

APLICAÇÃO DOS MODELOS DE HOLT-WINTERS E REDE NEURAL FEED-FORWARD NA PREVISÃO DA PRODUÇÃO DE PETRÓLEO

Bruno Matos Porto - Universidade Federal de Mato Grosso do Sul/CPAQ. bmatosporto@gmail.com
Dra. Daniela Althoff Philippi - Universidade Federal de Mato Grosso do Sul/CPAQ.
daniela_philippi@yahoo.com.br

Resumo

O objetivo deste estudo foi realizar previsões da produção de petróleo e comparar a precisão dos modelos Holt-Winters (HW) e rede neural (NNAR). Foram utilizados os modelos de séries temporais (HW) ambas as versões e a (NNAR) com uso do software R, com base nos dados retirados do sistema de gerenciamento de séries temporais do Banco Central do Brasil (BCB). Os dados são referentes à produção de petróleo do Brasil entre janeiro de 2007 a junho de 2017. As previsões da produção de petróleo abrangeram o intervalo de julho a setembro de 2017. As previsões dos modelos foram comparadas por meio das medidas de erro MAD, MSD e MAPE, onde os resultados gerados pelos critérios de avaliação mostraram que a (NNAR) é altamente precisa, assim superou todos os outros modelos. Para pesquisas futuras sugerimos previsões fora da amostra de (1 até 12 meses) de um vasto número de séries temporais.

Palavras-Chave: Acuracidade; Medidas de erros; Séries Temporais.

1. Introdução

Constantemente tem observado a necessidade de pesquisar sobre previsões de rede neurais em economia, financeiro, negócios (HAIDER; HANIF, 2009). Assim, como as previsões automáticas de um amplo número de séries cronológicas univariadas são frequentemente indispensáveis nos negócios (HYNDMAN; KHANDAKAR, 2007). Na tomada de decisão econômica as previsões é uma ferramenta indispensável (MEDEL, 2013).

O desenvolvimento dos preços a capacidade de precisão das previsões ambas características de futuros mercados de energia, é essencial a tomada de decisão alcançar decisões mais assertivas (KOUTROUMANIDIS; IOANNOU, ARABATZIS; 2009). A economia do mundo tem forte relação de dependência com o petróleo devido a necessidade de energia das indústrias (FRAUSTO-SOLÍS; CHIM, SHEREMETOV; 2015).

Neste sentido o desempenho do petróleo bruto é relevante para economia mundial, pois é a commodities mais comercializada do mundo chega a representar cerca de 10% do comércio mundial total (VERLEGER, 1993; YUSOF; RASHID, MOHAMED; 2010). Nesta perspectiva a relevância de entender os mercados de petróleo bruto está relacionada pelo fato de dependência de aproximadamente dois terços da procura de energia do mundo são atendidas pelas fontes de energia petróleo e gás natural (ALVAREZ-RAMIREZ et al., 2003; XIE et al., 2006).

Os engenheiros de petróleo pesquisam um método singelo, porem confiável de fazer previsões da produção de petróleo a muito tempo, as predições de produção podem apoiar os engenheiros de petróleo em previsões econômicas (NGUYEN; CHAN, 2005). Além disso, existe uma considerável quantidade de dados de produção coletado e armazenado, no entanto às vezes não são usados os dados históricos de produção que possibilita a aplicação de um modelo de previsão (NGUYEN; CHAN, 2005; LI; CHAN, NGUYEN; 2013). Métodos univariados são modelos de previsão que depende apenas do comportamento dos dados passados para prever os valores futuros da série temporal (CHATFIELD, 1978).

A indústria de petróleo e gás natural do Brasil entre os anos de 2000 e 2014 aumentou sua participação de 3% para 13% (AGÊNCIA PETROBRAS, 2014). Atualmente a empresa Petrobras produziu no Brasil e no exterior o equivalente 2,77 milhões de barris de petróleo e gás natural em outubro de 2017, sendo que em média a produção de petróleo no país foi de 2,16 milhões de barris por dia (AGÊNCIA BRASIL, 2017). O objetivo deste estudo foi realizar previsões da produção de petróleo de curto prazo de três meses e comparar as predições, por meio, dos critérios de avaliação MAD, MSD e MAPE. Para alcançar tal objetivo os dados foram retirados do sistema de gerenciamento de séries temporais do Banco Central do Brasil (BCB) e realizadas as previsões dos métodos de Holt-Winters (versões aditiva e multiplicativa) e rede neural dos períodos de julho até setembro de 2017.

2. Petróleo

De acordo com Alvarez-Ramirez et al., (2003) a commodities petróleo bruto é comercializada internacionalmente por vários e diferentes competidores do mercado que são países produtores de petróleo, empresas de petróleo, refinarias individuais, países importadores de petróleo e especuladores. Seu preço é determinado por meio da sua oferta e demanda (ALVAREZ-RAMIREZ et al., 2003; XIE et al., 2006). Este comércio internacional necessita

de bastante tempo para completar a transação de envio do petróleo bruto de países exportadores para importadores essa situação acarreta uma variação de preços em diferentes partes do mundo (ALVAREZ-RAMIREZ et al., 2003; YU, WANG; LAI, 2008).

As quedas e aumentos bruscos nos preços do petróleo pode influenciar as atividades que dependem da commodities essas flutuações de preços do petróleo bruto impactam significativamente na economia de um país, além disso as flutuações nos preços voláteis do petróleo são de extrema importância para diversas instituições, profissionais do mercado de petróleo e pesquisadores da academia (XIE et al., 2006; YU, WANG; LAI, 2008). Portanto uma previsão precisa das futuras oscilações dos preços do petróleo serve de apoio as decisões dos planejadores de petróleo no que se refere a diminuição ou aumento dos níveis de produção (SEHGAL; PANDEY, 2015).

As previsões de produção de petróleo são de extrema relevância para as operações econômicas na indústria do petróleo (NGUYEN; CHAN, 2005; LI; CHAN, NGUYEN; 2013). Tradicionalmente os métodos de previsão mais utilizados na previsão da produção de petróleo que se baseiam em dados de produção são curva de declínio e redes neurais artificiais (NGUYEN; CHAN, 2005; YU, WANG; LAI, 2008; LI; CHAN, NGUYEN; 2013). Vários tipos de redes neurais que foram aplicadas na previsão de curto prazo da produção de petróleo com base em dados de séries temporais univariadas e multivariadas (SHEREMETOV et al., 2014). Entre as principais vantagens da utilização de redes neurais está: capacidade de prever séries temporais não-lineares (NGUYEN; CHAN, 2005; YU, WANG; LAI, 2008).

3. Holt-Winters (HW)

O modelo foi criado em 1960, por Winters este modelo de previsão é uma extensão do modelo de Holt, assim apresenta um parâmetro a mais e equação complementar para a sazonalidade (MAKRIDAKIS, 1976). Dentre suas principais vantagens são a sua simples utilização (CHATFIELD, 1978; CHATFIELD; YAR, 1988; SILVER, 2000); o seu bom desempenho, de modo geral e na prática (CHATFIELD; YAR, 1988); o baixo custo de operação (NEWBOLD; GRANGER, 1974) e útil para prever como o modelo complexo de Box-Jenkins (SILVER, 2000).

O modelo de série temporal HW, tem muita utilidade para os decisores e planejadores estratégicos que visam um modelo econômico e relativamente preciso com a finalidade de

amplo horizonte de previsão e significativo número de séries de tempos (BRANDON, JARRETT; KHUMAWALA, 1987).

De acordo com Chatfield (1978), “Existem dois tipos de modelo sazonal: uma versão aditiva que pressupõe que os efeitos sazonais são de tamanho constante e uma versão multiplicativa que pressupõe que os efeitos sazonais são proporcionais em tamanho ao nível médio dessazonalizado local”. O modelo Holt-Winters baseia-se em quatro equações a primeira, o componente nível (1), em seguida, componente tendência (2), então, o componente sazonal (3) e, por fim, as previsões do tempo (4). As versões são exibidas na sequência.

$$L_t = \alpha \left(\frac{x_t}{S_{t-m}} \right) + (1-\alpha)(L_{t-1} + T_{t-1}) \quad (1)$$

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1} \quad (2)$$

$$S_t = \gamma \left(\frac{x_t}{L_t} \right) + (1-\gamma)S_{t-m} \quad (3)$$

$$F_{t+n} = (L_t + nT_t)S_{t-m+n} \quad (4)$$

Fonte: Adaptado de Chatfield (1978)

Enquanto na versão aditiva são as equações:

$$L_t = \alpha(x_t - S_{t-m}) + (1-\alpha)(L_{t-1} + T_{t-1}) \quad (5)$$

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1} \quad (6)$$

$$S_t = \gamma(x_t - L_t) + (1-\gamma)S_{t-m} \quad (7)$$

$$F_{t+n} = L_t + nT_t + S_{t-m+n} \quad (8)$$

Fonte: Adaptado de Chatfield (1978)

Onde: L_t – estimativa do grau médio dessazonalizada no período t ; T_t – motivo sazonal de estima para o tempo t ; S_t – prazo de tendência de estima para o tempo t ; m – numero de considerações em ciclo sazonal; F_{t+n} – previsões de período n em diante; $n = 1, 2, \dots$; x_t – numero observado e α, β e γ - constantes de ponderação de nível, tendência e sazonalidade, nesta ordem (CHATFIELD, 1978).

4. Rede neural (NNAR)

A rede neural de Feed-forward constitui-se em camadas: uma de entrada, uma de saída e, de modo geral uma ou mais camadas escondidas e a capacidade de aprendizagem em reconhecer padrões desta rede neural possibilita ser utilizada como um modelo de previsão aplicado nos negócios (LAW, 2000).

O modelo de rede neural usado nesta pesquisa pertence ao pacote do software R, denominado *forecast* e o modelo de previsão presente no manual do pacote chama-se *nnetar* este modelo funciona de forma semelhante aos neurônios do cérebro, assim a arquitetura da rede neural é composta por camadas.

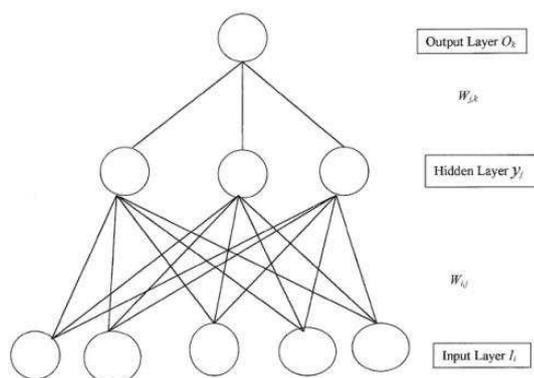
As entradas constituem a camada inferior e as saídas formam a camada superior é possível ter camadas ocultas Hyndman, R. J., & Athanasopoulos, G. (2013). Atendendo as orientações de Hyndman, R. J., & Athanasopoulos, G. (2013), que afirmam “O número de camadas ocultas e o número de nós em cada camada oculta devem ser previamente especificados”.

Assim definimos $p = 2$, $P = 2$, $size = 5$ $lambda = 3$, $decay = 0.28$. Onde: p - Dimensão de incorporação para séries temporais não sazonais; P - Número de atrasos sazonais utilizados como insumos; $size$ - Número de nós na camada oculta; $lambda$ - Parâmetro de transformação Box-Cox; $decay$ - parâmetro de decaimento (HYNDMAN, Rob J. et al, 2017).

Diante da flexibilidade das redes neurais elas não tem um processo sistêmico para criação de modelos, logo a obtenção de um modelo de rede neural robusto ocorre mediante a escolha de um grande número de parâmetros que são obtidos experimentalmente, por meio, de tentativa e erro (PALMER, MONTANO; SESÉ, 2006).

Este método foi utilizado neste estudo para selecionar a rede neural especificada aqui. Os detalhes sobre o funcionamento do modelo *nnetar* pode ser visto na seção 9.3, em Hyndman e Athanasopoulos (2013). A figura 1 apresenta a arquitetura geral de uma rede do tipo Feed-forward.

Figura 1 - Simplificação rede neural com três camadas



Fonte: elaborado por Law (2000)

5. Medida de precisão

A partir da explicação que devesse julgar a adaptação de qualquer medida de erro utilizada pelo resultado gerado da precisão das previsões fora da amostra do modelo de previsão, assim uma medida de erro para ser selecionada precisa aliar-se a finalidade da predição e os objetivos dos decisores (MAKRIDAKIS, 1993).

O MAPE fornece os resultados em porcentagem que facilita a interpretação pelos decisores, bem como gera um indicativo qualitativo da precisão do modelo de previsão testado (FLORES, 1986; MAKRIDAKIS, 1993). O *Mean Squared Error* (MAD) mede a acuracidade global e gera um indicativo da disseminação global em que todos os erros são dados pesos iguais (LAW, 2000). A medida é mesurada nas mesmas unidades dos dados históricos, além disso, é fácil para demonstrar aos tomadores de decisão por conta da facilidade de cálculo (FLORES, 1986). Neste sentido MAD constitui-se uma das primeiras medidas de erro, sendo singela de calcular e simples de compreender (BONETT; SEIER, 2003).

O *Mean Squared Error* (MSE) é uma medida comumente usada para ver a adaptação de um método de previsão em relação aos dados e medir o desempenho das previsões geradas, o critério também é fácil de calcular e de modo geral um bom critério para medir o desempenho de previsões da única série de tempo (CHATFIELD, 1988).

Este critério é comumente utilizado para comparar métodos de previsão, além de verificar o erro quadrático ele se diferencia de outras medidas de precisão porque demonstra qual modelo minimiza grandes erros uma vez que mostra estes erros mais do que outros critérios (THOMPSON, 1990).

$$MAD = \frac{\sum |R-D|}{n} \quad (9)$$

$$MSD = \frac{\sum (R-D)}{n-1} \quad (10)$$

$$MAPE = \frac{\sum |R-D/R|}{n} \cdot 100, (R \neq 0) \quad (11)$$

Fonte: Adaptado de MIN, Jennifer CH (2008).

Sendo, R = valor real de demanda; D = previsão; n = número de observações.

Medidas de erro são métodos de gerar informações sobre a precisão de certo modelo de previsão para prever os dados reais, tanto para modelos que são ajustadas aos dados quanto para previsões de períodos, fora da amostra (MAKRIDAKIS, 1993).

6. Procedimentos metodológicos

Nesta seção descreve-se a coleta de dados e o pacote usado no ambiente de trabalho R studio.

6.1 Coleta de dados

Os dados foram coletados a partir da ferramenta sistema gerenciador de séries temporais (SGS) que de acordo com o (BCB, 2017) “O Sistema Gerenciador de Séries Temporais (SGS) tem o objetivo de consolidar e tornar disponíveis informações econômico-financeiras, bem como manter uniformidade entre os documentos produzidos com base em séries temporais nele armazenadas”.

Tanto a ferramenta como as informações sobre a mesma são disponibilizadas pelo Banco Central do Brasil (BCB) na web site da empresa, portanto mediante a ferramenta a coleta foi referente a produção total do Brasil nos períodos de janeiro de 2007 a junho de 2017, atingindo 126 períodos mensais de amostra. Os dados utilizados encontram-se na tabela 1:

Tabela 1 - Produção de derivados de petróleo - Total - Barris/dia (mil) de janeiro de 2007 a junho de 2017

Mês/Ano	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
Janeiro	1.822	1.865	1.973	2.077	2.213	2.316	2.143	2.134	2.568	2.428	2.801
Fevereiro	1.846	1.858	1.991	2.096	2.151	2.289	2.108	2.175	2.528	2.412	2.784
Março	1.854	1.835	2.024	2.112	2.165	2.169	1.946	2.203	2.503	2.345	2.647
Abril	1.822	1.885	2.022	2.163	2.141	2.106	2.016	2.224	2.484	2.377	2.649
Mai	1.804	1.902	2.039	2.158	2.162	2.136	2.084	2.278	2.498	2.587	2.768
Junho	1.867	1.917	1.982	2.127	2.228	2.127	2.195	2.338	2.485	2.659	2.794
Julho	1.853	1.912	1.992	2.141	2.161	2.116	2.067	2.365	2.559	2.681	
Agosto	1.846	1.929	2.037	2.165	2.140	2.094	2.098	2.423	2.641	2.714	
Setembro	1.812	1.946	2.070	2.077	2.188	2.006	2.183	2.455	2.481	2.779	
Outubro	1.772	1.918	2.070	2.078	2.191	2.099	2.166	2.494	2.496	2.725	
Novembro	1.799	1.891	2.066	2.180	2.271	2.134	2.170	2.457	2.457	2.720	
Dezembro	1.894	1.924	2.079	2.271	2.301	2.198	2.197	2.596	2.619	2.847	

Fonte: elaborada pelos autores a partir de BCB (2017)

6.2 Pacote em R studio

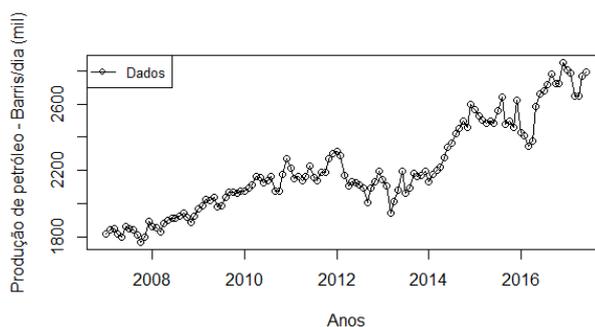
Para fazer as previsões e comparar a capacidade preditiva dos modelos HW versões aditiva, multiplicativa e rede neural, foi adotado com o apoio do software estatístico R. Procedeu-se as análises de previsão e acuracidade das previsões no *R studio* que é uma extensão do ambiente R, mediante o pacote *forecast* do R. Os cálculos das medidas de erro MAD, MAPE e MSD também foram executados com o pacote *forecast* no *R studio*.

As funções em R utilizadas para prever os valores no curto prazo de três meses são *forecast.HoltWinters* e *nnetar*, (HYNDMAN; KHANDAKAR, 2008; HYNDMAN, 2017). Já para comparar a acuracidade dos modelos de previsão foi usada a função *accuracy*. Assim, contemplando o período entre janeiro de 2007 até junho de 2017, verificou-se o comportamento das previsões com os dados reais (já disponibilizados pelo próprio BCB) concernentes ao período de julho a setembro de 2017. Esses recursos computacionais são de livre acesso e atualmente disponíveis para planejadores de petróleo e acadêmicos. No momento em que esses dados foram coletados não estavam disponíveis pelo BCB as observações mais atuais de 2017, por essa razão determinamos o terceiro trimestre de 2017, como o período de previsão.

6.3 Resultados da pesquisa

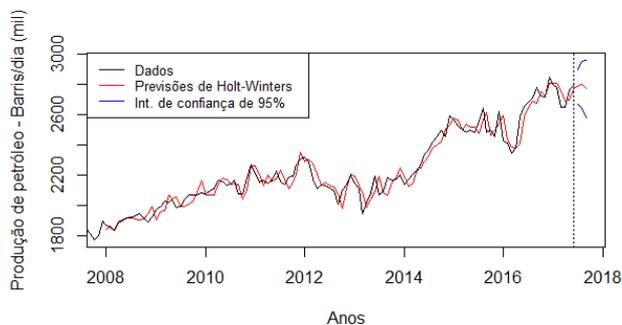
A princípio procedeu-se a criação de um gráfico de série temporal mediante os dados coletados de produção de petróleo e atendem-se as orientações de Hyndman e Athanasopoulos (2013), que recomendam inicialmente mostrar os dados em gráfico, construiu-se o gráfico de série temporal representado na figura 2.

Figura 2 - Produção de derivados de petróleo - Total - Barris/dia (mil)



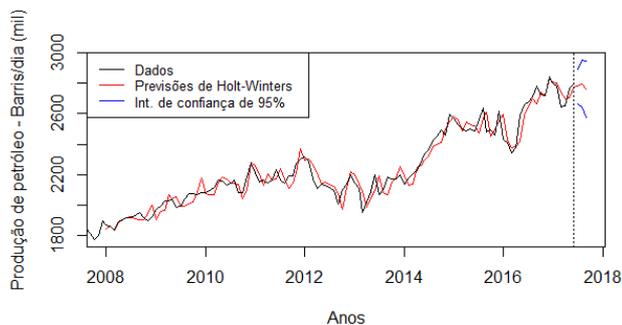
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 3 - Previsão versão aditiva de julho até setembro de 2017, com intervalo de confiança de 95%



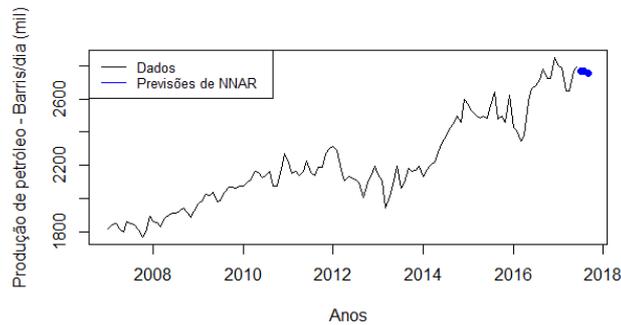
Fonte: Elaborado pelos autores com software R (2017)

Figura 4 - Previsão versão multiplicativa de julho até setembro de 2017, com intervalo de confiança de 95%



Fonte: Elaborado pelos autores com software R (2017)

Figura 5 - Previsões de NNAR de julho até setembro de 2017



Fonte: Elaborado pelos autores com software R (2017)

Os parâmetros de alisamento para as equações de nível, tendência e sazonalidade de ambas as versões de Holt-Winters e rede neural (NNAR) onde p é o número automaticamente selecionado para série de tempo não sazonal. P é o número de inputs atrasadas e $size$ é o número de nós na camada escondida estes referentes às previsões são demonstradas na tabela 2.

Tabela 2 - Parâmetros das previsões dos modelos

HW aditiva (α, β, γ)	HW multiplicativa (α, β, γ)	NNAR ($p; P; size$)
(0,9323368,0,1)	(0,9206957,0,1)	(2,2,5)

Fonte: elaborada pelos autores

Os modelos descritos foram utilizados para gerar as previsões de 3 meses da produção de petróleo. As observações e previsões de Holt-Winters versões aditiva, multiplicativa e rede neural em números para os meses de julho até setembro de 2017, podem ser visualizadas na tabela 3.

Tabela 3 - Comparação dos valores previstos com dados reais

Ano-2017				
Meses	Dados reais	HW aditiva	HW multiplicativa	Rede neural (NNAR)
Julho	2.734	2.785,55	2.780,65	2.766,586
Agosto	2.676	2.799,34	2.797,91	2.766,467
Setembro	2.766	2771,70	2.759,12	2.754,607

Fonte: elaborada pelos autores com base em BCB (2017)

As medidas de erro MAPE, MAD e MSD apresentam a precisão dos modelos em comparação com os dados reais. Uma característica óbvia na tabela 4, é que o modelo NNAR superou as duas versões de HW, assim apresentou um MAPE inferior a 10% que é considerado pela classificação de Lewis (1982), como previsão excelente.

Tabela 4 - Medidas de erro

Modelo	MAPE	MAD	MSD
HW aditiva	2.233672%	60.19949	5967,549367
HW multiplicativa	2.170201%	58.47909	5695,201667
Rede neural (NNAR)	1.661484%	44.81530	3125,308645

Fonte: elaborada pelos autores

O segundo melhor desempenho individual fica com HW versão multiplicativa isto com base nos resultados dos critérios MAPE, MAD e MSD como pode ser observada na tabela 4.

7. Considerações finais

Quanto aos resultados obtidos na pesquisa, mostrou-se que a rede neural (NNAR) fornece previsões, mais precisas da produção de petróleo, do que Holt-Winters (versões aditiva e multiplicativa). Os resultados obtidos estão consistentes com o que foi constatado por Szoplik (2015), que os modelos de previsão de rede neural superam os métodos de série de tempo em termos de precisão.

Além disso, o MAPE de 1,66% deste estudo superou os resultados de MAPE (5,5%) obtidos pela previsão complexa da rede neural modelo de perceptron multicamada (MPL) da demanda de gás natural na pesquisa de (SZOPLIK, 2015). Isto indica que é viável a utilização do modelo NNAR para prever a produção de petróleo. A pesquisa limitou-se em um único horizonte de previsão (3) meses fora da amostra e uma única série temporal.

Para superar essa limitação sugere-se a estudos futuros executar a previsão de vários horizontes de previsão (1, 2, 4, 5, 6, 7, 8, 9, 10, 11 e 12 meses à frente) e para essas predições utilizar um amplo número de séries temporais (no mínimo dez) para constatar o nível de generalização dos resultados verificados.

Referências

AGÊNCIA Brasil. Petrobras: produção de petróleo e gás atinge 2,77 milhões de barris por dia. **Governo do Brasil**, 15 Nov. 2017. Disponível em: < <https://goo.gl/tkaMBi> >. Acesso em: 15 Nov. 2017.

AGÊNCIA Petrobras. Setor de petróleo e gás chega a 13% do PIB brasileiro. **Governo do Brasil**, 17 Jun. 2014. Disponível em: < <https://goo.gl/WsbJnL> >. Acesso em: 20 Out. 2017.

ALVAREZ-RAMIREZ, Jose et al. Symmetry/anti-symmetry phase transitions in crude oil markets. **Physica A: Statistical Mechanics and its Applications**, v. 322, p. 583-596, 2003.

BANCO CENTRAL DO BRASIL. Séries Temporais: Sistema Gerenciador de Séries Temporais – (SGS). Disponível em: < <https://goo.gl/3WyeEa> >. Acesso em: 11 Dez. 2017b.

BANCO CENTRAL DO BRASIL. Sistema Gerenciador de Séries Temporais – v2.1: consultar séries. Disponível em: < <https://goo.gl/MXPZ01> >. Acesso em: 11 Dez. 2017.

BONETT, Douglas G.; SEIER, Edith. Statistical inference for a ratio of dispersions using paired samples. **Journal of Educational and Behavioral Statistics**, v. 28, n. 1, p. 21-30, 2003.

BRANDON, Charles; JARRETT, Jeffrey E.; KHUMAWALA, Saleha B. A comparative study of the forecasting accuracy of Holt-Winters and economic indicator models of earnings per share for financial decision making. **Managerial Finance**, v. 13, n. 2, p. 10-15, 1987.

CHATFIELD, Chris. The holt-winters forecasting procedure. **Applied Statistics**, p. 264-279, 1978.

CHATFIELD, Chris; YAR, Mohammad. Holt-Winters forecasting: some practical issues. **The Statistician**, p. 129-140, 1988.

FLORES, Benito E. A pragmatic view of accuracy measurement in forecasting. **Omega**, v. 14, n. 2, p. 93-98, 1986.

FRAUSTO-SOLÍS, Juan; CHI-CHIM, Manuel; SHEREMETOV, Leonid. Forecasting Oil Production Time Series with a Population-Based Simulated Annealing Method. **Arabian Journal for Science & Engineering (Springer Science & Business Media BV)**, v. 40, n. 4, 2015.

HAIDER, Adnan; HANIF, Muhammad Nadeem. Inflation forecasting in Pakistan using artificial neural networks. **Pakistan economic and social review**, p. 123-138, 2009.

HYNDMAN, Rob J. et al. Package ‘forecast’. Online, 2017. Disponível em: < <https://goo.gl/fudgPo> > Acesso em: 01 Jul. 2017.

HYNDMAN, Rob J. et al. **Automatic time series for forecasting: the forecast package for R**. Monash University, Department of Econometrics and Business Statistics, 2007.

HYNDMAN, Rob J. *forecast: Forecasting functions for time series and linear models*. R package version 8.2, 2017. Disponível em: < <https://goo.gl/nykh6h> > Acesso em: 01 Nov. 2017.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. Seção 1/6. OTexts, 2013. Disponível em: < <https://goo.gl/AESyxR> > Acesso em: 01 Jul. 2017.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. Seção 9/3. OTexts, 2013. Disponível em: < <https://goo.gl/QUJ4FB> > Acesso em: 30 Jun. 2017.

HYNDMAN, Rob J.; KHANDAKAR, Yeasmin. Automatic time series forecasting: the forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, p. 1–22, 2008.

KOUTROUMANIDIS, Theodoros; IOANNOU, Konstantinos; ARABATZIS, Garyfallos. Predicting fuelwood prices in Greece with the use of ARIMA models, artificial neural networks and a hybrid ARIMA–ANN model. **Energy Policy**, v. 37, n. 9, p. 3627-3634, 2009.

LAW, Rob. Back-propagation learning in improving the accuracy of neural network-based tourism demand forecasting. **Tourism Management**, v. 21, n. 4, p. 331-340, 2000.

LEWIS, Colin David. Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting. **Butterworth-Heinemann**, 1982.

LI, X.; CHAN, C. W.; NGUYEN, H. H. Application of the Neural Decision Tree approach for prediction of petroleum production. **Journal of Petroleum Science and Engineering**, v. 104, p. 11-16, 2013.

MAKRIDAKIS, Spyros. A survey of time series. **International Statistical Review/Revue Internationale de Statistique**, p. 29-70, 1976.

MAKRIDAKIS, Spyros. Accuracy measures: theoretical and practical concerns. **International Journal of Forecasting**, v. 9, n. 4, p. 527-529, 1993.

MEDEL, Carlos A. How Informative are In-sample Information Criteria to Forecasting?: The Case of Chilean GDP. **Latin American Journal of Economics**, v. 50, n. 1, p. 133-161, 2013.

MIN, Jennifer CH. Forecasting Japanese tourism demand in Taiwan using an intervention analysis. **International Journal of Culture, Tourism and Hospitality Research**, v. 2, n. 3, p. 197-216, 2008.

NEWBOLD, Paul; GRANGER, Clive WJ. Experience with forecasting univariate time series and the combination of forecasts. **Journal of the Royal Statistical Society. Series A (General)**, p. 131-165, 1974.

NGUYEN, Hanh H.; CHAN, Christine W. Applications of data analysis techniques for oil production prediction. **Engineering Applications of Artificial Intelligence**, v. 18, n. 5, p. 549-558, 2005.

PALMER, Alfonso; MONTANO, Juan Jose; SESÉ, Albert. Designing an artificial neural network for forecasting tourism time series. **Tourism Management**, v. 27, n. 5, p. 781-790, 2006.

SEHGAL, Neha; PANDEY, Krishan K. Artificial intelligence methods for oil price forecasting: a review and evaluation. **Energy Systems**, v. 6, n. 4, p. 479-506, 2015.

SHEREMETOV, L. et al. Data-driven forecasting of naturally fractured reservoirs based on nonlinear autoregressive neural networks with exogenous input. **Journal of Petroleum Science and Engineering**, v. 123, p. 106-119, 2014.

SILVER, Mick. **Estatística para administração**. Atlas, 2000.

STEVENSON, William J. **Estatística aplicada à administração**. 1. ed. São Paulo: Harper & Row do Brasil, 1981.

SZOPLIK, Jolanta. Forecasting of natural gas consumption with artificial neural networks. **Energy**, v. 85, p. 208-220, 2015.

THOMPSON, Patrick A. An MSE statistic for comparing forecast accuracy across series. **International Journal of Forecasting**, v. 6, n. 2, p. 219-227, 1990.

VERLEGER, P. K. **Adjusting to Volatile Energy Prices**. Institute for International Economics. Washington DC: USA, 1993.

XIE, Wen et al. A new method for crude oil price forecasting based on support vector machines. **Computational Science-ICCS 2006**, p. 444-451, 2006.

YU, Lean; WANG, Shouyang; LAI, Kin Keung. Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm. **Energy Economics**, v. 30, n. 5, p. 2623-2635, 2008.

YUSOF, Nazuha Muda; RASHID, Ruzaidah Sulong A.; MOHAMED, Zamzulani. Malaysia crude oil production estimation: an application of ARIMA model. In: **Science and Social Research (CSSR), 2010 International Conference on**. IEEE, 2010. p. 1255-1259.