_j^{(i)}, \dots, y_{j+L_i+1}^{(i)})^T \in R^{L_i}$, onde $K_i = N_i - L_i + 1$. Os vetores $X_j^{(i)}$ são chamados de vetores defasados.

Semelhante ao modelo espectral de análise univariada, a matriz $X^{(i)}$ é uma matriz Hankel que tem como característica suas entradas constantes ao longo das diagonais paralelas à diagonal secundária. Neste passo, considerando um conjunto M de séries temporais, com

$t = 1, \dots, N$, são definidas as matrizes trajetórias $X^{(i)}$, para $i = 1, \dots, M$ em cada série temporal $Y_{t_i}^{(i)}$, considerando que a matriz trajetória é uma sequência dos vetores defasados. O resultado da incorporação, conforme descrito por Hassani e Mahmoudvand (2013), é a formação de um bloco de matrizes trajetórias X_V , conforme:

$$X_V = \begin{bmatrix} X^{(1)} \\ \vdots \\ X^{(M)} \end{bmatrix} \quad (1)$$

No segundo passo, definido como decomposição em valor singular, é realizada a decomposição da matriz $X_V X_V^T$ obtendo uma soma de matrizes elementares. Assim, denota-se por $\lambda_{V_1}, \dots, \lambda_{V_{M \times L}}$ os autovalores de $X_V X_V^T$ em ordem decrescente de magnitude ($\lambda_{V_1} \geq \dots \geq \lambda_{V_{M \times L}} \geq 0$) e por $U_{V_1}, \dots, U_{V_{M \times L}}$ os autovetores ortogonais. A matriz $X_V X_V^T$ é dada conforme:

$$X_V X_V^T = \begin{bmatrix} X^{(1)} X^{(1)T} & X^{(1)} X^{(2)T} & \dots & X^{(1)} X^{(M)T} \\ X^{(2)} X^{(1)T} & X^{(2)} X^{(2)T} & \dots & X^{(2)} X^{(M)T} \\ \vdots & \vdots & \ddots & \vdots \\ X^{(M)} X^{(1)T} & X^{(M)} X^{(2)T} & \dots & X^{(M)} X^{(M)T} \end{bmatrix} \quad (2)$$

A estrutura em (2) é similar à matriz de variância-covariância obtida na literatura clássica da análise estatística multivariada. A matriz $X^{(i)} X^{(i)T}$ é a mesma utilizada pelo modelo de análise univariada para uma única série temporal $Y_{t_i}^{(i)}$. Semelhante ao obtido no modelo espectral de análise univariada, a decomposição é representada por:

$$X_V = H_{V_1} + \dots + H_{V_D} \quad (3)$$

onde $H_{V_i} = \sqrt{\lambda_{V_i}} U_{V_i} V_{V_i}^T$ representa o bloco de matriz elementar, $V_{V_i} = X_V^T U_{V_i} / \sqrt{\lambda_{V_i}}$, o conjunto $\sqrt{\lambda_{V_i}}, U_{V_i}, V_{V_i}$ como autotripla e V_D , o posto do bloco da matriz que corresponde ao número de autovalores não nulos.

No estágio de reconstrução, o passo agrupamento para o modelo AESM corresponde em dividir os blocos de matrizes elementares H_{V_1}, \dots, H_{V_D} em grupos disjuntos somando-os dentro de cada grupo. Assim, o desdobramento do conjunto de índices $J = \{1, \dots, D\}$ em subconjuntos disjuntos I_1, \dots, I_M corresponde à representação:

$$X_V = H_{I_1} + \dots + H_{I_M} \quad (4)$$

onde H_{I_1}, \dots, H_{I_M} são definidos como bloco de matrizes resultantes (HASSANI; MAHMOUDVAND, 2013).

Assim, como um caso simples que apresenta as componentes sinal e ruído da série temporal, são usados dois grupos de índices, conforme $I_1 = \{1, \dots, a\}$ e $I_2 = \{a+1, \dots, D\}$, o primeiro grupo associado a componente sinal e o último ao ruído, com a um inteiro maior que 1.

A ferramenta que auxilia na separação das componentes é o gráfico w -correlação cumulativa. Sua metodologia considera na definição da w -correlação $C(f)$ valores cumulativos, conforme explicam Patterson et al., (2011). Com isso, a w -correlação $C(1)$ é definida com o primeiro conjunto autotripla como integrante da subsérie sinal $Y_{N_i}^{(s)}$ e os demais conjuntos de autotriplas para formação da subsérie ruído $Y_{N_i}^{(n)}$. A w -correlação $C(2)$ é definida com o primeiro e segundo conjuntos de autotriplas como integrantes da subsérie sinal $Y_{N_i}^{(s)}$ e os demais conjuntos para formação da subsérie ruído $Y_{N_i}^{(n)}$ e assim sucessivamente.

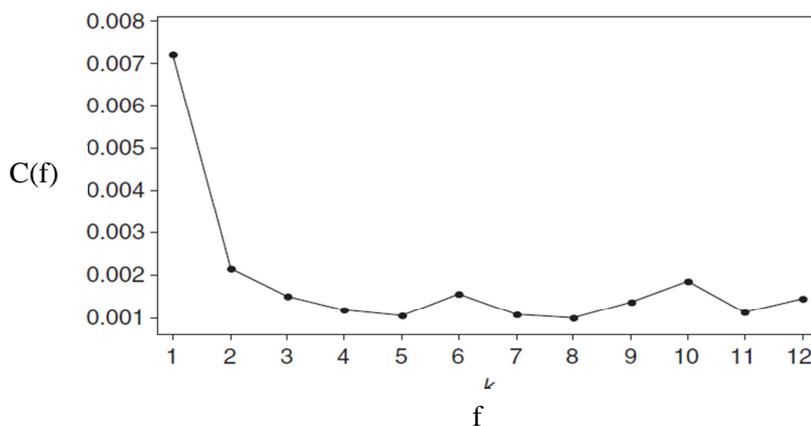


Figura 1 – Correlações cumulativas para as primeiras autotriplas

Essas w -correlações cumulativas são plotadas num gráfico, conforme Figura 1, adaptada de Patterson et. al., (2011). Logo, a existência da estrutura da série temporal está indicada por mínimos locais e máximos. Um padrão típico é um declínio para as w -correlações cumulativas, e isso correspondente a uma separação das componentes sinal e ruído. Percebe-se na Figura 1 que a subsérie sinal $Y_{N_i}^{(s)}$ será dada pelos conjuntos 1-5, e a subsérie ruído $Y_{N_i}^{(n)}$ pelos conjuntos 6-12, uma vez que $C(6)$ indica uma alteração deste declínio.

A previsão obtida a partir de um conjunto M de séries temporais é dada para h passos à frente (HASSANI; MAHMOUDVAND, 2013):

$$\left[\hat{y}_{j_1}^{(1)}, \dots, \hat{y}_{j_M}^{(M)} \right]^T = \begin{cases} \left[\tilde{y}_{j_1}^{(1)}, \dots, \tilde{y}_{j_M}^{(M)} \right] & j_i = 1, \dots, N_i \\ \left(I_{M \times M} - WW^T \right)^{-1} WU^{\nabla M^T} Z_h & j_i = N_i + 1, \dots, N_i + h \end{cases} \quad (5)$$

Com $U_j^{(i)\nabla}$ representando os primeiros $L_i - 1$ componentes do vetor $U_j^{(i)}$ e $\pi_j^{(i)}$ os últimos componentes do vetor $U_j^{(i)}$, com $(i = 1, \dots, M)$. A matriz $U_j^{\nabla(M)}$ é dada conforme:

$$U_j^{\nabla(M)} = \begin{bmatrix} U_j^{(1)\nabla} \\ \vdots \\ U_j^{(M)\nabla} \end{bmatrix} \quad (6)$$

e a matriz W representada por:

$$W = \begin{bmatrix} \pi_1^{(1)} & \pi_2^{(1)} & \dots & \pi_r^{(1)} \\ \pi_1^{(2)} & \pi_2^{(2)} & \dots & \pi_r^{(2)} \\ \vdots & \vdots & \dots & \vdots \\ \pi_1^{(M)} & \pi_2^{(M)} & \dots & \pi_r^{(M)} \end{bmatrix} \quad (7)$$

Além disso, $Z_h = [Z_h^{(1)}, \dots, Z_h^{(M)}]^T$ e $Z_h^{(i)} = [\hat{y}_{Ni-Li+h+1}^{(i)}, \dots, \hat{y}_{Ni+h-1}^{(i)}]$.

3.2 ALGORITMO SAZONAL HW

A incorporação da sazonalidade no algoritmo sazonal HW pode ser realizada por meio de dois enfoques distintos, dependentes do padrão de sazonalidade identificado na série: sazonalidade multiplicativa e aditiva. Ao considerar a sazonalidade multiplicativa, Morettin e Toloi (2006) explicam que série temporal pode ser definida por:

$$Y_t = N_t S_t + m_t + \varepsilon_t \quad (8)$$

com N_t o nível da série, S_t o fator sazonal, m_t o componente de tendência, ε_t o erro aleatório no instante t e $t = 1, \dots, N$.

A forma de recorrência para o enfoque multiplicativo, nesta pesquisa, é dado por HW_m , com o fator de sazonalidade multiplicativo representado pelas equações que envolvem as três constantes de suavização, α , β e γ , conforme:

$$\begin{cases} N_t = \alpha \frac{y_t}{S_{t-s}} + (1-\alpha)(N_{t-1} + m_{t-1}) \\ m_t = \beta(N_t - N_{t-1}) + (1-\beta)m_{t-1} \\ S_t = \gamma \frac{y_t}{N_t} + (1-\gamma)S_{t-s} \end{cases} \quad (9)$$

em que $0 < \alpha < 1$, $0 < \beta < 1$ e $0 < \gamma < 1$ são as condições das constantes de suavização do modelo, e s representa o número de observações.

As previsões para os valores futuros levam em conta os passos à frente h ; assim, em cada equação o fator sazonal considera o período correspondente, de acordo com as equações abaixo:

$$\begin{cases} \hat{Y}_t(h) = (N_t + hm_t)S_{t+h-s}; & h = 1, 2, 3, \dots, s \\ \hat{Y}_t(h) = (N_t + hm_t)S_{t+h-2s}; & h = s+1, s+2, s+3, \dots, 2s \\ \vdots \end{cases} \quad (10)$$

Para o enfoque sazonalidade multiplicativa a correção dos erros e_t é dada:

$$\begin{cases} N_t = N_{t-1} + m_{t-1} + \alpha \frac{e_t}{F_{t-s}} \\ m_t = m_{t-1} + \alpha\beta \frac{e_t}{F_{t-s}} \\ S_t = S_{t-s} + \gamma(1-\alpha) \frac{e_t}{N_t} \end{cases} \quad (11)$$

O outro enfoque do método, dado nesta pesquisa por HW_a , é aplicado quando a série apresenta sazonalidade aditiva. Assim, para Morettin e Toloi (2006), ao tomar por base o fator sazonal aditivo, a série temporal fica representada pela soma de todos os componentes conforme:

$$Y_t = N_t + m_t + S_t + \varepsilon_t \quad (12)$$

Na sazonalidade aditiva, a forma de recorrência é dada pelas equações:

$$\begin{cases} N_t = \alpha(Y_t - S_{t-s}) + (1-\alpha)(N_{t-1} + m_{t-1}) \\ m_t = \beta(N_t - N_{t-1}) + (1-\beta)m_{t-1} \\ S_t = \gamma(Y_t - N_t) + (1-\gamma)S_{t-s} \end{cases} \quad (13)$$

com as mesmas condições das constantes de suavização do modelo para o enfoque multiplicativo. Os valores futuros são previstos nas equações:

$$\begin{cases} \widehat{Y}_t(h) = (N_t + hm_t) + S_{t+h-s}; & h = 1, 2, 3, \dots, s \\ \widehat{Y}_t(h) = (N_t + hm_t) + S_{t+h-2s}; & h = s + 1, s + 2, s + 3, \dots, 2s \\ \vdots \end{cases} \quad (14)$$

O procedimento de correção dos erros para esse tipo de sazonalidade passa a ser dado por:

$$\begin{cases} N_t = N_{t-1} + m_{t-1} + \alpha e_t \\ m_t = m_{t-1} + \alpha \beta e_t \\ S_t = S_{t-s} + \gamma(1 - \alpha)e_t \end{cases} \quad (15)$$

3.3 MODELO SARIMA

Em algumas situações é importante considerar a sazonalidade estocástica para explicar o comportamento sazonal da série temporal. Desta maneira, a recomendação é que uma das variações do modelo ARIMA seja utilizada. Trata-se do modelo ARIMA sazonal multiplicativo ou modelo SARIMA. Para Box e Jenkins (1976), o modelo geral representado por ARIMA $(p, d, q) \times (P, D, Q)$ pode ser definido:

$$\phi(B)\Phi_p(B^s)[\Delta^d \Delta_s^D - \mu]Y_t = \theta(B)\Theta_Q(B^s)\varepsilon_t \quad (16)$$

com $\phi(B)$ o operador autorregressivo, Φ_p o polinômio estacionário autorregressivo sazonal de ordem P , Δ o operador diferença, μ o valor esperado da série, $\theta(B)$ o operador de médias móveis, Θ_Q o polinômio invertível de médias móveis sazonal de ordem Q e ε_t um erro aleatório.

O polinômio estacionário autorregressivo sazonal de ordem P é dado por:

$$\Phi_p(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{Ps} \quad (17)$$

O polinômio invertível de médias móveis sazonal de ordem Q é dado por:

$$\Theta_Q(B^s) = 1 - \theta_1 B^s - \theta_2 B^{2s} - \dots - \theta_Q B^{Qs} \quad (18)$$

com o operador diferença sazonal de ordem D representado por:

$$\Delta_s^D = (1 - B^s)^D Y_t \quad (19)$$

Em que, de modo geral, a primeira diferenciação sazonal $\Delta_s^D = (1 - B^s)^D Y_t = Y_t - Y_{t-s}$ consegue excluir a sazonalidade da série temporal (ESQUIVEL, 2012).

3.4 MODELO GARCH

A estimação de um modelo para representar uma série temporal e sua previsão pode ter tratamento diferenciado daquele dado em modelos clássicos para séries temporais, a exemplo do modelo ARMA, uma vez que eles não reproduzem fatos estilizados: não normalidade condicional / incondicional e variância não constante ao longo do tempo (MORETTIN; TOLOI, 2006).

Proposto por Bollerslev (1987) para modelagem da volatilidade, o modelo AR(p)-ARCH(q) pode ser representado através da equação $Y_t = \varepsilon_t \sqrt{h_t}$ considerando ε_t normal e identicamente distribuído. Assim, o modelo alternativo ao ARCH é o GARCH, no qual as dependências adicionais são permitidas em defasagem de variâncias condicionais.

O GARCH é uma generalização do modelo ARCH, no qual a variância condicional no instante t depende não somente de perturbações ao quadrado passadas, mas também de variâncias condicionais passadas (GUJARATI, 2005). Considerando o modelo GARCH(p,q), o primeiro termo p se refere à defasagem dos termos autorregressivos, e o segundo, ao número de defasagens no componente de média móvel.

Para o modelo, a dependência temporal da variância condicional é avaliada por um modelo ARMA (p,q) aplicado ao quadrado dos retornos. Com isso, as estimativas dos parâmetros do modelo que explicam a volatilidade condicional são realizadas com o uso de mecanismos econométricos tradicionais associados aos modelos da classe ARMA. Na pesquisa, conforme justificativas em Lima et al., 2010, será utilizado o modelo ARIMA-GARCH, por conta de o modelo ARIMA especificar a expressão para a variância condicionada e modelar movimentos persistentes na volatilidade de maneira parcimoniosa, e o modelo GARCH apresentar menor quantidade parâmetros que o modelo ARCH.

3.5 MODELO RNA

O modelo é adaptável às séries temporais e se diferencia dos modelos clássicos de previsão por ser um modelo não paramétrico e por envolver algoritmos de aprendizado (LIMA et al., 2010). De forma simplificada, uma rede neural é uma estrutura computacional baseada num processo biológico inspirado na arquitetura do cérebro humano. Para Pasquotto (2010), cada neurônio artificial funciona como uma unidade com autonomia cujo objetivo é converter um sinal de entrada em outro sinal de saída. Como os neurônios estão atuando em rede, a intensidade desses sinais é amplificada ou amortecida de acordo com os parâmetros que são atribuídos às sinapses, também definidos por pesos sinápticos ou apenas pesos.

3.5.1 O modelo de neurônio artificial

Os neurônios artificiais se agrupam em três tipos de camadas: a camada de entrada, a camada intermediária ou oculta e a camada de saída. Para Haykin (2001), os neurônios entre diferentes camadas são conectados por sinapses que, por sua vez, estão associadas a pesos ou importâncias relativas de cada neurônio de uma camada com o neurônio de uma camada subsequente. O modelo de neurônio artificial representado pela Figura 1 adaptada de Haykin (2001) é dado por diversos elementos.

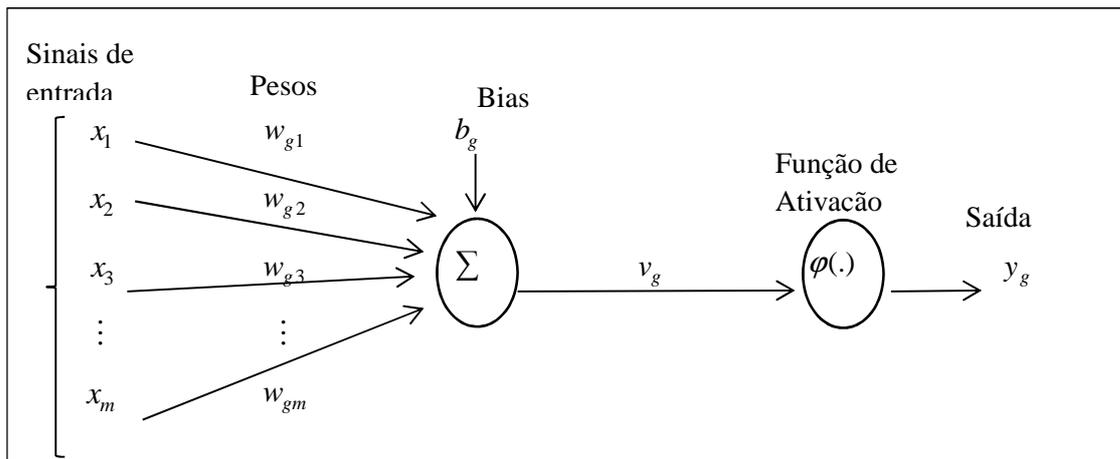


Figura 1 – Representação do neurônio artificial
Fonte: Haykin (2001)

Os elementos do neurônio artificial descritos na Figura 1 são representados por: m , que indica o número de sinais de entrada do neurônio; x_j o j -ésimo sinal de entrada do neurônio; w_{gj} o peso associado com o j -ésimo sinal de entrada no neurônio g ; b o limiar de cada neurônio também denominado de bias; v_g uma combinação ponderada de sinais de entrada e do bias do g -ésimo neurônio e $\varphi(.)$ como função de ativação do g -ésimo neurônio.

O bias apresenta o efeito de aumentar ou reduzir a entrada da função de ativação conforme seu sinal muda de positivo para negativo. Com um pequeno ajuste, Pasquotto (2010) explica que é possível realizar a substituição do bias b_g para uma entrada fixa $x_0 = 1$ de forma que o bias torna-se um novo peso sináptico $w_{g0} = b_g$.

Com isso, pode-se descrever matematicamente o neurônio g por:

$$v_g = \sum_{j=0}^m x_j w_{gj} \quad (20)$$

e

$$y_g = \varphi(v_g(t)) \quad (21)$$

com v_g definido como campo local induzido ou potencial de ativação e a função de ativação definindo a saída $y_g(t)$ do g -ésimo neurônio no instante t .

Dentre as funções mais utilizadas na literatura, Pasquotto (2010) cita: i) função de limiar, que é uma função descontínua e binária; ii) função sigmoide, que é uma função contínua em forma de S, variando de 0 a 1 e iii) função tangente hiperbólica, que é uma função contínua e derivável em todos os seus pontos.

3.5.2 Arquitetura das redes neurais

A arquitetura para o modelo RNA sofre mudanças de acordo com sua finalidade. A maneira como os neurônios estão distribuídos em rede está relacionada com o algoritmo de aprendizagem utilizado. A classificação dada na literatura considera a maneira como o processamento ocorre na rede neural bem como os neurônios estão dispostos em camadas. Para Haykin (2001), as classificações camada única, multicamadas, alimentadas à frente e recorrentes constituem maneiras de apresentar a arquitetura da rede neural.

Para a arquitetura camada única, os neurônios são dispostos em paralelo em uma camada única. Nas entradas desse tipo de rede existem nós que não são neurônios, não existindo computação do sinal, de forma que o processamento tem prosseguimento apenas numa camada de onde emergem as saídas da rede. Na arquitetura multicamadas existem camadas posicionadas entre os nós de entrada e a camada responsável por gerar as saídas da rede. As camadas escondidas, também definidas como camadas ocultas ou intermediárias, propagam os sinais até que cheguem à saída da rede neural. A arquitetura de rede alimentada à frente tem o processamento num único sentido, ou seja, da entrada até a saída, com a ausência de realimentação. Por fim, no tipo recorrente há pelo menos um laço de realimentação. Com isso, a saída de pelo menos um dos neurônios é reintroduzida em algum ponto anterior da rede, configurando recorrência de processamento. Quando a realimentação ocorre no próprio neurônio que a originou, esse tipo de operação é definido como autorrealimentação (HAYKIN, 2001).

3.5.3 Tipos de treinamento

O treinamento para RNA consiste em ajustar os parâmetros da rede de maneira interativa, requerendo uma sequência de eventos, conforme: i) estímulo da rede neural pelo ambiente; ii) modificações em seus pesos por conta dos estímulos dados e iii) resposta da rede

de uma forma diferente ao ambiente em razão das modificações. Para as redes neurais, existem dois padrões de aprendizado (PASQUOTTO, 2010).

3.5.3.1 Aprendizado supervisionado

Este tipo de aprendizado funciona indicando na saída da rede a resposta correta para cada situação. Existe um conjunto de dados de entrada apresentados à rede neural como exemplos que geram uma saída de rede que é comparada com a saída esperada, obtendo-se desta forma o erro correspondente.

Considerando o neurônio g na saída de uma rede no instante t , o erro correspondente e_g será definido por:

$$e_g = d_g(t) - y_g(t) \quad (22)$$

com $d_g(t)$ como sinal de resposta desejada do neurônio g no instante t e $y_g(t)$ como sinal de saída do neurônio g no instante t . O erro é usado como parâmetro iterativo de ajuste de pesos cuja intenção é reduzir progressivamente o erro até um valor mínimo aceitável. O algoritmo de retropropagação é muito utilizado para o aprendizado supervisionado (LIMA et al., 2010).

3.5.3.1.1 Algoritmo básico de retropropagação

O algoritmo de retropropagação percorre a função de erro na saída da rede em busca de um ponto mínimo. Os pesos sinápticos podem ficar alterados após serem percorridas duas etapas: i) propagação à frente e ii) retropropagação. Na primeira etapa, o sinal é propagado ao longo da rede, iniciando pela primeira camada até gerar o erro na última camada. Na segunda etapa, o erro é corrigido camada a camada, alterando os pesos no sentido inverso.

No algoritmo de retropropagação, os pares de entrada-saída são apresentados, cada uma deles para a rede neural, existindo duas maneiras de se aplicar a correção dos erros. Na primeira, definida como alteração incremental, a alteração nos pesos é realizada sempre que um novo par entrada-saída é apresentado à rede gerando um erro que é corrigido individualmente logo após cada par ser submetido à rede.

Ao contrário da primeira maneira, na alteração por lote, todos os n pares são apresentados à rede neural, gerando-se um erro correspondente a todo lote e, só depois disso, é realizada a atualização dos pesos, podendo envolver a apresentação repetitiva do mesmo conjunto de pares por muitas vezes.

3.5.3.2 Aprendizado não supervisionado

Tem como característica a ausência na saída da rede neural de uma resposta correta. Ou seja, como não existem vetores de respostas desejadas, não existem comparações para fornecer erros. Nesta situação de aprendizado, são fornecidas à rede neural condições para realização de uma medida independentemente da tarefa que deve ser aprendida, e os parâmetros livres da rede são otimizados em relação a essa medida. Para esse tipo de aprendizado, Haykin (2001) explica que existem duas maneiras de conduzi-lo: por reforço e de forma auto-organizada.

3.6 AVALIAÇÃO DO DESEMPENHO DAS PREVISÕES

Após a aplicação dos modelos AESM, SARIMA, ARIMA-GARCH e RNA, além do algoritmo sazonal HW, é necessário avaliar o desempenho das previsões obtidas. Como as previsões podem apresentar erros, independente do modelo adotado, costuma-se avaliar o resultado das previsões ao comparar os valores obtidos com os da série temporal original e determinar o seu desempenho por meio de alguma medida. Então, na pesquisa, as previsões serão confrontadas com 12 semanas subsequentes à semana final da amostra. Para isso, a avaliação de desempenho faz uso da medida EQM definida por:

$$EQM = \frac{1}{h} \sum_{N+1}^{N+h} (Y_j - \hat{Y}_j)^2 \quad (23)$$

com Y_j representando o valor da série original, \hat{Y}_j o valor da previsão e h , a quantidade de observações previstas e reservadas para avaliação. Além dessa medida, a pesquisa faz uso da metodologia proposta por Goyal e Welch (2003), dada pela diferença entre os erros de previsão ao quadrado acumulados do modelo de melhor desempenho e os erros de previsão ao quadrado acumulados do modelo de melhor desempenho subsequente, considerando o EQA dado por:

$$EQA = \sum_{N+1}^{N+h} (Y_j - \hat{Y}_j)^2 \quad (24)$$

Sempre que essa diferença for positiva, o modelo de melhor desempenho subsequente supera o de melhor desempenho.

Considerando duas previsões de uma série temporal Y_t , e definindo e_{it} e e_{jt} como os respectivos erros de previsão, uma análise das perdas associadas a cada uma dessas previsões pode ser feita através do teste DM, que faz uso de uma função perda para medir o erro de previsão, ou seja, a perda é calculada a partir de valores realizados e previstos da variável em

questão. Com isso, o teste verifica se a perda diferencial não é significativa entre duas previsões realizadas.

4 RESULTADOS E DISCUSSÕES

4.1 TESTES ESTATÍSTICOS APLICADOS SOBRE OS DADOS

A escolha das commodities etanol, boi gordo, milho, café e soja é motivada pelo crescimento dos volumes de exportações nos últimos 5 anos, segundo dados disponibilizados pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) e pelo papel significativo na pauta das exportações brasileiras. Em 2013, do total de exportações, 42% corresponderam aos produtos do agronegócio e, consoante relatórios do MAPA, desse total, essas commodities juntas representaram mais de 70% do volume exportado. Além disso, todas elas apresentam contratos negociados na Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&FBOVESPA).

As séries temporais são identificadas na pesquisa conforme: ETAN (etanol), BOIG (boi gordo), MILH (milho), CAFE (café) e SOJA (soja). Os preços foram obtidos no banco de dados da Escola Superior de Agricultura Luiz de Queiroz (ESALQ) e correspondem ao período de 14 de novembro de 2008 a 20 de dezembro de 2013, cuja periodicidade é semanal.

Para testar se a amostra de dados tem origem de uma população com uma distribuição específica, os testes AD e SW são aplicados. Na pesquisa, os dois testes permitem uma visão abrangente dos resultados. Como pode ser visto, com base nos resultados dispostos na Tabela 1, para um nível de 5% de significância, as séries temporais não estão distribuídas normalmente.

Tabela 1 – Teste de Normalidade AD, SW e *p*-valor

	ETAN	BOIG	MILH	CAFE	SOJA
Número de Observações	267	267	267	267	267
Shapiro-Wilk	0.96	0.94	0.91	0.92	0.95
<i>p</i> -valor	0.00	0.00	0.00	0.03	0.00
Anderson-Darling	1.05	2.02	2.95	0.83	1.87
<i>p</i> -valor	0.00	0.00	0.00	0.03	0.00

Fonte: Elaborado pelos autores

Em seguida, para avaliar o aspecto da normalidade do conjunto de dados, fez-se o uso do teste DHO, que é um teste de normalidade multivariada aplicado entre pares formados pelas séries temporais. Os resultados apresentados na Tabela 2 indicam que há fortes evidências de normalidade multivariada para um nível de 5% de significância entre o par

BOIG/CAFE. As exceções ocorrem para os demais pares. Na pesquisa, seu uso justifica-se para conhecimento das características das séries temporais analisadas porque o modelo AESM não pressupõe a hipótese de normalidade dos dados.

Tabela 2 – Teste de Normalidade Multivariada DHO e p -valor

	ETAN	BOIG	MILH	CAFÉ	SOJA
ETAN		19.06	34.27	22.02	19.49
p -valor		0,00	0.00	0.00	0.00
BOIG			27.67	8.35	16.38
p -valor			0.00	0.07	0.00
MILH				25.71	24.04
p -valor				0.00	0.00
CAFE					10.99
p -valor					0.03

Fonte: Elaborado pelos autores

Os testes de não linearidade de Tsay e de McLeod Li também são aplicados nas séries temporais. Para o primeiro teste, antes de sua aplicação, os dados são filtrados por um modelo AR. A Tabela 3 apresenta os resultados para os dados da amostra com base no critério de seleção *Akaike Information Criterion* (AIC) para determinar a ordem do modelo em Tsay e, em *lags* de 5 e 10 semanas, para McLeod e Li. Assim, para um nível de 5% de significância, as séries temporais podem ser consideradas lineares.

Tabela 3 – p -valor para Testes Tsay e McLeod do Primeiro Conjunto de Séries Reais

	<i>order</i>	ETAN	BOIG	MILH	CAFE	SOJA
	<i>lags</i>					
Número de Observações		267	267	267	267	267
Tsay	2					
p -valor		0.27	0.12	0.91	0.71	0.59
McLeod	5					
p -valor		0.84	0.32	0.17	0.35	0.71
McLeod	10					
p -valor		0.89	0.28	0.31	0.81	0.91

Fonte: Elaborado pelos autores

Por fim, foram realizados os testes DFA e KPSS para avaliar a estacionariedade das séries temporais. A Tabela 4 apresenta os resultados dos dois testes. Para o primeiro teste, a hipótese nula é que a série possui raiz unitária e, portanto, não é estacionária. Em relação ao segundo teste, a hipótese nula é que não possui raiz unitária e, portanto, é estacionária. Os

dois testes confirmam que as séries temporais não são estacionárias. Em resumo, as séries temporais utilizadas na pesquisa não estão distribuídas normalmente, não são estacionárias, são lineares além de não apresentarem, de forma geral, normalidade multivariada.

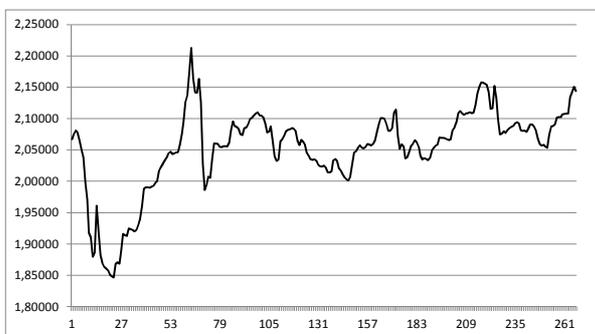
Tabela 4 – Teste DFA e KPSS para Série Simulada e Conjuntos de Séries Reais

Séries temporais	DFA	Valor	
		Crítico 5%	KPSS
ETAN	-2,81	-3,43	0,22
BOIG	-2,73	-3,43	0,23
MILH	-2,81	-3,43	0,25
CAFÉ	-2,90	-3,43	0,26
SOJA	-2,81	-3,43	0,27

Fonte: Elaborado pelos autores

Além dos testes estatísticos, que indicam características das séries temporais das commodities agropecuárias, também é possível identificar a não estacionariedade na Figura 2, que apresenta o comportamento das séries temporais no período de novembro de 2008 a dezembro de 2013, representado pelas 267 semanas.

(a) Séries temporais ETAN e BOIG



semana



semana

(b) Séries temporais MILHO e CAFE



semana



semana

(c) Série temporal SOJA



Figura 2 – Comportamento semanal dos preços das commodities agropecuárias
 Fonte: Elaborado pelos autores

4.2 APLICAÇÕES EMPÍRICAS

Para definição dos resultados, no modelo AESM foi utilizado como comprimento da janela 16 semanas uma vez que esse valor define o tamanho ótimo de janela. Os modelos HWa e HWm têm a escolha dos valores de parâmetros de alisamento definidos com base na minimização da soma dos quadrados dos erros de previsão um passo à frente, valores estes definidos no pacote do programa estatístico R, para posterior aplicação da rotina de previsão. Em relação ao modelo SARIMA, as ordens foram dadas com base no critério de minimização dos valores para AIC. Para o modelo ARIMA-GARCH, faz-se necessário ajustar inicialmente o modelo ARIMA, com base no mesmo critério. O procedimento também é realizado em rotina própria do programa R. Após verificar que os resíduos não apresentam estrutura de autocorrelação, é feita a modelagem da volatilidade condicional e da previsão para as séries temporais. Por fim, o modelo RNA, definido no mesmo programa, é estruturado com 1 camada composta de 7 neurônios, admitindo número máximo de iterações igual a 100.000 com aprendizado supervisionado e aplicação do algoritmo de retropropagação. Como proposta de previsão, o modelo RNA aplicado na pesquisa faz uso do passeio aleatório.

Além dos parâmetros utilizados pelos modelos AESM, SARIMA e ARIMA-GARCH, observa-se na Tabela 5, conforme o trabalho de Esquivel (2012), que quando os passos à frente h aumentam, de modo geral, os desempenhos das previsões, avaliados pela medida de erro EQM, não apresentam bons resultados. Na mesma tabela, percebe-se não existir diferenças significativas para as previsões realizadas entre o algoritmo HW com sazonalidade aditiva e multiplicativa. As previsões obtidas pelo modelo AESM, quando comparadas com aquelas obtidas pelo algoritmo sazonal HWa e HWm dos modelos SARIMA, ARIMA-GARCH e RNA, correspondem ao melhor desempenho (MD na Tabela 5), por conta dos

menores valores para a medida de erro descrita em (23). As exceções para isso são dadas nos passos à frente h (6, 9 e 12 semanas) na série temporal CAFE.

Tabela 5 – Desempenho de Previsão pelo EQM

Série	L	Paramêtros	EQM					ARIMA GARCH		
		(p,d,q)(P,D,Q)	h	AESM	HWa	HWm	SARIMA	RNA	MD	
ETAN	16	(1,1,0)(1,0,0)								
		(1,1,0)(1,1)	3	1.4E-05	3.0E-04	3.1E-04	3.2E-04	3.3E-04	3.8E-04	AESM
			6	9.9E-05	2.2E-04	2.2E-04	8.1E-04	7.1E-04	8.5E-04	AESM
			9	9.0E-05	4.3E-04	4.4E-04	1.2E-03	3.2E-03	8.2E-04	AESM
			12	1.3E-04	1.2E-03	1.2E-03	1.2E-03	4.5E-03	7.1E-03	AESM
BOIG	16	(1,1,0)(1,0,0)								
		(1,1,0)(1,1)	3	3.5E-05	2.5E-02	2.4E-02	2.7E-02	6.7E-02	2.9E-02	AESM
			6	1.1E-04	3.1E-02	3.0E-02	3.5E-02	5.5E-02	3.8E-02	AESM
			9	9.7E-05	3.3E-02	3.0E-02	3.8E-02	4.9E-02	4.3E-02	AESM
			12	1.3E-04	3.3E-02	3.1E-02	3.9E-02	6.7E-02	3.3E-02	AESM
MILH	16	(2,1,0)(1,0,0)								
		(2,1,0)(1,1)	3	3.6E-05	8.4E-04	8.1E-04	7.6E-04	8.9E-04	9.6E-04	AESM
			6	8.5E-05	1.7E-03	1.6E-03	1.3E-04	5.5E-04	8.3E-04	AESM
			9	8.2E-05	9.6E-03	3.8E-03	2.2E-04	4.2E-04	4.2E-04	AESM
			12	9.9E-04	3.8E-03	4.0E-03	1.8E-03	9.3E-03	8.9E-03	AESM
CAFE	16	(0,1,0)(1,0,0)								
		(0,1,0)(1,1)	3	1.4E-04	1.9E-04	2.1E-04	4.8E-04	6.8E-04	5.1E-04	AESM
			6	6.1E-04	2.4E-04	2.5E-04	2.0E-04	3.1E-04	7.0E-04	SARIMA
			9	4.4E-03	4.1E-03	4.2E-03	1.8E-03	5.7E-03	8.8E-03	SARIMA
			12	1.4E-02	1.4E-02	1.5E-02	7.9E-03	8.7E-03	9.3E-02	SARIMA
SOJA	16	(0,1,0)(1,0,0)								
		(1,1,0)(1,1)	3	7.2E-05	1.6E-04	1.7E-04	8.7E-04	8.8E-04	7.2E-04	AESM
			6	4.8E-04	1.7E-03	1.8E-03	3.8E-03	3.9E-03	3.9E-03	AESM
			9	5.1E-04	1.9E-03	2.1E-03	5.1E-03	5.9E-03	5.7E-03	AESM
			12	4.0E-04	1.6E-03	1.8E-03	4.9E-03	6.1E-03	6.9E-03	AESM

Fonte: Elaborado pelos autores

Tabela 6 – Desempenho de Previsão pela Diferença do EQA

Série	h	EQA		
		AESM	HWa	Diferença
ETAN	3	4.2E-05	9.0E-04	-8.6E-04
	6	5.9E-04	1.3E-03	-7.1E-04
	9	8.1E-04	3.9E-03	-3.1E-03
	12	1.5E-03	1.4E-02	-1.3E-02
		AESM	HWm	Diferença
BOIG	3	1.0E-04	7.4E-01	-7.4E-01
	6	6.6E-04	1.9E-00	-1.9E-00
	9	8.8E-04	2.9E-00	-2.9E-00

	12	1.6E-03	3.9E-00	-3.9E-00
		AESM	SARIMA	Diferença
MILH				
	3	1.1E-04	2.6E-03	-2.5E-03
	6	5.1E-04	7.7E-03	-7.2E-03
	9	7.3E-04	1.9E-02	-1.9E-02
	12	1.0E-02	2.2E-02	-1.0E-02
		SARIMA	HWa	Diferença
CAFE				
	6	1.2E-03	1.5E-03	-2.6E-04
	9	1.6E-02	3.7E-02	-2.1E-02
	12	9.4E-02	1.7E-01	-7.3E-02
		AESM	HWa	Diferença
SOJA				
	3	2.2E-04	4.7E-04	-2.5E-04
	6	2.9E-03	1.0E-02	-7.0E-03
	9	4.6E-03	1.7E-02	-1.3E-02
	12	4.8E-03	1.9E-02	-1.4E-02

Fonte: Elaborado pelos autores

Em seguida, com o objetivo de avaliar se a diferença entre os EQMs do modelo de melhor desempenho preditivo com o modelo de melhor desempenho subsequente é estatisticamente significativa, aplicou-se o teste DM. Os resultados expostos na Tabela 7 indicam que, para os modelos comparados, a hipótese nula de que a diferença entre as medidas de erro é zero pode ser rejeitada para as séries temporais ETAN, BOIG, MILH e SOJA. Em relação à série CAFE, a hipótese nula de que a diferença entre as medidas de erro é zero não pode ser rejeitada, não existindo superioridade dos modelos de melhor desempenho de previsão.

Tabela 7 – Teste Diebold-Mariano e Modelos Comparados

Série	h	D-M	p-value	Modelos
ETAN				
	3	8.68	0.00	AESM, HWa
	6	8.44	0.00	AESM, HWa
	9	6.37	0.00	AESM, HWa
	12	5.07	0.00	AESM, HWa
BOIG				
	3	4.07	0.00	AESM, HWm
	6	5.14	0.00	AESM, HWm
	9	8.21	0.00	AESM, HWm
	12	11.24	0.00	AESM, HWm
MILH				
	3	5.20	0.00	AESM, SARIMA
	6	8.13	0.00	AESM, SARIMA

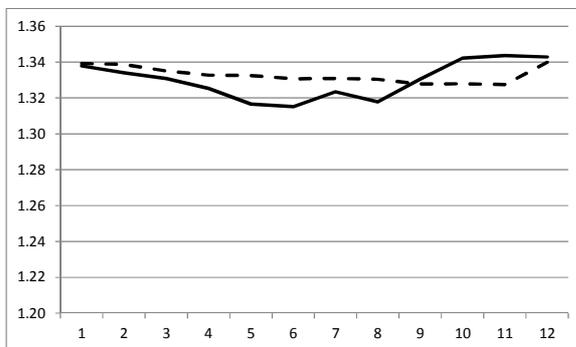
	9	7.80	0.00	AESM, SARIMA
	12	6.34	0.00	AESM, SARIMA
<hr/>				
CAFE				
	3	1.15	0.36	AESM, HWa
	6	1.22	0.82	SARIMA, HWa
	9	1.85	0.10	SARIMA, HWa
	12	2.72	0.03	SARIMA, HWa
<hr/>				
SOJA				
	3	8.89	0.00	AESM, HWa
	6	4.53	0.00	AESM, HWa
	9	4.08	0.00	AESM, HWa
	12	4.75	0.00	AESM, HWa

Fonte: Elaborado pelos autores

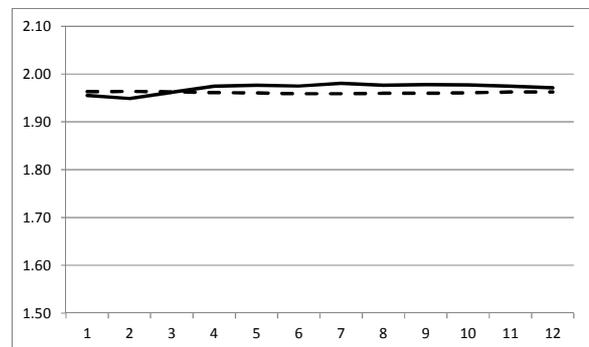
Pode-se concluir, com base no teste estatístico DM, através do desempenho das previsões realizadas para os passos à frente h (3, 6, 9 e 12 semanas), que o modelo AESM agrega evidências favoráveis quando aplicado na previsão dos preços das commodities investigadas.

Na Figura 3 são apresentados, por meio dos gráficos dos preços das commodities no período semanal, os comportamentos das séries temporais originais (linhas sólidas) e séries temporais previstas (linhas tracejadas) obtidos com o modelo AESM, uma vez que ele apresentou os melhores desempenhos. Os gráficos foram elaborados no período de 27 de dezembro de 2013 a 14 de março de 2014, fora da amostra. Observa-se que o modelo AESM, no período, conseguiu detectar a tendência dos preços das commodities, com exceção para a série temporal CAFE.

(a) Série temporal ETAN e BOIG

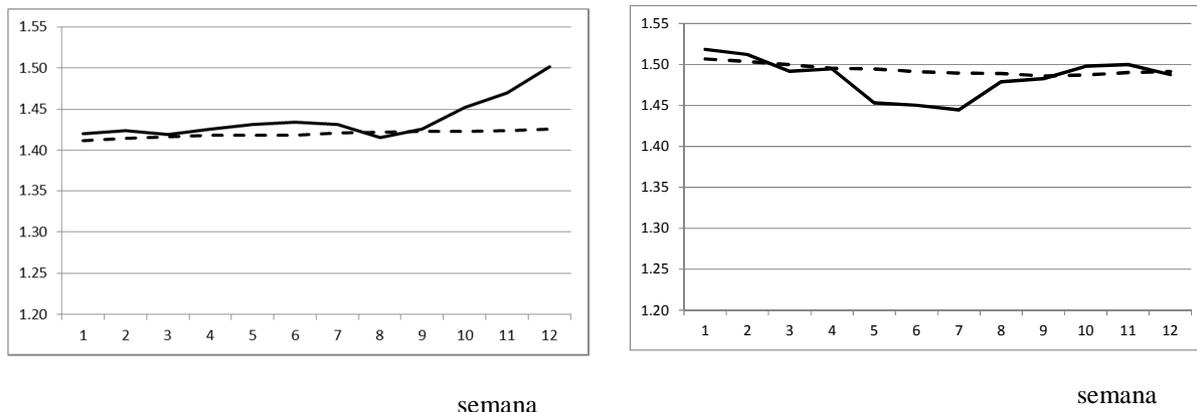


semana



semana

(b) Série temporal CAFÉ e SOJA



(c) Série temporal MILH

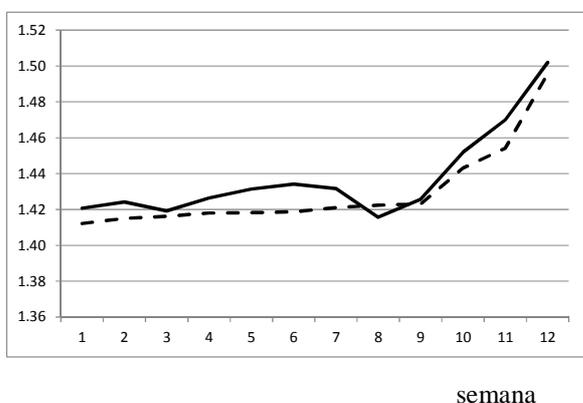


Figura 3 – Preços das commodities de 27 de dezembro de 2013 a 14 de março de 2014

Fonte: Elaborada pelos autores

5 CONCLUSÕES E SUGESTÕES

A análise dos preços das commodities agropecuárias reveste-se de singular importância para os participantes do mercado por conta da relevância das informações sobre o comportamento dos preços. Acontece que pesquisas realizadas sobre previsão de preços de commodities são dadas pelo comportamento dos preços a partir da utilização de dados referentes apenas à commodity em estudo.

Como a dinâmica das séries temporais de commodities agropecuárias apresenta mudanças no tempo, é preciso ter certeza de que o modelo de previsão não seja sensível a essas mudanças. A motivação pela utilização do modelo AESM na pesquisa dá-se por causa da sua capacidade de capturar estruturas que representem o comportamento mais abrangente levando em consideração os efeitos do conjunto de séries temporais.

Nas pesquisas realizadas por Lima et al. (2010) e Ceretta, Righi e Schlender (2010) a fim de investigar o comportamento dos preços da soja — a primeira com base no modelo ARIMA-GARCH / RNA, e a segunda ao comparar o modelo ARIMA com RNA —, para os

autores, os resultados de previsão foram favoráveis aos modelos ARIMA-GARCH e RNA. Diferente das pesquisas, os resultados obtidos indicam superioridade preditiva do modelo AESM.

Para as commodities soja, boi gordo e milho, o trabalho de Ferreira et al. (2011) evidencia a possibilidade do uso das redes neurais como uma estratégia de precificação por conta dos resultados favoráveis. Ainda em relação a essas commodities, o trabalho desenvolvido por Lima, Góis e Ulises (2007) indica que o modelo autorregressivo integrado demonstrou melhor poder de previsão. Esses resultados não são confirmados na pesquisa uma vez que para as mesmas commodities o desempenho preditivo indica superioridade do modelo AESM em relação aos modelos autorregressivo e de redes neurais.

Na avaliação das previsões para a commodity café, Miranda, Coronel e Vieira (2013) concluíram que o modelo RNA, quando comparado com o modelo ARMA, demonstrou-se eficaz na previsão do preço do café, uma vez que os preços previstos foram próximos aos observados. Para a commodity café, os resultados de desempenho preditivo foram favoráveis ao modelo de suavização exponencial.

Portanto, no contexto da pesquisa e, com exceção para o café, os resultados empíricos demonstram superioridade do modelo AESM, quando comparado com os modelos HWa, HWm, SARIMA, ARIMA-GARCH e RNA, ao permitir um maior número de melhores desempenhos das previsões. Os resultados obtidos no período fora da amostra, mediante o uso das medidas de erro EQM e EQA, além do teste MD para os passos à frente h (3, 6, 9 e 12 semanas), confirmam isso.

De modo geral, o modelo AESM superou, em termos de perdas estatísticas, o modelo que apresentou o melhor desempenho subsequente. Assim, a pesquisa, ao utilizar AESM, realizou contribuições aos profissionais do mercado agropecuário por agregar evidências favoráveis ao seu uso. Do ponto de vista prático, os resultados obtidos podem auxiliar na formulação e na aplicação de políticas direcionadas ao setor agropecuário, por conta da relevância da previsão dos preços como instrumento de planejamento e de análise do comportamento da tendência dos preços das commodities.

Para próximas pesquisas, sugere-se a utilização de outras bases de dados, a exemplo de preços dos mercados internacionais, a inclusão de outras commodities, a adoção de outros períodos de análise, além do uso de outras variáveis que possam aumentar o poder explicativo do modelo AESM dado seu caráter multivariado.

CONTRIBUIÇÕES DOS AUTORES

O artigo faz parte do trabalho de pesquisa elaborado por Carlos Alberto Orge Pinheiro, no Curso de Doutorado em Modelagem Computacional e Tecnologia Industrial da Faculdade de Tecnologia Senai Cimatec. Este autor foi responsável pela coleta de dados, aplicação dos testes estatísticos e elaboração da redação. Já o segundo autor, professor Valter de Senna, ficou responsável pela orientação em todas as etapas da pesquisa e na análise dos resultados obtidos.

REFERÊNCIAS

- AGUIAR, S. C. G. E.; BORESTEIN, D. Redes bayesianas: uma ferramenta na previsão de preço de commodity. **Revista de Administração e Negócios da Amazônia**, v. 4, p. 237-253. 2012.
- ARÊDES, A. F.; PEREIRA, M. W. G. Potencialidade da utilização de modelos de séries temporais na previsão do preço do trigo no estado do Paraná. **Revista de Economia Agrícola**, v.55, p. 63-76, 2008.
- BOLLERSLEV, T. A conditional heterokedasticity time series model for speculative process and rates of return. **Review of Economics and Statistics**, v.69, p.542-547, 1987.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control**. San Francisco: Holden Day, 1976.
- BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **Revista de Administração Eletrônica**, v.3, p. 1-20, 2004.
- BROCKWELL, P. J.; DAVIS R. A. **Introduction to time series and forecasting**, 2. ed. New York: Springer, 2002.
- CAMPOS, K. C. Análise da volatilidade de preços de produtos agropecuários no Brasil. **Revista de Economia e Agronegócio**, v. 5, p. 303-328, 2007.
- 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**, v. 40, p.15-27, 2010.
- DIEBOLD, F.; MARIANO, R. Comparing Predictive Accuracy. **Journal of Business and Economic Statistics**, v. 13, p. 253-265, 1995.
- ENGLE, R. Autoregressive conditional heterokedasticity with estimates of the variances of U.K. inflation. **Econometrica**, v.50,p.987-1008, 1982.
- ESQUIVEL, R. M. **Análise espectral singular**: modelagens de séries temporais através de estudos comparativos usando diferentes estratégias de previsão. 2012. 161f. Dissertação (Mestrado em Modelagem Computacional e Tecnologia Industrial) – Faculdade de Tecnologia SenaiCimatec, Salvador (BA), 2012.

FERREIRA, L. et al. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **Revista de Administração e Inovação**, v. 8, p. 6-26, 2011.

GUJARATI, D.N. **Econometria básica**. São Paulo: Pearson Education do Brasil, 2005.

GOYAL, A.; WELCH, I. Predicting the equity premium with dividend ratios. **Management Science**, v. 49, p. 639–654, 2003.

HASSANI, H. Singular spectrum analysis: methodology and comparison. **Journal of Data Science**, v. 5, p. 239-257, 2007.

HASSANI, H.; HERAVI, S.; ZHIGLJAVSKY, A. Forecasting European industrial production with singular spectrum analysis. **International Journal of Forecasting**, v. 25, p. 103-118, 2009.

HASSANI, H.; MAHMOUDVAND, R. 2013. Multivariate singular spectrum analysis: a general view and new vector forecasting approach. **International Journal of Energy and Statistics**, v. 1, p. 55-83, 2013.

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

KEPPENNE, C.; GHIL, M. Adaptive filtering and prediction of noisy multivariate signals: An application to subannual variability in atmospheric angular momentum. **International Journal of Bifurcation and Chaos**, v. 3, p. 625-634, 1993.

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**, v. 45, p. 621-644, 2007.

LIMA, F. G. et al. Previsão de preços de commodities com modelos ARIMA-GARCH e redes neurais com ondaletas: velhas tecnologias: novos resultados. **Revista de Administração**, v. 45, p. 188-202, 2010.

MARQUES, J.; ANTUNES, S. A perigosidade natural da temperatura do ar em Portugal continental: a avaliação do risco na mortalidade. **Territorium 16**, p. 49-61, 2009.

MCLEOD, A. I.; LI, W. K. Diagnostic checking ARMA time series models using squared residual autocorrelations. **Journal of Time Series Analysis**, v. 4, p. 169-176, 1983.

MENEZES, M. L. et al. Modelagem e previsão de demanda de energia com filtragem SSA. **Revista de Estatística UFOP**, v. 3, p. 170-187, 2014.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. Projeções do agronegócio 2013/14 a 2025/25. Assessoria de Gestão Estratégica. Brasília. 2013.

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**, v. 38, p. 66-98, 2013.

MORETTIN, P.A.; TOLOI, C.M.C. **Análise de séries temporais**. São Paulo: Blücher, 2006.

OLIVEIRA, V. A.; AGUIAR, D.R. Determinantes do desempenho dos contratos futuros de commodities agropecuários no Brasil. In: CONGRESSO INTERNACIONAL DE ECONOMIA E GESTÃO DE REDES AGROALIMENTARES, 2003, Ribeirão Preto (SP). **Anais...** São Paulo: Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto, 2003.

ORANJE, M. **Competitividade das frutas brasileiras no comércio internacional**. 2003. 114f. Dissertação (Mestrado em Economia Aplicada) – Universidade Federal de Viçosa, Viçosa, (MG), 2003.

PASQUOTTO, J. L. D. **Previsão de séries temporais no varejo brasileiro: uma investigação comparativa da aplicação de redes neurais recorrentes de Elman**. 2010. 191f. Dissertação (Mestrado em Administração) – Faculdade de Economia, Administração e Contabilidade de São Paulo, Universidade de São Paulo, São Paulo (SP), 2010.

PATTERSON, K. et al. Multivariate singular spectrum analysis for forecasting revisions to real-time data. **Journal of Applied Statistics**, v. 38, p. 2183-2211, 2011.

PLAUT, G.; VAUTARD, R. Spells of low-frequency oscillations and weather regimes in the Northern Hemisphere. **Journal of the Atmospheric Sciences**, v. 51, p. 210-236, 1994.

RIBEIRO, C. O.; SOSNOSKI, A. A. K.; OLIVEIRA, S. M. Um modelo hierárquico para previsão de preços de commodities agrícolas. **Revista Produção On-line**, v. 10, p. 719-733, 2010.

SCHWAGER, J. D. **Fundamental analysis**. New York: John Wiley & Sons, 1995.

SOBREIRO, V. A. et al. Uma estimação do valor da commodity de açúcar usando redes neurais artificiais. **Revista P&D em Engenharia de Produção**, p. 36-53, 2008.

TIBULO, C.; CARLI, V. Previsão do preço do milho através de séries temporais. **Scientia Plena**, v. 10, p. 2-10, 2014.

TSAY, R. 1986. Non-linearity tests for time series. **Biometrika**, v. 73, p. 461-466, 1986.

TURBAN, E. **Decision support and expert systems: management support systems**. New York: MacMillan, 1993.

VITYAZEVA, V., MILLER, N.; PRUDNIKOVA, E. J. Singular spectrum analysis in astrometry and geodynamics. **AIP Conference Proceedings**, v. 1283, p. 317-326, 2010.