



Interdisciplinary

LINKSCIENCEPLACE

DOI: 10.17115

ISSN: 2358-8411

Scientific Journal



Interdisciplinary Scientific Journal. ISSN: 2358-8411

Nº 4, volume 4, article nº 14, October/December 2017

D.O.I: <http://dx.doi.org/10.17115/2358-8411/v4n4a14>

Accepted: 18/05/2017 Published: 30/12/2017

A COMPARISON OF ARTIFICIAL NEURAL NETWORKS AND TRADITIONAL TIME SERIES MODELS: A PREDICTION OF THE OIL PRICE

UM COMPARATIVO DE REDES NEURAIS ARTIFICIAIS E MODELOS TRADICIONAIS DE SÉRIES TEMPORAIS: UMA PREVISÃO DO PREÇO DO PETRÓLEO

Fabricio Freitas da Silva¹

Mestrando em Engenharia de Produção

Fábio Freitas da Silva²

Doutorando em Planejamento Regional e Gestão da Cidade

Italo de Oliveira Matias³

Doutor em Engenharia Civil

Claudio Luiz Melo de Souza⁴

Doutor em Produção Vegetal

Abstract: The oil price has strong influence on the global economy, affecting several economic and energy sectors. Therefore, the objective of this work was to estimate oil prices in daily and weekly periods. For this, Artificial Neural Networks (ANNs) and traditional prediction models applied Computational Intelligence. The ANNs is an appropriate nonlinear technique for predicting complex markets. The results were compared with two models, simple moving average (MMS) and exponential smoothing (SE). The approach by Artificial Neural Networks presented an average absolute error, smaller than the other techniques used. In addition, it was observed that this method allows using different variables to make future forecasts, for example, to carry out a certain forecast economic, environmental and demographic indicators can be considered.

Keywords: Oil price; Neural Networks; forecast.

¹ Universidade Candido Mendes, Campos dos Goytacazes-RJ, f.freitassilva.br@gmail.com

² Universidade Candido Mendes, Campos dos Goytacazes-RJ, fabio_freitassilva@hotmail.com

³ Universidade Candido Mendes, Campos dos Goytacazes-RJ, italo@ucam-campos.br

⁴ Universidade Candido Mendes, Campos dos Goytacazes-RJ, claudiomelo.edu@gmail.com

Resumo: O preço do petróleo tem grande influência sobre a economia global, afetando vários setores econômicos e energéticos. Portanto, o objetivo deste trabalho foi realizar uma estimativa do preço do petróleo nos períodos diário e semanal. Para isso, utilizou-se a Inteligência Computacional por meio do uso das Redes Neurais Artificiais (RNAs) e modelos tradicionais de previsão. A RNA é uma técnica não linear adequada para previsão de mercados complexos. Os resultados foram comparados com dois modelos, média móvel simples (MMS) e suavização exponencial (SE). A abordagem por Redes Neurais Artificiais apresentou um erro absoluto médio, menor do que as outras técnicas utilizadas. Além disso, foi observado que este método possibilita o uso de diferentes variáveis para realizar previsões futuras, por exemplo, para realizar uma determinada previsão, podem ser considerados indicadores econômicos, ambientais e demográficos.

Palavras-chave: Preço do Petróleo; Redes Neurais Previsão

INTRODUÇÃO

O preço do petróleo é um fator-chave que afeta as decisões políticas e os planos governamentais, devido à importante função do petróleo na economia global como fonte de energia (Jammazi & Aloui, 2012). Além disso, o seu preço é sensível a mudanças nas condições econômicas e políticas, justamente por essa mercadoria ser uma commodity (Adrangi et al., 2001), sendo intensamente influenciado por fatores, tais como: atividades no mercado de ações, níveis de estoque, taxa de câmbio e condições climáticas (Bernabe et al., 2004). O preço desta commodity também influencia o desenvolvimento econômico de países importadores e exportadores, bem como afeta direta ou indiretamente outros mercados (Godarzi et al., 2014), sendo, assim, de grande relevância para a estabilidade e projeções de crescimento da economia mundial (Abosedra & Baghestani, 2004). Portanto, uma percepção do possível comportamento futuro dos preços do petróleo pode diminuir a vulnerabilidade da economia a partir das variações e mudanças nas condições do seu mercado (Godarzi et al., 2014).

Segundo Mingming e Jinliang (2012), os principais métodos de previsão de demanda para o preço do óleo são quantitativos, dentre os quais a maioria segue princípios lineares. Na realidade, os preços do petróleo são séries de tempos com características muito complexa e não lineares (Herrera et al., 2011; Hamilton, 2011; Mingming & Jinliang, 2012; Yang et al., 2002). Como alternativa ao uso dos modelos lineares, as redes neurais artificiais podem ser usadas para predição e classificação. As redes neurais artificiais (RNAs) são amplamente utilizadas para o controle de

sistemas dinâmicos não lineares, dada a capacidade de aproximação universal dos modelos neurais. A RNA é uma importante técnica não linear capaz de resolver múltiplos problemas complexos (Mulero et al., 2017), sendo modelos úteis em contextos nos quais não é possível atribuir precisamente um conjunto de regras. Usualmente, isso acontece em um ambiente dinâmico, onde as variáveis mudam constantemente. As RNAs têm sido muito utilizadas para predição e modelagens não lineares (Azadeh et al., 2008).

Nesse contexto, o objetivo do trabalho foi utilizar o método de Redes Neurais Artificiais (RNAs) para realizar a predição do preço do petróleo em diferentes períodos, além de compará-lo com outras técnicas de previsão.

2. REDE NEURAL ARTIFICIAL

A RNA é uma técnica computacional que tenta simular a maneira de aprendizagem de um cérebro humano (Law, 2000). Um neurônio biológico recebe as informações de entrada por uma fonte externa, combina-as com operações não lineares e produz um resultado com base no conhecimento assimilado (Godarzi et al., 2014). De forma semelhante, o neurônio artificial comunica-se por meio de extenso número de ligações formando uma rede ponderada na qual os sinais de entrada são enviados para outros neurônios. Os neurônios são variáveis de processadores interligados, operando em paralelo para executar uma determinada função (Kankal et al., 2011). Os neurônios são organizados em uma estrutura de redes formada por camadas contendo um número definido de neurônios. Na modelagem, é utilizado o processo de aprendizagem por treinamento (Mulero et al., 2017). A RNA consiste em extrair informações de um banco de dados de variáveis contínuas e categóricas para identificar padrões entre elementos de entrada e um elemento de interesse (Cosenza et al., 2017).

Uma das principais arquiteturas das RNAs comumente utilizadas em aplicações de engenharia é a Perceptron Multi-Camadas (MLP) (Aguilar et al., 2016; Kankal et al., 2011). A arquitetura do tipo MLP é utilizada para resolução de vários problemas do tipo não lineares. O modelo MLP constitui conjuntos de unidades sensoriais que estabelecem uma camada de entrada, uma ou mais camadas intermediárias (camadas ocultas) e camada de saída (Cosenza et al., 2017; Mulero et al., 2017). A camada de entrada funciona como fonte de informação para

camadas subsequentes. Nestas camadas, as variáveis contínuas são representadas por um único nó. As variáveis categóricas são convertidas em variáveis binárias, sendo cada categoria representada por um nó. A camada intermediária irá processar as informações por meio da função de ativação de cada nó. As funções, geralmente não-lineares, normalizam a soma dos valores iniciais. Estes valores são multiplicados por seus respectivos pesos e transmitem esse novo sinal até a última camada. Por fim, a camada de saída processa as informações novamente e gera a saída, que pode ser quantitativa ou qualitativa. Os sinais são propagados da entrada para a saída pela rede assumindo uma relação positiva. O treinamento do MLP utiliza um algoritmo de aprendizagem chamado retro-propagação do erro, que consiste em “corrigir” os erros durante o treinamento (Haykin, 1994). Para uma RNA ser utilizada, é preciso de um conjunto de treinamento e um conjunto de teste. Os dois conjuntos de treinamento e teste utilizam informações de entrada e saídas, geradas mediante dados reais. A camada de entrada é usada para o treinamento da rede e a segunda camada, para avaliar o funcionamento da rede. No procedimento de teste, os dados de entrada fomentam a rede e os padrões de saída são comparados com os obtidos por meio da rede neural. A aceitação, ou não, destes dois conjuntos dá uma indicação do desempenho da rede neural (Lek & Guégan, 1999).

Nas décadas recentes, houve um grande interesse dos pesquisadores pelo uso da RNA, principalmente por ser uma abordagem não linear, dada a sua capacidade de aproximar ou prever não linearidades, entre entradas e saídas de qualquer problema complexo. Para predição ou aproximação, é usado um algoritmo de aprendizagem com uma assistência de um conjunto de dados de treinamento. A RNA pode ser usada em situações em que há informações imprecisas. As redes neurais apresentam alta capacidade de aproximação, sendo ferramentas adequadas quando a relação entre entradas e saídas não é precisa (Yaman et al., 2017).

2.1 REDES NEURAS APLICADAS A PREVISÃO

As RNAs são utilizadas em diversas áreas do conhecimento e, como técnica de predição de demanda, tem sido bastante aplicada em vários setores (Khashei & Bijari, 2010). Segundo Akdeniz et al. (2018), a RNA vem sendo usada na literatura para previsão de séries temporais não lineares. Suganthi e Samuel (2012)

identificaram várias aplicações de métodos de previsão de demanda relacionadas ao consumo energético e observaram o uso das redes neurais para as seguintes previsões: carga elétrica; projeções de demanda de energia considerando variáveis macroeconômicas; consumo de energias verdes no mundo; dependência energética; consumo de óleo e gás natural; e o preço da energia elétrica. Pode-se mencionar, por exemplo, o trabalho de Sozen e Arcaklioglu (2007) em que diferentes modelos de RNAs foram usados para estimar o consumo energético na Turquia, os quais levam em consideração indicadores, como, capacidade instalada, exportação e importação de energia, PIB e PNB. Sozen (2009) determina a dependência energética da Turquia usando dados históricos do consumo de energia e métricas básicas em uma Rede Neural Artificial (RNA). Gorucu (2004) utiliza redes neurais para estimar o consumo de gás em Ankara. O autor ainda considera dois cenários, sendo um pessimista e o outro otimista em relação à economia. Outra área de utilização de redes neurais é na previsão de demanda para o turismo. Song e Gang (2008) identificaram o uso de RNAs como um dos métodos utilizados para a previsão de demanda turística. Palmer et al. (2006) desenvolveram uma metodologia para a criação de redes neurais com a intenção de prever séries temporais no turismo. Para ilustrar esse processo, os autores estimam as despesas do turismo nas Ilhas Baleares na Espanha.

Em pesquisas mais recentes, encontram-se trabalhos como os de Raza et al. (2016), os quais observaram, em uma revisão abrangente e sistemática de modelos aplicados à previsão de potências de saída de sistemas fotovoltaicos, que as RNAs apresentaram melhor desempenho nas aproximações não lineares e na capacidade de lidar com a incerteza. Marjanović et al. (2016) empregaram RNAs e programação genética para prever o PIB com base nas emissões de CO₂ e os resultados mostraram que a técnica de redes neurais teve uma melhor precisão.

Silva et al. (2017) avaliaram o efeito das RNAs em comparação com modelos lineares na previsão de resistência à ferrugem em café arábica. A RNA apresentou a taxa de erro de previsão inferior a (1,60%) enquanto que os modelos lineares generalizados sob o enfoque bayesiano, uma taxa de (2,4%). A RNA mostrou uma abordagem promissora para prever a resistência à ferrugem em café arábica. Pinheiro e Senna (2017) utilizaram análise multivariada e redes neurais para previsão de preços no mercado agrícola brasileiro.

3. PROCEDIMENTOS METODOLÓGICOS

3.1 DADOS

Os dados históricos foram coletados mediante a plataforma gratuita para negociação no mercado financeiro, a *MetaTrader 4* (MT4). Os períodos de análise foram escolhidos de forma aleatória com o objetivo de avaliar a eficácia dos modelos. A variação do preço do petróleo foi analisada em dois períodos diferentes: diário (16.08.2012 – 15.08.2016) e semanal (11.04.2010 – 07.08.2016). Esses dados foram usados em sua forma padrão para as técnicas tradicionais, enquanto que, para a RNA, o mesmo conjunto de valores foi normalizado dentro de um intervalo de [0, 1], conforme a equação abaixo:

$$Z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (1)$$

em que Z_i - valor normalizado; x_i - valor bruto; $\min(x)$ - valor mínimo de todo conjunto de dados; e $\max(x)$ - valor máximo de todo conjunto de dados.

3.2 TÉCNICAS DE PREVISÃO

3.2.1 REDE NEURAL ARTIFICIAL

Foi utilizada a rede Perceptron Multi-Camadas (MLP) com a técnica de treinamento *back-propagation* para realizar a previsão. Por convenção, o conjunto de treinamento é dividido em 80% ou 90% e o conjunto de teste, em 20% ou 10% (Kulkarni & Haidar, 2009; Yu et al. 2010). O padrão adotado neste artigo foi o de 80% dos dados de entrada para o treinamento e os 20% restantes, para o teste. Os parâmetros de configuração da rede foram os seguintes: taxa de aprendizado de 0,7; e condição de parada quando o erro desejado atingir valores abaixo de 0,0001. Segundo Zain et al. (2010), o nível de precisão da predição na RNAs é determinado pelo número de camadas e neurônios. A Tabela 1 mostra diferentes estruturas testadas para o modelo de previsão.

Tabela 1 - Diferentes especificações para MLP

MLP número do modelo	1	2	3	4	5
Número de neurônios na camada de entrada	10	10	10	10	10
Número de neurônios na camada oculta (m)	4	4	4	3	15
Número de neurônios na segunda camada oculta (n)	6	2	0	0	0
Número de neurônios na camada de saída	1	1	1	1	1

A Figura 1 mostra a estrutura da rede especificada na Tabela 1. Independente do modelo MPL, foram utilizados dez valores anteriores ($t_{n-1}, t_{n-2}, \dots, t_{n-10}$) do histórico de dados para prever um valor à frente (t_n).

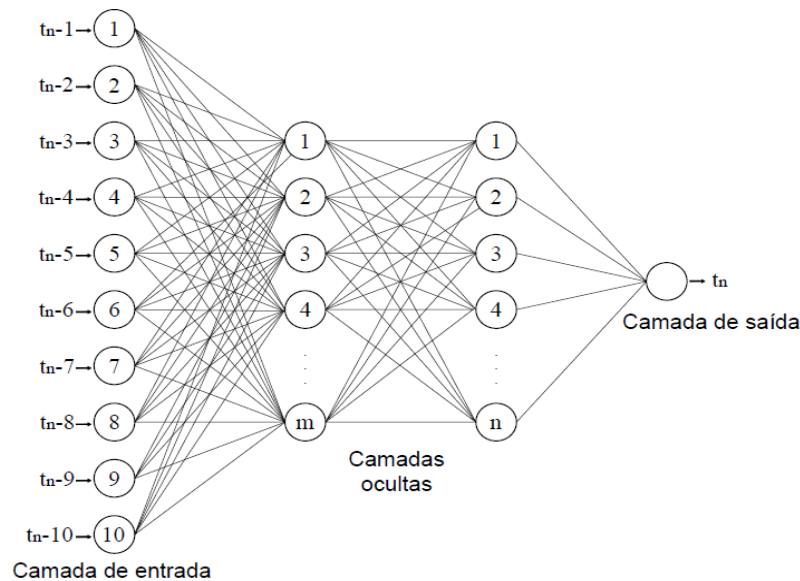


Figura 1: Estrutura da rede para previsão.

3.2.2 MODELOS LINEARES

As técnicas utilizadas para comparação com a RNA foram de média móvel simples (MMS) e de suavização exponencial (SE). A escolha destes métodos é derivada da utilização desses modelos tradicionais no mercado financeiro. As equações a seguir mostram o procedimento de cálculo desses métodos.

SE (2)

$$\hat{z}_{t+1} = \alpha z_t + (1 - \alpha) \hat{z}_t$$

MMS (3)

$$\hat{z}_{t+1} = \frac{z_t + z_{t-1} + z_{t-2} + \dots + z_{t-n+1}}{n}$$

em que \hat{z}_{t+1} - previsão para o período $t+1$; α - constante de suavização, $\alpha \in [0;1]$, valor adotado 0,2; z_t - valor real observado; \hat{z}_t - previsão feita para o tempo t ; n - número de observações, valor utilizado 10.

3.2 MODELOS DE PRECISÃO

Para avaliar o desempenho dos métodos de previsão, foram utilizadas as seguintes métricas comumente aplicadas na avaliação de séries temporais: erro percentual absoluto médio (MAPE); desvio absoluto médio (MAD); e desvio quadrado médio (MSD). Esses métodos são importantes para verificar um bom ajuste dos dados. As equações a seguir mostram a fórmula de cálculo dessas métricas.

MAPE (4)

$$\frac{\sum_{t=1}^n |y_t - \hat{y}_t| / y_t}{n}$$

MAD (5)

$$\frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n}$$

MSD (6)

$$\frac{\sum_{t=1}^n |y_t - \hat{y}_t|^2}{n}$$

em que y_t - valor real; \hat{y}_t - valor previsto; n - número de observações.

O MAPE representa a acurácia do erro em porcentagem, quanto menor o MAPE melhor os ajustes dos dados. O MAD apresenta o desvio padrão em relação aos valores observados. O MSD é uma medida muito utilizada quando há *outliers* nos conjuntos de dados.

4. RESULTADOS E DISCUSSÕES

Para prever o preço do barril de petróleo, foram utilizadas várias redes MPL; a Tabela 1 mostra esses modelos de rede. A melhor estrutura encontrada, número 5, corrobora com a proposta por Movagharnejad et al. (2011), com 15 neurônios na camada oculta, pois mostrou uma melhor precisão para os valores estimados, com um MAPE de 3,00%, enquanto que, para as outras séries temporais, esse erro foi de 3,69% e de 4,22%, respectivamente, para os métodos SE e MMS. Os valores previstos pelos modelos propostos foram comparados com os respectivos valores reais e são apresentados na Figura 2. Nota-se, nesta Figura, que todos os métodos seguem próximos aos valores reais, porém a predição feita pela técnica de RNA

acompanha um comportamento semelhante ao Real, em que suas curvas não são suavizadas, ou seja, se adere melhor à dinâmica do mercado.

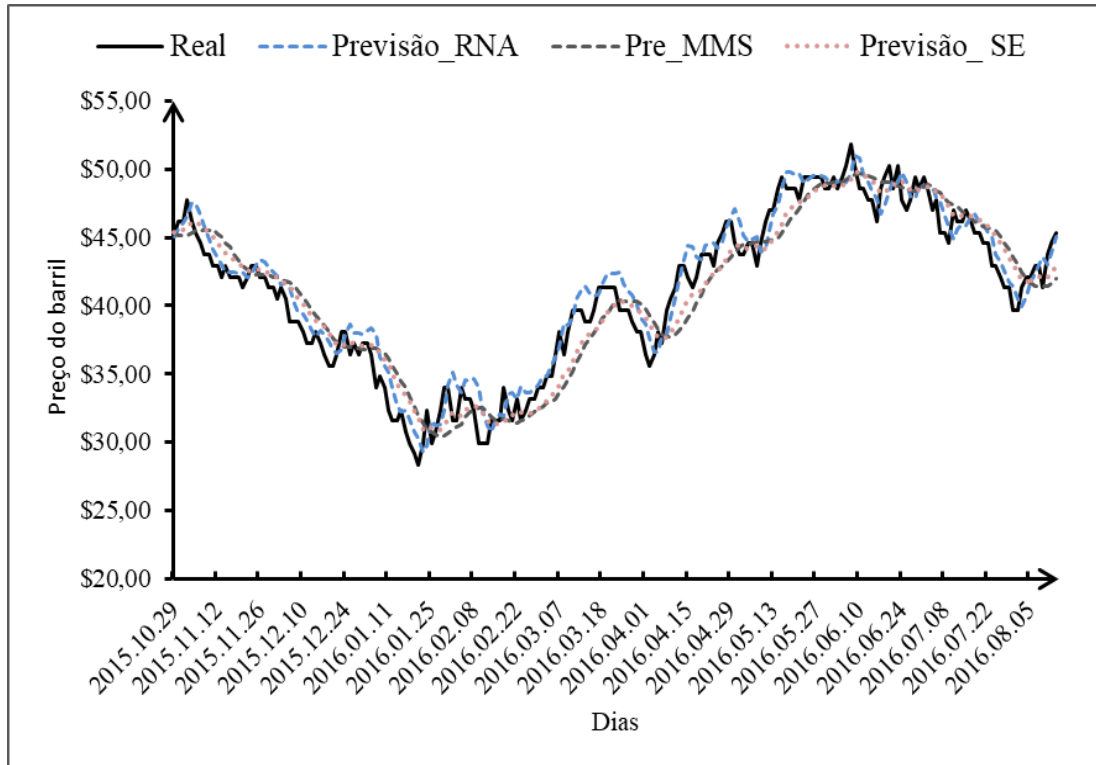


Figura 2: Comparação entre a previsão e o valor real (diário) para os métodos de RNA, MMS e SE.

Analogamente, foi realizado o mesmo procedimento para a previsão semanal do preço do petróleo. O modelo da rede MPL número 5 ainda continuou sendo o melhor. A Figura 3 exibe o gráfico comparativo entre os valores reais e os previstos. O comportamento foi diferente do anterior; neste caso, o método SE apresentou uma melhor previsão, com MAPE de 8,55%, já os de RNA e de MMS geraram um erro de 8,94% e de 9,83%. Logo, a técnica SE obteve um melhor resultado no período semanal, contudo, isso ocorreu devido à pouca quantidade de dados históricos disponível para esse período. Segundo Lek e Guégan (1999), o conjunto de treinamento tem que ser amplo o suficiente para representar o problema. Nota-se que a quantidade de exemplos para o processo de aprendizagem da RNA foi de 829, no diário e de 258, no semanal. Assim, a capacidade da rede foi comprometida, não conseguindo absorver a dinâmica do mercado.

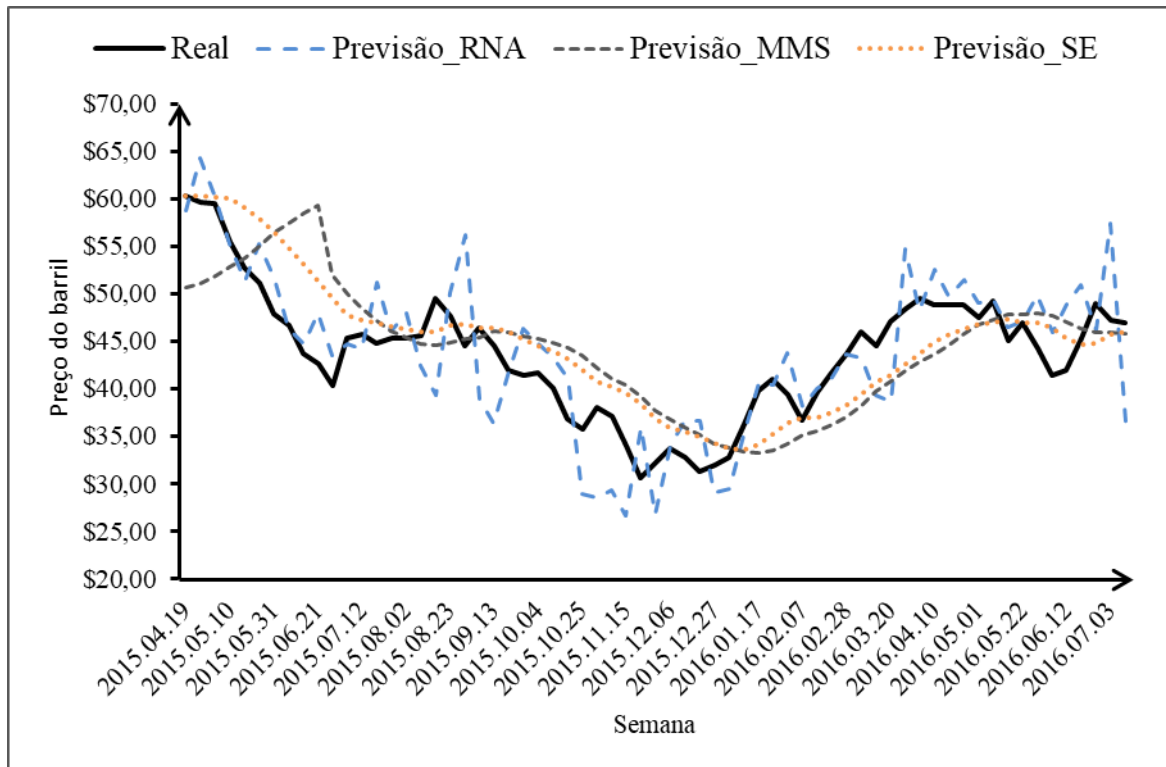


Figura 3: Comparação entre a previsão e o valor real (semanal) para os métodos de RNA, MMS e SE.

4.1 MEDIDAS DE PRECISÃO

As medidas de precisão utilizadas para avaliar os métodos podem ser observadas na Tabela 2. Nesta Tabela, para cada método, existem três indicadores de precisão relacionados ao intervalo diário e semanal. Como já citado, o método de RNA teve melhor desempenho na previsão diária do preço do petróleo; nesse intervalo de tempo, o MAPE foi de 3,00%, e o MAD e o MSD, com 1,18 e 2,01 respectivamente, enquanto os outros métodos apresentaram valores superiores para todas as métricas, ou seja, uma menor precisão. No período semanal, a técnica que obteve uma maior precisão foi a de SE, com um MAPE 8,55%, e o MAD e o MSD, com 3,59 e 18,91, respectivamente, sendo mais adequados do que as de RNA e MMS.

Tabela 2 – Comparação das medidas de precisão para as técnicas de predição.

Período	Método	MAPE	MAD	MSD
Diário	RNA	3,00%	1,18	2,01
	MMS	4,22%	1,66	4,07
	SE	3,67%	1,45	3,00
Semanal	RNA	8,94%	3,76	23,20
	MMS	9,83%	4,00	21,96

SE	8,55%	3,59	18,91
----	-------	------	-------

Além dos métodos de comparação, foi realizado um agrupamento dos erros da previsão, em que os mesmos foram agrupados dentro de intervalos de erro, conforme pode ser visto na Figura 4. Do lado direito da Figura 4, encontram-se as técnicas de previsão utilizadas; nota-se que elas estão alinhadas horizontalmente. Na parte inferior, estão localizados os intervalos contendo as margens de erros percentuais; também estão indicados os períodos.




Figura 4: Margem de erro das previsões agrupadas em intervalos

A análise da Figura 4 pode ser feita da seguinte maneira: do total de previsões realizadas, no período diário, pelos métodos SE, MMS e RNA, respectivamente, 51%, 48% e 65% das estimativas estão localizadas dentro de um intervalo de erro de 0% a 3%. No período semanal, houve uma alta ocorrência de erros de previsão, por isso há um maior conjunto de intervalos. Assim, para as técnicas SE, MMS e RNA, respectivamente, 38%, 45% e 34% das previsões possuem um desvio entre 0 e 6%. Este tipo de avaliação auxilia a identificação das concentrações dos erros, pois fornece os padrões de agrupamentos deles.

5. CONCLUSÕES

O objetivo do trabalho foi utilizar RNA para prever o provável comportamento do preço futuro do petróleo em duas janelas de tempo. A fim de analisar a robustez do modelo, este foi comparado com dois métodos tradicionais de previsão de séries temporais, média móvel simples (MMS) e suavização exponencial (SE). Os resultados mostraram que a técnica de redes neurais teve uma melhor precisão na modelagem dos valores diários, com um MAPE de 3,00%, enquanto que, na

modelagem dos valores semanais, a técnica de suavização exponencial obteve um desempenho melhor, com um MAPE de 8,55%, do que a técnica de redes neurais. Contudo, isso ocorreu devido a poucos dados históricos disponíveis nesse período. Desta forma, o e aprendizado da RNA foi comprometido. Segundo Lek e Guégan (1999), o conjunto de treinamento tem que ser amplo o suficiente para representar o problema.

Portanto a RNA mostrou-se adequada para prever as flutuações do preço diário do petróleo, por exemplo, o preço real no dia 15/08/2015 foi de US \$ 45,65 / barril e o previsto pela RNA foi de US \$ 45,09 / barril. O comportamento do preço do petróleo segue uma estrutura não linear. Segundo Akdeniz et al. (2018), a RNA é frequentemente utilizada para análises de previsões de séries temporais não lineares.

Este estudo também mostrou algumas aplicações e abordagens de redes neurais para previsão de demanda. Nessa análise, foi observado que, além dos padrões históricos tradicionais para determinar a previsão futura, está técnica permite englobar vários indicadores ao mesmo tempo, tais como, econômicos, demográficos e ambientais. Desta maneira, este padrão possibilita uma melhor aproximação com a realidade e a dinâmica do mercado.

REFERÊNCIAS

- Abosedra, S., & Baghestani, H. (2004). On the predictive accuracy of crude oil futures prices. *Energy policy*, 32(12), 1389-1393.
- Adrangi, B., Chatrath, A., Dhanda, K. K., & Raffiee, K. (2001). Chaos in oil prices? Evidence from futures markets. *Energy Economics*, 23(4), 405-425.
- Aguiar, L. M., Pereira, B., Lauret, P., Díaz, F., & David, M. (2016). Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. *Renewable Energy*, 97, 599-610.
- Akdeniz, E., Egrioglu, E., Bas, E., & Yolcu, U. (2018). An ARMA Type Pi-Sigma Artificial Neural Network for Nonlinear Time Series Forecasting. *Journal of Artificial Intelligence and Soft Computing Research*, 8(2), 121-132.
- Azadeh, A., Ghaderi, S. F., & Sohrabkhani, S. (2008). A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran. *Energy Policy*, 36(7), 2637-2644.

- Bernabe, A., Martina, E., Alvarez-Ramirez, J., & Ibarra-Valdez, C. (2004). A multi-model approach for describing crude oil price dynamics. *Physica A: Statistical Mechanics and its Applications*, 338(3), 567-584.
- Cosenza, D. N., Soares, A. A. V., Alcântara, A. E. M. D., Silva, A. A. L. D., Rode, R., Soares, V. P., & Leite, H. G. (2017). Site classification for eucalypt stands using Artificial Neural Network based on environmental and management features. *CERNE*, 23(3), 310-320.
- Godarzi, A. A., Amiri, R. M., Talaei, A., & Jamasb, T. (2014). Predicting oil price movements: A dynamic Artificial Neural Network approach. *Energy Policy*, 68, 371-382.
- Gorucu, F. B. (2004). Artificial neural network modeling for forecasting gas consumption. *Energy Sources*, 26(3), 299-307.
- Hamilton, J.D. (2011). Nonlinearities and the macroeconomic effects of oil prices. *Macroeconomic dynamics*, 15(3), 364-378.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- Herrera, A. M., Lagalo, L. G., & Wada, T. (2011). Oil price shocks and industrial production: Is the relationship linear? *Macroeconomic Dynamics*, 15(S3), 472-497.
- Jammazi, R., & Aloui, C. (2012). Crude oil price forecasting: Experimental evidence from wavelet decomposition and neural network modeling. *Energy Economics*, 34(3), 828-841.
- Kankal, M., Akpınar, A., Kömürcü, M. İ., & Özşahin, T. Ş. (2011). Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Applied Energy*, 88(5), 1927-1939.
- Khashei, M., & Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with applications*, 37(1), 479-489.
- Kulkarni, S., & Haidar, I. (2009). Forecasting model for crude oil price using artificial neural networks and commodity futures prices. *arXiv preprint arXiv:0906.4838*.
- Law, R. (2000). Back-propagation learning in improving the accuracy of neural network-based tourism demand forecasting. *Tourism Management*, 21(4), 331-340.
- Lek, S., & Guégan, J. F. (1999). Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological modelling*, 120(2), 65-73.
- Marjanović, V., Milovančević, M., & Mladenović, I. (2016). Prediction of GDP growth rate based on carbon dioxide (CO₂) emissions. *Journal of CO₂ Utilization*, 16, 212-217.
- Mingming, T., & Jinliang, Z. (2012). A multiple adaptive wavelet recurrent neural network model to analyze crude oil prices. *Journal of Economics and Business*, 64(4), 275-286.

- Movagharnejad, K., Mehdizadeh, B., Banihashemi, M., & Kordkheili, M. S. (2011). Forecasting the differences between various commercial oil prices in the Persian Gulf region by neural network. *Energy*, 36(7), 3979-3984.
- Mulero, Á., Pierantozzi, M., Cachadiña, I., & Di Nicola, G. (2017). An Artificial Neural Network for the surface tension of alcohols. *Fluid Phase Equilibria*, 449, 28-40
- Palmer, A., Montano, J. J., & Sesé, A. (2006). Designing an artificial neural network for forecasting tourism time series. *Tourism Management*, 27(5), 781-790.
- Pinheiro, C. A. O., & Senna, V. D. (2017). Multivariate analysis and neural networks application to price forecasting in the Brazilian agricultural market. *Ciência Rural*, 47(1). 1-7
- Raza, M. Q., Nadarajah, M., & Ekanayake, C. (2016). On recent advances in PV output power forecast. *Solar Energy*, 136, 125-144.
- Silva, G. N., Nascimento, M., Sant'Anna, I. D. C., Cruz, C. D., Caixeta, E. T., Carneiro, P. C. S., ... & Oliveira, M. D. S. (2017). Artificial neural networks compared with Bayesian generalized linear regression for leaf rust resistance prediction in Arabica coffee. *Pesquisa Agropecuária Brasileira*, 52(3), 186-193.
- Song, H., & Li, G. (2008). Tourism demand modelling and forecasting - A review of recent research. *Tourism management*, 29(2), 203-220.
- Sözen, A. (2009). Future projection of the energy dependency of Turkey using artificial neural network. *Energy policy*, 37(11), 4827-4833.
- Sözen, A., & Arcaklioglu, E. (2007). Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey. *Energy policy*, 35(10), 4981-4992.
- Suganthi, L., & Samuel, A. A. (2012). Energy models for demand forecasting—A review. *Renewable and sustainable energy reviews*, 16(2), 1223-1240.
- Yaman, M. A., Elaty, M. A., & Taman, M. (2017). Predicting the ingredients of self compacting concrete using artificial neural network. *Alexandria Engineering Journal*. 56, 523-532
- Yang, C. W., Hwang, M. J., & Huang, B. N. (2002). An analysis of factors affecting price volatility of the US oil market. *Energy economics*, 24(2), 107-119.
- Yu, L., Wang, S., Lai, K. K., & Wen, F. (2010). A multiscale neural network learning paradigm for financial crisis forecasting. *Neurocomputing*, 73(4), 716-725.
- Zain, A. M., Haron, H., & Sharif, S. (2010). Prediction of surface roughness in the end milling machining using Artificial Neural Network. *Expert Systems with Applications*, 37(2), 1755-1768.