

Previsão da produção industrial por meio da análise espectral multivariada

Forecast of industrial production through Multivariate Singular Spectrum Analysis

Carlos Alberto Orge Pinheiro

Administrador de Empresas pela Universidade Salvador, Doutorando pelo Programa de Pós-Graduação em Modelagem Computacional e Tecnologia Industrial da Faculdade de Tecnologia Senai Cimatec, Professor do Departamento de Ciências Humanas da Universidade do Estado da Bahia – Uneb. Salvador, BA [Brasil] carlos.orge@terra.com.br

Valter de Senna

Graduado em Matemática pela Universidade Federal do Rio de Janeiro, Professor do Programa de Pós-Graduação em Modelagem Computacional e Tecnologia Industrial da Faculdade de Tecnologia Senai Cimatec. Salvador, BA [Brasil]

Resumo

Neste estudo, aplicou-se o modelo espectral de análise multivariada ao conjunto de séries temporais da produção de diferentes segmentos da indústria de transformação, no Brasil, considerando-se a capacidade desse modelo em capturar estruturas que representem o comportamento abrangente da série temporal em estudo. A escolha dos segmentos industriais deu-se por conta do destaque de cada um deles no total produzido no ano de 2013. O modelo espectral de análise multivariada demonstrou-se adequado, quando comparado com dois modelos clássicos que levam em consideração a sazonalidade, ao permitir um maior número de melhores desempenhos das previsões dos preços. Os resultados obtidos no período fora da amostra, mediante o uso das medidas de erro e do teste estatístico preditivo, confirmam isso. A pesquisa pode auxiliar os gestores na formulação e aplicação de políticas direcionadas ao setor industrial. A possibilidade de antever o comportamento da produção pode ser decisiva no que diz respeito às políticas de estabilização da produção, ao longo do ano, eliminando os possíveis entraves provocados pela sazonalidade.

Palavras-chave: Análise espectral multivariada. Previsão. Produção industrial.

Abstract

This study has applied the multivariate spectrum analysis model to the set of time series of production in different segments of the manufacturing industry in Brazil, motivated by the model's ability to capture structures that represent the comprehensive behavior of the time series under study. The industrial segments were chosen on the basis of their having been leaders in total production in 2013. The multivariate spectrum analysis model showed itself adequate, when compared with two classical models that take into account seasonality, by allowing a greater number of better performances of price forecasts. The results obtained in the out-of-sample period, through the use of error measurements and predictive statistical tests, confirm this. Research can help managers in formulating and applying policies targeting the industrial sector. The ability to predict productive behavior may be decisive as regards establishing production stabilization policies throughout the year, eliminating the potential hindrances caused by seasonality.

Key words: Forecast. Industrial production. Multivariate singular spectrum analysis.

1 Introdução

Nos últimos anos, a indústria no Brasil se desenvolveu e se modernizou, destacando-se como atividade de alto valor econômico e social (CAMPOS, 2007), com tendência de crescimento acentuado no curto prazo. O desenvolvimento dos mercados interno e externo contribuiu para o caráter dinâmico dessas mudanças nas organizações, com a incorporação de tecnologias produtivas para satisfazer às exigências desses mercados. Para Oranje (2003), o melhor desempenho produtivo da empresa pode ser obtido por meio da competitividade, explicada pela opção em escolher entre diferentes fornecedores aqueles cuja capacidade produtiva possa atender as demandas da empresa por preços reduzidos.

A previsão do volume de produção se constitui como uma das principais ferramentas para executar o planejamento e avaliar os segmentos industriais, uma vez que é fator de decisão dos investimentos. A análise do volume de produção, como elemento do mecanismo de troca, reveste-se de singular importância para os participantes deste mercado, sejam eles compradores ou vendedores. Então, as decisões tomadas pelos produtores presumem o conhecimento do comportamento do volume de produção (RIBEIRO; SOSNOSKI; OLIVEIRA, 2010). Além delas, as decisões referentes ao conjunto de produção e a adoção de políticas de financiamento como alternativa de assegurar preços são baseadas em expectativas.

Para Martins e Martinelli (2010), o principal problema sobre a previsão reside nas grandes oscilações que ocorrem em razão dos fatores climáticos, mercadológicos e conjunturais que promovem incerteza de renda para os produtores, armazenadores, exportadores bem como processadores dos produtos. Assim, a previsão tem sido cada vez mais objeto de interesse dos acadêmicos, uma vez que por meio dela é possível reduzir a incerteza no

processo de decisão por parte daqueles que operam na indústria ou fazem negociações usando-a. Logo, todos os participantes necessitam de informações sobre o volume de produção que são fundamentais para a rentabilidade de suas atividades.

A previsão de vendas passa a ser fundamental para o sucesso de qualquer atividade e seu dimensionamento traz benefícios para clientes, fornecedores e indústria, como referem Walter et al. (2013). Desse modo, para esses autores, quanto mais acurada for a previsão, melhor para os clientes, que não se decepcionarão com a falta de produtos; assim como para a indústria e para seus fornecedores, que não perderão vendas por motivo de rupturas e não enfrentarão excesso de estoques por falta de demanda.

Acontece que, na literatura, as pesquisas empíricas realizadas sobre previsão alternam-se entre preços e volatilidade do comportamento dos dados de alta frequência (MARTINS; MARTINELLI, 2010) da série temporal em estudo. Portanto, as investigações usam modelos de previsão que não estão estruturados para realizar previsões do volume de produção com base nos dados de um conjunto de segmentos industriais.

Diante disso, neste estudo, objetivou-se realizar a previsão dos volumes de produção por meio do modelo de análise espectral singular multivariada (AESM), uma vez que evidências empíricas sugerem que as previsões realizadas com base nesse modelo apresentam melhor desempenho, quando comparadas as efetuadas com modelos univariados (ESQUIVEL, 2012; HASSANI, 2007; HASSANI et al., 2009; HASSANI; MAHMOUDVAND, 2013; MENEZES et al., 2014; PATTERSON et al., 2011).

A previsão dos volumes de produção assume papel central na discussão, em que se espera que o modelo AESM possa capturar estruturas das séries temporais que representem o comportamento abrangente das séries levando em consi-

deração os efeitos do conjunto de diferentes segmentos industriais.

Para tanto, organizou-se o artigo da seguinte forma: na próxima seção é apresentada a fundamentação teórica de alguns modelos aplicados para séries temporais com sazonalidade. Na seção 3, são descritos a metodologia e os modelos de previsão utilizados na pesquisa. Na seção 4, os dados e os resultados dos testes de normalidade, normalidade multivariada, linearidade, estacionariedade, testes preditivos e resultados empíricos são apresentados. As conclusões e sugestões para próximas pesquisas são expostas na última seção.

2 Fundamentação teórica

Na literatura de séries temporais, é possível distinguir duas estratégias clássicas de modelagem. A primeira delas é considerada simples e refere-se aos modelos de suavização exponencial, enquanto que 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 que 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, também consideram tendência e ruído (MORETTIN; TOLOI, 2006).

Levando em conta que, por meio da suavização, um processo de médias móveis é pouco intuitivo para o comportamento de uma particular série temporal e considerando que a aplicação dos modelos autorregressivos (definido por valores an-

teriores e adição do ruído) 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 mediante 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), o qual se fundamenta 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 quando são usadas defasagens múltiplas de quatro, conforme as estações do ano, ou em dados econômicos que exigem defasagens múltiplas de 12, de acordo com os meses do ano (ESQUIVEL, 2012). Com isso, é adequado considerar uma periodicidade estocástica para avaliar o comportamento da série temporal. Portanto, quando o modelo ARIMA leva em consideração essa sazonalidade ele passa a ser conhecido como seasonal autoregressive integrated moving average (SARIMA).

Se para os modelos clássicos descritos anteriormente o sinal (tendência e periodicidade) da série temporal é estudado em termos de unidades de tempo, para os modelos espectrais singulares 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 singulares de análise univariada e multivariada,

quando comparados com os 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), como, para Vityazev, Miller e Prudnikova (2010), investigam a estrutura das séries temporais com mais detalhes quando comparados com as transformadas de Fourier e de Wavelet.

2.1 Desempenho das previsões de modelos clássicos e espectrais

Hassani (2007), em uma pesquisa, 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 ARIMA e HW, também empregados por Brockwell e Davis (2002), para a previsão da série temporal morte acidental nos Estados Unidos na década de 1970. A pesquisa revelou que o modelo espectral de análise univariada gerou previsões mais precisas que aquelas obtidas pelos modelos clássicos.

Ainda em relação ao modelo espectral de análise univariada, Menezes et al. (2014), ao confrontarem os resultados de previsão para dados do consumo de energia elétrica de uma distribuidora de eletricidade que atende parte do estado do Rio de Janeiro, confirmaram melhor desempenho da análise espectral em relação ao modelo ARMA e 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 SARIMA e HW.

Em outra investigação, Hassani et al. (2009) utilizaram o ARIMA e o HW na 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, concluíram que tanto o modelo espectral de análise univariada como o AESM apresentaram melhor desempenho de previsão, comparado ao ARMA. Mesma conclusão sobre o desempenho de previsão dos modelos espectrais univariado e multivariado em relação ao modelo ARIMA e HW é obtida por Hassani et al. (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) demonstraram que o modelo AESM apresentou melhores desempenhos em comparação com o espectral de análise univariada. Ainda em relação a esse modelo as suas primeiras pesquisas foram inicialmente 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).

Já em relação às pesquisas com produção industrial, Walter et al. (2013) realizaram previsões para indústria de motocicletas usando o modelo SARIMA. Os autores explicaram que para a indústria automotiva os estudos são realizados com base em suavização exponencial, regressão e modelo ARIMA. Sandmann et al. (2014) fizeram uso do modelo HW para previsão de derivados do leite e carne na região oeste do Paraná. Esses trabalhos apresentam diferentes metodologias para identificar padrões de comportamento da sazonalidade e realizar previsões. No entanto, ao analisarem o comportamento da série temporal em estudo, não levam em consideração as séries temporais de outros segmentos industriais de forma a favorecer a captura da estrutura da série

temporal em análise, o que acaba justificando a aplicação do modelo AESM.

3 Abordagem metodológica

Com o objetivo de avaliar a contribuição do modelo AESM na previsão dos volumes de produção de diferentes segmentos industriais, nesta pesquisa, além de se fazer uso do modelo de análise multivariada, utilizaram-se o HW e o modelo SARIMA por conta dos aspectos de sazonalidade das séries temporais. Assim, um aspecto importante da pesquisa é poder, depois de realizadas as previsões passos mais adiante, confrontá-las, fora do período da amostra e avaliar seu desempenho por meio das medidas Erro Quadrático Médio (EQM) e Erro Quadrático Acumulado (EQA), além do teste estatístico preditivo proposto por Diebold e Mariano (1995).

3.1 Modelo espectral de análise multivariada

Semelhante ao modelo espectral de análise univariada, o 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 $Y_{t_i}^{(i)} = (y_{t_i}^{(1)}, \dots, y_{t_i}^{(i)})$, com $i = 1, \dots, M$, para uma matriz multidimensional $[X_1^{(i)}, \dots, X_{K_i}^{(i)}]$ com vetores $X_j^{(i)} = (y_j^{(i)}, \dots, y_{j+L_i+1}^{(i)})^T \in R^{L_i}$ em que $K_i = N_i - L_i + 1$. Os vetores $X_j^{(i)}$ são chamados de vetores defasados. Semelhante ao modelo de análise univariada, a matriz $X^{(i)}$ é uma matriz Hankel por apresentar 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 $Y_{t_i}^{(i)}$, levando em conta 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 do bloco de matrizes trajetórias $X_V X_V^T$ 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 como segue:

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

A estrutura em (2) é similar a 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 univariado para uma única série temporal $Y_{t_i}^{(i)}$. Semelhante ao obtido no modelo espectral univariado, 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 blo-

co da matriz que corresponde ao número de autovalores não nulos.

No estágio de reconstrução, o passo agrupamento para o modelo de análise multivariada 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:

$$X_V = H_{I_1} + \dots + H_{I_M} \tag{4}$$

em que H_{I_1}, \dots, H_{I_M} são definidos como bloco de matrizes resultantes.

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 autotripas para formação da subsérie ruído $Y_{N_i}^{(n)}$. A w -correlação $C(2)$ é definida com primeiro e segundo conjuntos de autotripas 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.

Essas w -correlações cumulativas são plotadas num gráfico, como mostrado na Figura 1, adaptada de Patterson et al. (2011, p. 2203). 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 corresponde a uma separação das componentes sinal e ruído. Com base nisso, percebe-se mediante a Figura 2 que a subsérie sinal $Y_{N_i}^{(s)}$ será dada pelos conjuntos autotripas 1-5 e, a subsérie ruído $Y_{N_i}^{(n)}$ pelos conjuntos 6-12, uma vez que $C(6)$ indica uma alteração desse declínio.

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




Figura 1: Correlações cumulativas para as primeiras autotripas

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

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 da seguinte maneira:

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

e a matriz W representada por:

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

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 de Holt-Winters

Os modelos de suavização exponencial, também definidos como modelos de alisamento ou amortecimento, são desenvolvidos para um fim específico e não requerem fundamentação probabilística. Entre os modelos disponíveis na literatura, o HW é indicado para séries temporais com padrão de comportamento mais complexo, que além de apresentarem sazonalidade também apresentam tendência e ruído.

A incorporação da sazonalidade no modelo HW pode ser realizada por intermédio de dois enfoques distintos, dependentes do padrão de sazonalidade identificado na série: sazonalidade multiplicativa e aditiva. Ao considerar a sazonalidade multiplicativa, a série temporal pode ser definida (MORETTIN; TOLOI, 2006) como:

$$Y_t = N_t S_t + m_t + \epsilon_t \tag{8}$$

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

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

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, a seguir:

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

Para o enfoque sazonalidade multiplicativa, a correção dos erros e_t é dada do seguinte modo:

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

O outro enfoque do método, dado nesta pesquisa por HW_a , é aplicado quando a série apresenta sazonalidade da forma 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:

$$Y_t = N_t + m_t + S_t + \epsilon_t \tag{12}$$

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 sua-
vização do modelo para o enfoque multiplicativo
bem como s representando o número de obser-
vações.

Os valores futuros são previstos pelas equações:

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

O procedimento de correção dos erros para
este 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 consi-
derar a sazonalidade estocástica para explicar o
comportamento sazonal da série temporal. Desta
maneira, a recomendação é que uma das varia-
ções do modelo ARIMA seja utilizada. Trata-se
do ARIMA sazonal multiplicativo ou SARIMA.
O modelo geral representado por ARIMA (p,d,q)
 $\times(P,D,Q)$ pode ser definido (BOX; JENKINGS,
1976) como:

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

com $\phi(B)$ o operador autorregressivo, Φ_p o poli-
nômio estacionário autorregressivo sazonal de or-
dem 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 sa-
zonal 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 sa-
zonal 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 re-
presentado por:

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

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

3.4 Avaliação do desempenho das previsões

Como as previsões podem apresentar erros,
independentemente do modelo adotado, costuma-
se avaliar o resultado das previsões ao comparar
os valores obtidos com os valores da série tempo-
ral original e determinar o seu desempenho por
meio de alguma medida. Então, as previsões serão
confrontadas com seis meses subsequentes ao mês
final da amostra. Para isso, a avaliação de desem-
penho faz uso da medida EQM definida:

$$EQM = \frac{1}{h} \sum_{N+1}^{N+h} (Y_j - \widehat{Y}_j)^2 \quad (20)$$

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 EQA dado por:

$$EQA = \sum_{N+1}^{N+h} (Y_j - \hat{Y}_j)^2 \quad (21)$$

Então, sempre que esta 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 é feita a partir do trabalho de Diebold e Mariano (1995), nesta pesquisa denominada de 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 Análise dos resultados

4.1 Testes estatísticos aplicados sobre os dados

Entendem-se, como conjunto de séries temporais, os valores brutos mensais da produção de diferentes segmentos industriais, no Brasil, conforme definidos pela Classificação Nacional de Atividade Econômica (CNAE), responsáveis, nos anos de 2011, 2012 e 2013, respectivamente, por 72,1%, 72,9% e 71,7% do total produzido pela indústria de transformação nacional.

Assim, por conta da participação que representam do volume total produzido pela indústria de transformação, as séries temporais escolhidas são identificadas da seguinte maneira: ALI (produtos alimentícios), CEL (celulose e papel), PET (coque e derivados do petróleo), QUI (produtos químicos), MIN (minerais não metálicos), MET (metalurgia), PRO (produtos de metal), INF (informática e eletrônicos), MAQ (máquinas e aparelhos) e VEI (veículos automotores, reboques e carrocerias). Os valores da produção desses segmentos industriais foram obtidos no banco de dados do Instituto Brasileiro de Geografia e Estatística (IBGE) e correspondem ao período de março de 2006 a fevereiro de 2014, cuja periodicidade é mensal totalizando 96 meses. Todas as séries temporais na pesquisa são utilizadas na forma logarítmica.

Para testar se a amostra de dados é originada de uma população com uma distribuição específica, os testes de Anderson-Darling (A-D) e de Shapiro-Wilk (S-W) são usados. Na pesquisa, os dois testes são utilizados para uma visão abrangente dos resultados. Como pode ser visto, a partir dos achados dispostos na Tabela 1, para um nível de 1% de significância, as séries temporais não estão distribuídas normalmente.

Para avaliar o aspecto da normalidade do conjunto de séries temporais, fez-se uso do teste Doornik-Hansen-Omnibus (DHO), que é um teste de normalidade multivariada aplicado entre pares formados pelas séries. Os resultados apresentados na Tabela 2 indicam que há fortes evidências de não normalidade multivariada para um nível de 1% de significância na maior parte dos pares formados. As exceções ocorrem para aqueles pares cujo p -valor é superior a 0,01. Na pesquisa, seu uso justifica-se para conhecimento das características das séries temporais, uma vez que os modelos espectrais não pressupõem a hipótese de normalidade dos dados.

Tabela 1: Teste de normalidade A-D, S-W e p-valor

	ALI	CEL	PET	QUI	NIM	MET	PRO	INF	MAQ	VEI
Número de observações	96	96	96	96	96	96	96	96	96	96
Shapiro-Wilk	0,91	0,74	0,86	0,90	0,87	0,81	0,90	0,91	0,88	0,83
p-valor	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Anderson-Darling	3,51	13,12	6,55	3,78	5,40	7,37	4,79	3,08	5,20	3,24
p-valor	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Fonte: Os autores.

Tabela 2: Teste de normalidade multivariada DHO e p-valor

	ALI	CEL	PET	QUI	MIN	MET	PRO	INF	MAQ	VEI
ALI		18,21	10,70	24,43	30,83	54,93	21,48	12,73	11,46	63,83
p-valor		0,00	0,03	0,00	0,00	0,00	0,00	0,03	0,03	0,00
CEL			4,16	10,17	9,50	38,51	16,38	17,85	2,22	76,04
p-valor			0,38	0,03	0,04	0,00	0,00	0,00	0,69	0,00
PET				8,14	16,29	38,59	8,68	12,54	2,05	47,26
p-valor				0,06	0,00	0,00	0,07	0,03	0,72	0,00
QUI					14,69	16,77	2,97	8,46	1,71	36,67
p-valor					0,00	0,00	0,56	0,07	0,78	0,00
MIN						46,96	23,57	23,44	9,86	124,03
p-valor						0,00	0,00	0,00	0,04	0,00
MET							14,95	40,29	19,71	96,06
p-valor							0,00	0,00	0,00	0,00
PRO								10,82	7,91	57,99
p-valor								0,03	0,09	0,00
INF									16,01	40,28
p-valor									0,00	0,00
MAQ										51,39
p-valor										0,00

Fonte: Os autores.

Os testes de não linearidade de Tsay (1986) e de McLeod e Li (1983) 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 em *lags* de cinco e dez meses. Para um nível de 1% de significância as séries temporais podem ser consideradas lineares.

Por fim, foram realizados os testes de Dickey-Fuller Aumentado (DFA) e Kwiatkowski-Phillips-Schmidt-Shin (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 as séries temporais possuem raiz unitária e, portanto, não são estacionárias. Em relação ao segundo, a hipótese nula é que as séries temporais não possuem raiz unitária e, logo, são estacionárias. Desta forma, ambos confirmam à sua maneira, que as séries temporais ALI, CEL, PET, MET, PRO, INF e MAQ não são estacionárias. Em resumo, a maior parte das séries temporais, utilizadas na pesquisa, não é estacionária e apresenta não normalidade multivariada, além disso, todas as séries são lineares.

A Figura 2 apresenta o comportamento de cada série temporal no período de março de 2006 a fevereiro de 2014.

Tabela 3: p-valor para testes Tsay e McLeod do primeiro conjunto de séries reais

	Lag	ALI	CEL	PET	QUI	MIN	MET	PRO	INF	MAQ	VEI
Número de observações		96	96	96	96	96	96	96	96	96	96
Tsay	5										
p-valor		0,06	0,57	0,55	0,03	0,02	0,05	0,11	0,34	0,05	0,04
Tsay	10										
p-valor		0,16	0,25	0,10	0,04	0,03	0,06	0,78	0,35	0,48	0,63
McLeod	5										
p-valor		0,30	0,05	0,25	0,30	0,40	0,10	0,40	0,90	0,80	0,04
McLeod	10										
p-valor		0,10	0,03	0,10	0,20	0,60	0,30	0,25	0,80	0,45	0,07

Fonte: Os autores.

Tabela 4: Teste DFA e KPSS para série simulada e conjuntos de séries reais

Séries temporais	DFA	Valor Crítico 1%	KPSS	Valor Crítico 1%
ALI	-1,83	-4,05	0,23	0,21
CEL	-3,80	-4,05	0,28	0,21
PET	-0,72	-4,05	0,28	0,21
QUI	-5,74	-4,05	0,05	0,21
MIN	-5,56	-4,05	0,08	0,21
MET	-3,80	-4,05	0,22	0,21
PRO	-3,38	-4,05	0,27	0,21
INF	-3,79	-4,05	0,22	0,21
MAQ	-3,40	-4,05	0,26	0,21
VEI	-5,15	-4,05	0,07	0,21

Fonte: Os autores.

4.2 Aplicações empíricas

Além dos parâmetros utilizados pelos modelos AESM e SARIMA, 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 não apresentam bons resultados. Na mesma tabela, percebe-se que não existem diferenças significativas para as previsões realizadas entre o HW com sazonalidade aditiva e multiplicativa. As previsões obtidas pelo modelo AESM, quando comparadas com as previsões obtidas pelos modelos HWa, HWm e SARIMA, correspondem ao maior número dos melhores desempenhos (MD na Tabela 5), por


conta dos menores valores para a medida de erro (22). O modelo AESM foi responsável por 30 melhores desempenhos contra 12 do modelo HWa e 8 do modelo HWm.

Na Tabela 6, percebe-se que o modelo de melhor desempenho (MD) de previsão supera o de melhor desempenho subsequente (MDS, na mesma tabela), uma vez que as diferenças apresentadas são negativas. Exceções para isso são dadas na série temporal PRO com $h = 5,6$ para HWm e HWa e na série VEI com $h = 3$, para HWa e HWm.


Em seguida, com o objetivo de avaliar se a diferença entre os EQMs do modelo de melhor desempenho com o melhor desempenho subsequente é estatisticamente significativa, aplicou-se o teste DM para os passos à frente três e seis meses, uma vez que esses períodos são compatíveis com o período de divulgação da atividade econômica representada pelo Produto Interno Bruto (PIB). 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 ao nível estatístico 1% de significância para as séries temporais ALI, PET, MIN, MET e INF para os passos à frente h (três e seis meses), e CEL e QUI para o passo à frente h (seis meses), indicando a superioridade do modelo de melhor desempenho. Em relação às




(a) Séries temporais ALI e CEL




(b) Séries temporais PET e QUI



(c) Séries temporais MIN e MET



(d) Séries temporais PRO e INF



(e) Séries temporais MAQ e VEI




Figura 2: Valores brutos da produção industrial

Tabela 5: Desempenho de previsão por meio do EQM

Série	Parâmetros			EQM					
	L	(p,d,q)(P,D,Q)	h	AESM	HWa	HWm	SARIMA	MD	MDS
ALI	9	(1,1,0)(2,0,0)	2	1.8E-05	9.6E-05	1.32E-04	1.5E-04	AESM	HWa
			3	2.7E-05	3.7E-04	9.87E-04	3.4E-05	AESM	SARIMA
			4	1.6E-05	5.6E-04	1.26E-03	9.3E-05	AESM	SARIMA
			5	8.6E-07	6.5E-04	1.98E-03	2.3E-05	AESM	SARIMA
			6	2.4E-07	7.0E-04	2.25E-03	4.5E-06	AESM	SARIMA
CEL	9	(2,1,2)(0,0,1)	2	3.7E-06	4.3E-07	4.7E-07	4.5E-06	HWa	HWm
			3	3.1E-06	2.9E-07	3.1E-07	3.5E-06	HWa	HWm
			4	5.6E-06	4.2E-07	4.3E-07	1.3E-05	HWa	HWm
			5	4.6E-06	7.6E-07	7.4E-07	8.7E-06	HWm	HWa
			6	8.5E-07	2.0E-06	1.9E-06	2.6E-06	AESM	HWm
PET	9	(4,1,3)(0,0,1)	2	1.7E-06	3.6E-05	3.7E-05	2.0E-06	AESM	SARIMA
			3	7.2E-07	1.1E-05	1.2E-05	1.9E-05	AESM	HWa
			4	8.0E-06	8.1E-06	8.2E-06	6.9E-05	AESM	HWa
			5	6.1E-06	1.7E-05	1.9E-05	6.4E-05	AESM	HWa
			6	1.8E-07	2.0E-05	2.1E-05	4.0E-05	AESM	HWa
QUI	9	(3,0,4)(0,0,1)	2	1.3E-05	1.3E-06	1.2E-06	2.1E-04	HWm	HWa
			3	4.3E-06	8.8E-06	8.9E-06	2.0E-04	AESM	HWa
			4	6.2E-06	2.0E-05	2.1E-05	1.7E-04	AESM	HWa
			5	5.0E-06	4.8E-05	4.9E-05	1.3E-04	AESM	HWa
			6	1.7E-07	1.0E-04	1.2E-04	4.5E-05	AESM	HWa
MIN	9	(2,0,2)(1,0,1)	2	1.3E-05	4.0E-05	4.1E-05	2.1E-04	AESM	HWa
			3	4.3E-06	2.0E-05	2.1E-05	2.0E-04	AESM	HWa
			4	6.2E-06	1.4E-07	1.5E-07	1.7E-04	HWa	HWa
			5	5.0E-06	1.1E-05	1.3E-05	1.3E-04	AESM	HWa
			6	1.7E-07	3.9E-05	4.0E-05	4.5E-05	AESM	HWa
MET	9	(1,1,2)(0,0,1)	2	1.1E-05	4.6E-05	4.8E-05	5.0E-05	AESM	HWa
			3	6.3E-06	4.5E-05	4.6E-05	3.9E-05	AESM	HWa
			4	3.1E-05	2.6E-05	2.8E-05	5.1E-05	HWa	HWm
			5	2.9E-05	1.6E-05	1.9E-05	4.6E-05	HWa	HWm
			6	4.7E-06	4.5E-05	4.5E-05	1.1E-05	AESM	SARIMA
PRO	9	(1,1,1)(1,0,0)	2	3.5E-05	6.9E-06	6.8E-06	1.3E-04	HWm	HWa
			3	2.6E-05	8.5E-06	8.3E-06	7.9E-05	HWm	HWa
			4	7.8E-05	1.7E-05	1.6E-05	1.2E-04	HWm	HWa
			5	6.5E-05	1.3E-05	1.1E-05	1.0E-04	HWm	HWa
			6	1.4E-05	7.5E-06	7.2E-06	4.5E-05	HWm	HWa
INF	9	(2,1,1)(0,0,1)	2	2.5E-05	2.7E-05	2.9E-05	1.2E-04	AESM	HWa
			3	6.5E-06	2.6E-05	2.7E-05	1.7E-04	AESM	HWa
			4	3.0E-04	5.3E-04	5.4E-04	7.0E-04	AESM	HWa
			5	2.4E-04	4.6E-04	4.8E-04	5.2E-04	AESM	HWa
			6	6.3E-06	4.6E-05	4.7E-05	8.6E-05	AESM	HWa
MAQ	9	(1,1,0)(1,0,0)	2	6.9E-07	3.6E-06	3.7E-06	6.0E-05	AESM	HWa
			3	1.6E-07	3.4E-06	3.5E-06	3.5E-05	AESM	HWa
			4	4.4E-04	7.0E-05	7.2E-05	1.7E-04	HWa	HWm
			5	9.1E-05	5.8E-05	5.9E-05	1.5E-04	HWa	HWm
			6	8.5E-06	3.2E-06	3.3E-06	2.4E-05	HWa	HWm
VEI	9	(1,0,1)(1,0,0)	2	8.8E-06	9.0E-06	1.0E-05	4.8E-04	AESM	HWa
			3	5.9E-05	1.9E-06	3.8E-06	3.5E-04	HWa	HWm
			4	4.6E-04	2.1E-04	2.5E-04	7.7E-04	HWa	HWm
			5	4.1E-04	2.0E-04	1.9E-04	7.3E-04	HWm	HWa
			6	8.4E-05	2.7E-05	2.4E-05	3.4E-04	HWa	HWm

Fonte: Os autores.

Tabela 6: Desempenho de previsão pela diferença do EQA

Série	h	EQA		Diferença
		MD	MDS	
ALI	2	AESM	HWa	-4.9E-05
	3	AESM	SARIMA	-1.6E-04
	4	AESM	SARIMA	-2.4E-04
	5	AESM	SARIMA	-2.7E-04
	6	AESM	SARIMA	-2.7E-04
CEL	2	HWa	HWm	-2.3E-04
	3	HWa	HWm	-2.5E-04
	4	HWa	HWm	-3.4E-04
	5	HWm	HWa	-3.7E-07
	6	AESM	HWm	-3.6E-04
PET	2	AESM	SARIMA	-7.1E-05
	3	AESM	HWa	-8.7E-05
	4	AESM	HWa	-1.0E-04
	5	AESM	HWa	-1.7E-04
	6	AESM	HWa	-2.2E-04
QUI	2	HWm	HWa	-7.0E-05
	3	AESM	HWa	-6.3E-05
	4	AESM	HWa	-4.9E-05
	5	AESM	HWa	-1.5E-05
	6	AESM	HWa	-2.0E-05
MIN	2	AESM	HWa	-7.8E-05
	3	AESM	HWa	-5.6E-05
	4	HWa	HWa	-2.5E-05
	5	AESM	HWa	-4.9E-04
	6	AESM	HWa	-1.2E-04
MET	2	AESM	HWa	-9.0E-05
	3	AESM	HWa	-1.7E-04
	4	HWa	HWm	-1.4E-04
	5	HWa	HWm	-8.6E-04
	6	AESM	SARIMA	-3.8E-05
PRO	2	HWm	HWa	-1.1E-05
	3	HWm	HWa	-1.6E-06
	4	HWm	HWa	-2.0E-05
	5	HWm	HWa	1.1E-04
	6	HWm	HWa	3.1E-04
INF	2	AESM	HWa	-4.7E-05
	3	AESM	HWa	-9.7E-05
	4	AESM	HWa	-2.1E-03
	5	AESM	HWa	-2.2E-03
	6	AESM	HWa	-2.0E-03
MAQ	2	AESM	HWa	-4.7E-06
	3	AESM	HWa	-1.1E-05
	4	HWa	HWm	-2.4E-04
	5	HWa	HWm	-1.2E-04
	6	HWa	HWm	-1.1E-04
VEI	2	AESM	HWa	-1.8E-04
	3	HWa	HWm	3.3E-06
	4	HWa	HWm	-7.9E-04
	5	HWm	HWa	-8.1E-04
	6	HWa	HWm	-5.7E-04

Fonte: Os autores.

Tabela 7: Teste Diebold-Mariano e modelos comparados

Série	H	DM	p-valor	MD	MDS
ALI	3	-4,40	0,00	AESM	SARIMA
	6	-4,29	0,00	AESM	SARIMA
CEL	3	-0,31	0,78	HWa	HWm
	6	-4,71	0,00	AESM	HWm
PET	3	-4,59	0,00	AESM	HWa
	6	-7,28	0,00	AESM	HWa
QUI	3	-1,66	0,24	AESM	HWa
	6	-4,53	0,00	AESM	HWa
MIN	3	-4,91	0,00	AESM	HWa
	6	-4,83	0,00	AESM	HWa
MET	3	-4,06	0,00	AESM	HWa
	6	-4,74	0,00	AESM	SARIMA
PRO	3	-0,61	0,91	HWm	HWa
	6	-0,04	0,90	HWm	HWa
INF	3	-4,61	0,00	AESM	HWa
	6	-4,92	0,00	AESM	HWa
MAQ	3	-4,53	0,00	AESM	HWa
	6	-1,92	0,70	HWa	HWm
VEI	3	-0,06	0,93	HWa	HWm
	6	-1,06	0,90	HWa	HWm

Fonte: Os autores.

séries PRO e VEI, a hipótese nula de que a diferença entre as medidas de erro é zero não pode ser rejeitada ao mesmo nível de significância para os passos à frente h (três e seis meses), demonstrando inexistência de superioridade entre os resultados dos modelos de previsão.

Na Figura 3, são apresentados, por meio dos gráficos do volume de produção bruta no período mensal, os comportamentos das séries temporais originais (linhas sólidas) e das temporais previstas (linhas tracejadas), obtidos pelo modelo AESM, pois este apresentou os melhores desempenhos. Os gráficos foram elaborados no período de março de 2014 a agosto de 2014, fora da amostra. Observa-se que o modelo, no período em análise, conseguiu detectar a tendência dos volumes de produção, com exceção para as séries temporais MET, PRO, MAQ e VEI.



Figura 3: Previsão para os volumes de produção das atividades industriais

5 Conclusões e sugestões

A análise do volume de produção dos segmentos industriais, como elemento do mecanismo de troca, reveste-se de singular importância para os participantes da indústria ou aqueles que estabelecem negociações com o setor produtivo. Assim, as decisões tomadas por estes participantes presumem o conhecimento do comportamento do volume de produção. Entretanto, pesquisas realizadas sobre previsão são dadas entre análises empíricas que observam os preços e a volatilidade do comportamento da série temporal a partir da utilização de dados de alta frequência referentes apenas a um dado segmento industrial em estudo. Desse modo, nas pesquisas, utilizam-se modelos de previsão que não estão estruturados para realização de previsões com base nos dados de um conjunto de segmentos.

Como a dinâmica de algumas séries temporais podem apresentar mudanças no tempo, é preciso ter certeza de que o modelo de previsão não é sensível a essas variações. A motivação para utilizar o modelo AESM dá-se por causa da sua capacidade de capturar estruturas que representem o comportamento mais abrangente e que levem em consideração os efeitos entre um conjunto M de séries temporais.

Os resultados dos testes estatísticos aplicados às séries temporais indicam que a maior parte das séries temporais usadas neste estudo não é estacionária e apresenta não normalidade multivariada, além disso, todas as séries são lineares.

No contexto da pesquisa, o modelo AESM demonstrou-se adequado, quando comparado com os modelos HWa, HWm e SARIMA, 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 das previsões para os passos à frente h (6 e 12 meses),

confirmam isso. De modo geral, os resultados obtidos pelo modelo AESM superaram, com base no teste estatístico preditivo, aqueles encontrados pelo modelo de melhor desempenho subsequente. Neste estudo, ao utilizar-se o AESM, realizaram-se contribuições para os gestores na formulação de políticas direcionadas ao setor industrial à medida que se agregaram evidências favoráveis à generalidade da eficácia de tal modelo, quando aplicado ao volume de produção de diferentes segmentos da indústria de transformação no Brasil, mediante separação de sinal e ruído das séries temporais, permitindo auxiliar na previsão dos passos à frente.

Do ponto de vista prático, os resultados obtidos podem ajudar os gestores na formulação e na aplicação de políticas direcionadas ao setor industrial. Assim, a possibilidade de antever o comportamento da produção pode ser decisiva no que diz respeito à implementação de políticas para estabilizar a produção, ao longo do ano, eliminando os possíveis entraves provocados pela sazonalidade. Para próximas pesquisas, sugere-se a utilização de outras bases de dados, a inclusão de outras séries temporais de produção industrial, a adoção de outros períodos de análise e o uso de outras variáveis que possam aumentar o poder explicativo do modelo AESM.

Referências

- BOX, G. E. P.; JENKINS, G. M. *Time series analysis forecasting and control*. San Francisco: H. Day, 1976.
- BROCKWELL, P. J.; DAVIS, R. A. *Introduction to time series and forecasting*. 2nd 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.
- DIEBOLD, F.; MARIANO, R. Comparing predictive accuracy. *Journal of Business and Economic Statistics*, v. 13, p. 253-265, 1995.

- ESQUIVEL, R. M. *Análise espectral singular: modelagens de séries temporais através de estudos comparativos usando diferentes estratégias de previsão*. 2012. 161 f. Dissertação (Mestrado em Modelagem Computacional)–Faculdade de Tecnologia Senai Cimatec, Salvador, 2012.
- GOYAL, A.; WELCH, I. Predicting the equity premium with dividend ratios. *Management Science*, v. 49, p. 639-654, 2003.
- HASSANI, H.; MAHMOUDVAND, R. Multivariate singular spectrum analysis: a general view and new vector forecasting approach. *International Journal of Energy and Statistics*, v. 1, p. 55-83, 2013.
- 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. Singular spectrum analysis: methodology and comparison. *Journal of Data Science*, v. 5, p. 239-257, 2007.
- 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.
- MARQUES, J.; ANTUNES, S. A perigosidade natural da temperatura do ar em Portugal continental: a avaliação do risco na mortalidade. In: I CONGRESSO INTERNACIONAL DE RISCOS, 2009, Lisboa. *Anais...* Lisboa: I Congresso Internacional de Riscos, 2009.
- MARTINS, T. M.; MARTINELLI, D. P. Ciclos e previsão cíclica dos preços de commodities: um modelo indicador antecedente para commodity açúcar. *Revista de Administração, Contabilidade e Economia*, v. 2, p. 2-12, 2010.
- 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.
- MORETTIN, P. A.; TOLOI, C. M. C. *Análise de séries temporais*. São Paulo: Blücher, 2006.
- ORANJE, M. *Competitividade das frutas brasileiras no comércio internacional*. 2003. 114 f. Dissertação (Mestrado em Economia Aplicada)–Universidade Federal de Viçosa, Viçosa, 2003.
- 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. 1994. 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.
- SANDMANN, A. et al. Utilização do modelo Holt-Winters para previsão das vendas de produtos de origem animal no oeste paranaense. In: IV CONGRESSO BRASILEIRO DE ENGENHARIA DA PRODUÇÃO, 2014, Ponta Grossa. *Anais...*Ponta Grossa: IV Congresso Brasileiro de Engenharia da Produção, 2014.
- TSAY, R. 1986. Non-linearity tests for time series. *Biometrika*, v. 73, p. 461-466, 1986.
- VITYAZEV, V.; MILLER, N.; PRUDNIKOVA, E. J. Singular spectrum analysis in astrometry and geodynamics. *AIP Conference Proceedings*, v. 1283, p. 317-326, 2010.
- WALTER, O. M. F. C. et al. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. *Exacta*, v. 11, n.1, p. 77-88, 2013.

Recebido em 29 dez. 2014 / aprovado em 17 abr. 2015

Para referenciar este texto

PINHEIRO, C. A. O.; SENNA, V. Previsão da produção industrial por meio da análise espectral multivariada. *Exacta – EP*, São Paulo, v. 13, n. 1, p. 27-43, 2015.

