

PREVISÃO DE SÉRIES TEMPORAIS POR MEIO DE REDES NEURAIAS

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 trabalho foi gerar previsões e comparar a precisão preditiva no curto prazo de redes neurais perceptron multi-camada (MLP) e máquina de aprendizagem extrema (ELM), na previsão da produção de petróleo. Foram utilizadas três séries temporais do sistema de gerenciamento de séries temporais do Banco Central do Brasil (BCB). Os dados são referentes a produção de gás natural, óleo bruto e petróleo registradas entre janeiro de 2007 a setembro de 2017. Com uso do software R e a extensão R *studio*. As predições da produção abrangeram o intervalo de outubro a dezembro de 2017, sendo então comparadas aos dados reais do mesmo período. As previsões da MLP e ELM foram comparadas por meio dos critérios MAPE e MAD, onde os resultados gerados pelas medidas de erros mostraram que a ELM teve o melhor desempenho individual, MLP e ELM geraram previsões excelentes. Para pesquisas futuras sugerimos análises de previsões de curto, médio e longo prazo fora da amostra.

Palavras-Chave: Petróleo; Perceptron multi-camada.

1. Introdução

As previsões mensais são frequentemente indispensáveis nos negócios em várias linhas de produtos que necessitam de predições (HYNDMAN; KHANDAKAR, 2008). As redes neurais são muito aplicadas como uma opção potencial para previsão de série tempo (FARAWAY; CHATFIELD, 1998; ZHANG; BERARDI, 2001) sendo, assim foi muito usada e obteve sucesso que determinou um papel importante na predição de séries cronológicas (ZHANG; BERARDI, 2001). As séries temporais são formadas de valores observados em vários períodos ordenados e subsequentes (STEVENSON, 1981; KAZMIER, 1982).

A tomada de decisão depende de previsões precisas para não incorrer em mal uso de recursos ou eliminação de oportunidade (KARCHERE, 1976). Assim, a possibilidade de prever os dados futuros através do histórico de dados passados é uma ferramenta interessante para apoiar as decisões individuais e organizacionais (TONG, 2015). Por conseguinte, as previsões servem de apoio a tomada de decisões do que se refere ao planejamento de produção nos níveis operacional, tático e a alta administração da empresa (SAGAERT et al., 2017).

Empresas em diversas indústrias enfrentam um problema de demanda muito flutuante e lidam com essa questão gerando previsões de demanda com base nas informações disponíveis para gerar previsões precisas (MIYAOKA; HAUSMAN, 2008).

Nas últimas décadas, as redes neurais têm sido amplamente usadas como modelos de previsões da demanda turística, financeiras e econômicas onde o seu desempenho de previsão tem obtido altos níveis de acuracidade. Também ocorre aplicação prática das redes neurais na indústria de petróleo (STUNDNER et al., 2001). Em outubro de 2017, a Petrobras produziu 2,77 milhões de barris de petróleo e gás natural (AGÊNCIA BRASIL, 2017). Além disso, a participação da indústria de petróleo e gás natural do Brasil, no Produto Interno Bruto (PIB) aumentou de 3% em 2000 para 13% em 2014 (AGÊNCIA PETROBRAS, 2014).

Diante dessas constatações, o objetivo desta pesquisa foi gerar previsões de curto prazo especificamente num único horizonte de três meses à frente e comparar as previsões, por meio, dos critérios MAPE e MAD. Foram aplicadas as redes neurais perceptron multi-camada (MLP) e máquina de aprendizagem extrema (ELM). No contexto da previsão da produção de petróleo em três séries temporais de produção de derivados de petróleo, Gás natural, barris/dia (milhões), produção de derivados de petróleo, óleo bruto, barris/dia (mil) e produção de derivados de petróleo, total, barris/dia (mil).

2. Base teórica

A seguir apresentam-se, com base na literatura consultada, perceptron multi-camada, algoritmo de aprendizado máquina de aprendizagem extrema e critério de avaliação.

2.1 Perceptron multi-camada (MLP)

Devido ao crescente avanço na computação e disponibilidade de dados às redes neurais são cada vez mais usadas na previsão de diferentes áreas (KOURENTZES, BARROW; CRONE, 2014). Uma rede neural constitui-se em camadas: uma de entrada, uma de saída e, de modo geral uma ou mais camadas escondidas (KAASTRA; BOYD, 1996; LAW, 2000; PALMER, MONTANO; SESÉ, 2006). As redes neurais (NN) classificam-se em modelos de aprendizagem supervisionada e aprendizagem não supervisionada (CLAVERIA; TORRA, 2014). As NN são por vezes aplicadas pela capacidade de mapear todas as funções lineares ou não lineares (WHITE, 1989; ZHANG; BERARDI, 2001; CLAVERIA; TORRA, 2014; FAN, WANG; LI, 2016).

O método de NN perceptron multi-camada (MLP) é a rede neural mais utilizada na previsão de séries temporais (KAASTRA; BOYD, 1996; ZHANG; BERARDI, 2001; CLAVERIA;

TORRA, 2014; FAN, WANG; LI, 2016). Além disso, é eficiente na predição de série de tempo (DE OLIVEIRA, NOBRE; ZÁRATE, 2013). No tipo de arquitetura MLP as observações (dados) são transmitidos da camada de entrada em direção à camada de saída (PALMER, MONTANO; SESÉ, 2006).

Os neurônios dentro de cada camada possuem interligação, por meio, de forças de conexão (pesos) que junto com a arquitetura da NN, acumula o aprendizado de uma rede treinada (KAASTRA; BOYD, 1996). Além de neurônios de processamento existe um neurônio de polarização que faz a conexão de cada unidade de processamento nas camadas ocultas e de saída este neurônio tem um valor positivo e tem a função semelhante à interceptação em métodos de regressão (KAASTRA; BOYD, 1996).

De acordo com Kaastra e Boyd (1996) as formas dos neurônios e do viés são organizadas em camadas: uma de entrada, uma de saída e, geralmente uma ou mais camadas ocultas, neste sentido “O número de camadas escondidas e neurônios dentro de cada camada pode variar de acordo com o tamanho e a natureza do conjunto de dados” (KAASTRA; BOYD, 1996, p. 217). O modelo (MLP) utilizado neste artigo é totalmente automático foi proposto por Kourentzes, Barrow e Crone, 2014, para cumprir o desafio de ter a capacidade de utilizar a rede neural MLP nos dados de séries cronológicas sem a intervenção de um especialista (CRONE; KOURENTZES, 2010).

Modelo de rede de MLP é supervisionada com base em perceptron simples original com a programação traseira que treina a rede, assim o funcionamento básico geralmente ocorre em uma camada de entrada de nós de origem, uma camada de saída e uma ou mais camadas escondidas de neurônios que aumentam a capacidade de aprendizagem do MLP, o número de neurônios ocultos determina o poder de aprender da rede neural (CLAVERIA; TORRA, 2014; FAN, WANG; LI, 2016).

O método MLP é fundamentado em torno de um filtro neural iterativo que combina uma ferramenta gráfica simples de análise da distância euclidiana em parcelas sazonais ano a ano (CRONE; KOURENTZES, 2010). A forma funcional do modelo é exibida na sequência.

$$\hat{y}_{t+1} = \beta_0 + \sum_{h=1}^H \beta_h g \left(\gamma_{0i} + \sum_{i=1}^I \gamma_{hi} p_i \right). \quad (1)$$

Onde, $\boldsymbol{w} = (\boldsymbol{\beta}, \boldsymbol{\gamma})$ ambos são os pesos do modelo MLP com $\boldsymbol{\beta} = [\beta_1, \dots, \beta_H]$, $\boldsymbol{\gamma} = [\gamma_{11}, \dots, \gamma_{HI}]$ para as camadas escondidas e a saída, nessa ordem, β_0 e γ_{0i} são os vieses de

cada neurônio, que para cada neurônio agem de forma semelhante a interceptação em uma regressão, \mathbf{H} é a quantidade de nós escondidos na MLP e $\mathbf{g}(\cdot)$ é uma função de transferência não-linear, que em geral é o sigmoide logístico ou a tangente hiperbólica (KOURENTZES, BARROW; CRONE, 2014). A rede pode modelar interações de entradas, as saídas dos nós escondidos estão em conexão a um nó de saída que gera a predição (KOURENTZES, BARROW; CRONE, 2014).

2.2 Algoritmo de aprendizado Máquina de Aprendizagem Extrema (ELM)

Huang, Zhu e Siew, (2006) propõe um novo algoritmo de aprendizagem para as redes neurais feedforward chamado máquina de aprendizagem extrema. As vantagens são tem uma tendência em alcançar o menor erro de treinamento; obtém a menor norma de pesos e o bom desempenho de generalização e a velocidade de aprendizado pode ser muito mais rápida (HUANG, ZHU; SIEW, 2004).

Para N amostras arbitrárias distintas (\mathbf{x}_i, t_i) , onde $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathcal{R}^n$ e $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathcal{R}^m$, SLFN padrão com \tilde{N} nós ocultos e função de ativação $\mathbf{g}(x)$ são modelados matematicamente como

$$\sum_{i=1}^{\tilde{N}} \beta_i \mathbf{g}_i(\mathbf{x}_j) = \sum_{i=1}^{\tilde{N}} \beta_i \mathbf{g}(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = \mathbf{o}_j, \quad j = 1, \dots, N, \quad (2)$$

Onde $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ é o vetor de peso que liga o i th nó escondido e os nós de entrada, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ é o vetor de peso que liga o i th nó escondido e os nós de saída, e b_i é o limiar do nó oculto i . $\mathbf{w}_i \cdot \mathbf{x}_j$ denota o produto interno de \mathbf{w}_i e \mathbf{x}_j . Que SLFN padrão com \tilde{N} nós ocultos com função de ativação $\mathbf{g}(x)$ pode aproximar estas N amostras com zero erro significa que $\sum_{j=1}^N \|\mathbf{o}_j - t_j\| = 0$, isto é, existe β_i , \mathbf{w}_i e b_i de tal modo que

$$\sum_{i=1}^{\tilde{N}} \beta_i \mathbf{g}(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = t_j, \quad j = 1, \dots, N. \quad (3)$$

Este algoritmo máquina de aprendizagem extrema (ELM) foi utilizado com a rede neural perceptron multi-camada (MLP). Os detalhes sobre o funcionamento do ELM, pode ser visto em Huang, Zhu e Siew, (2006).

2.3 Critério de avaliação

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 *Mean Absolute Percentage Error* (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 medida 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 simples de calcular e simples de compreender (BONETT; SEIER, 2003).

$$MAD = \frac{\sum |R-D|}{n} \quad (4)$$

$$MAPE = \frac{\sum |R-D/R|}{n} \cdot 100, (R \neq 0) \quad (5)$$

Fonte: Adaptado de Moreira (2011)

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

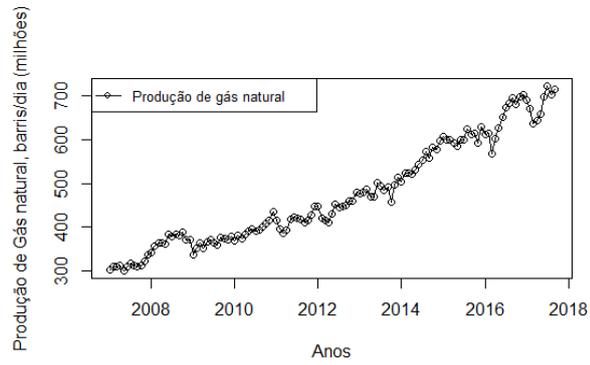
3. Procedimentos metodológicos

Estas seções estão organizadas da seguinte forma descreve-se a coleta de dados, pacote usado no ambiente de trabalho R studio, resultados e considerações finais.

3.1 Coleta de dados

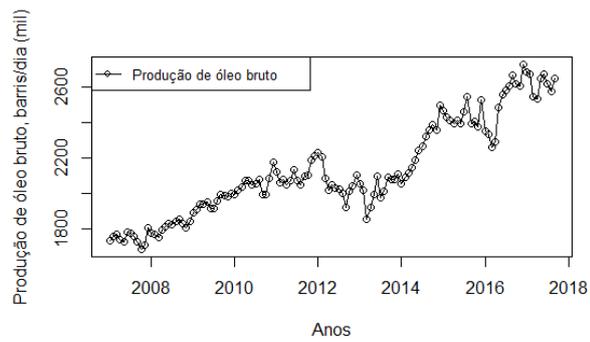
Os dados foram retirados da ferramenta sistema gerenciador de séries temporais (SGS). Tanto a ferramenta como as informações sobre a mesma são disponibilizadas pelo Banco Central do Brasil (BCB, 2017), na web site da empresa, portanto mediante a ferramenta a coleta foi referente as séries temporais de produção de derivados de petróleo, Gás natural, barris/dia (milhões), produção de derivados de petróleo, óleo bruto, barris/dia (mil) e produção de derivados de petróleo, total, Barris/dia (mil). As três séries temporais são da produção do Brasil nos períodos de janeiro de 2007 a setembro de 2017, atingindo 129 períodos mensais de amostra. As séries cronológicas usadas encontram-se nas figuras 1, 2 e 3:

Figura 1 - Produção de gás natural



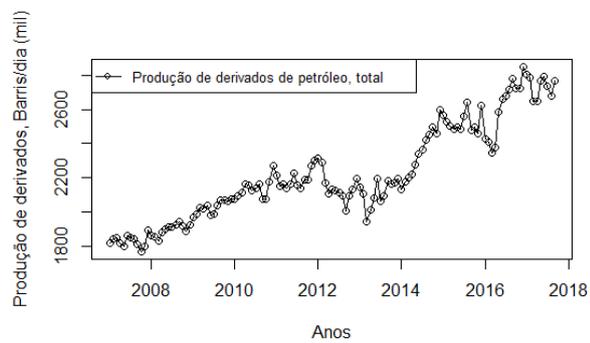
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 2 - Produção de óleo bruto



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

Figura 3 - Produção de derivados de petróleo – total



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

3.2 Pacote em R studio

Para fazer as previsões e comparar a capacidade preditiva das redes neurais MLP e máquina de aprendizagem extrema (ELM), 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 ao pacote *nnfor* do R (KOURENTZES, 2017). Os cálculos das medidas de erro MAPE e MAD, foram executados com o pacote *forecast* no *R studio* (HYNDMAN; KHANDAKAR, 2008; HYNDMAN, 2017).

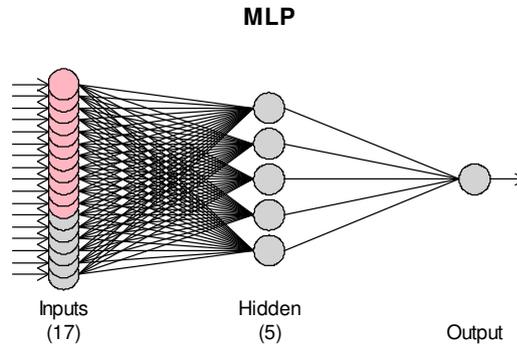
As funções em R utilizadas para prever os valores no curto prazo de três meses são *mlp* e *elm*, já para comparar a acuracidade das redes neurais foi usada a função *accuracy*. Assim, contemplando o período entre janeiro de 2007 até setembro de 2017, verificou-se o comportamento das previsões com os dados reais, já disponibilizados pelo Banco Central do Brasil, concernentes ao período de outubro a dezembro de 2017.

Esses recursos computacionais são de livre acesso e atualmente disponíveis para gerentes de previsão e acadêmicos. No momento em que esses dados foram coletados não estavam disponíveis pelo BCB as observações mais atuais de 2018, por essa razão determinamos o último trimestre de 2017, como o período de previsão.

4. Resultados

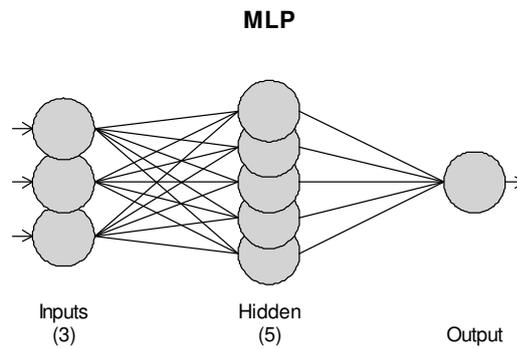
As redes neurais dos modelos perceptron multi-camada (MLP) com suas respectivas arquiteturas são geradas com base nas séries temporais produção de gás natural (figura 1); produção de óleo bruto (figura 2) e produção de derivados de petróleo, total (figura 3). Bem como as arquiteturas da máquina de aprendizagem extrema (ELM) por meio das séries históricas: produção de gás natural (figura 1); produção de óleo bruto (figura 2) e produção de derivados de petróleo, total (figura 3). Os resultados de arquitetura estão representados nas figuras 4, 5, 6, 7, 8 e 9.

Figura 4 - Arquitetura da MLP com base em produção de gás natural



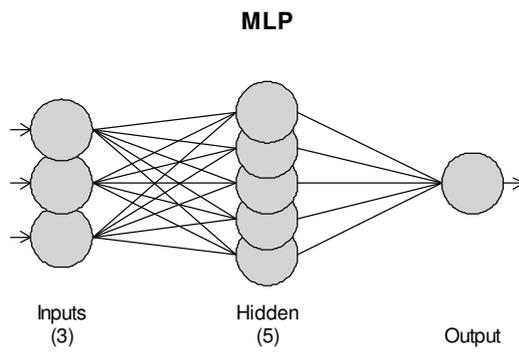
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 5 - Arquitetura da MLP com base em produção de óleo bruto



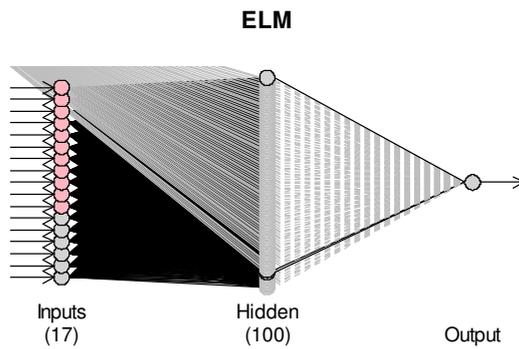
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 6 - Arquitetura da MLP com base em produção de derivados de petróleo - total



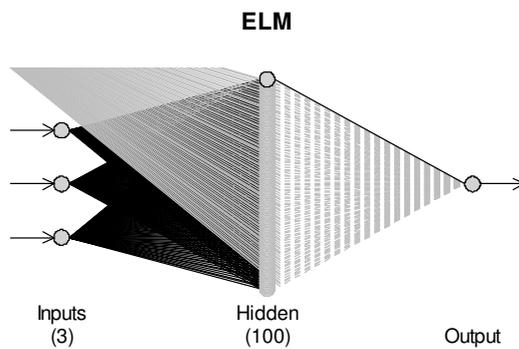
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 7 - Arquitetura da ELM com base em produção de gás natural



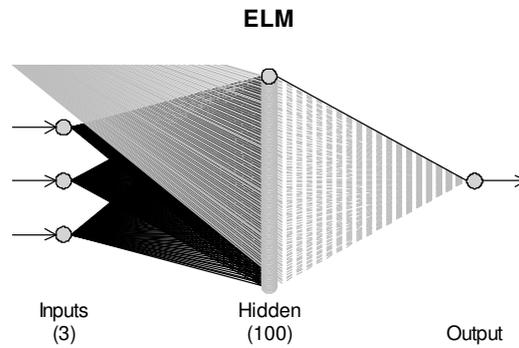
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 8 - Arquitetura da ELM com base em produção de óleo bruto



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

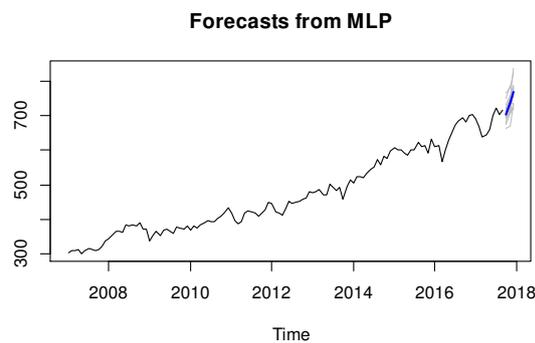
Figura 9 - Arquitetura da ELM com base em produção de derivados de petróleo - total



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

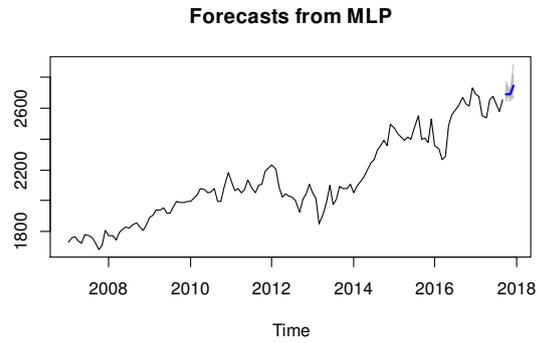
As arquiteturas 5, 6, 8 e 9 são iguais por conta das semelhanças no comportamento dos dados nas séries temporais produção de óleo bruto (figura 2) e produção de derivados de petróleo, total (figura 3). Mas os dados de cada série temporal são diferentes essa informação pode ser confirmada em (BCB, 2017), até mesmo os valores previstos de cada arquitetura podem confirmar a afirmação por que as previsões geradas foram diferentes em cada arquitetura (tabela 3). Em seguida foi gerado os gráficos de séries temporais com as previsões de curto prazo representados nas figuras 10, 11, 12, 13, 14 e 15.

Figura 10 - Previsões da produção de gás natural de outubro até dezembro de 2017



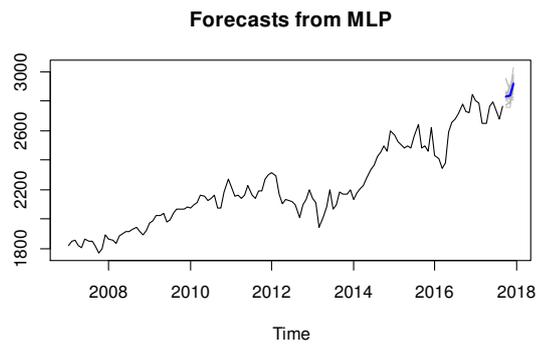
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 11 - Previsões da produção de óleo bruto de outubro até dezembro de 2017



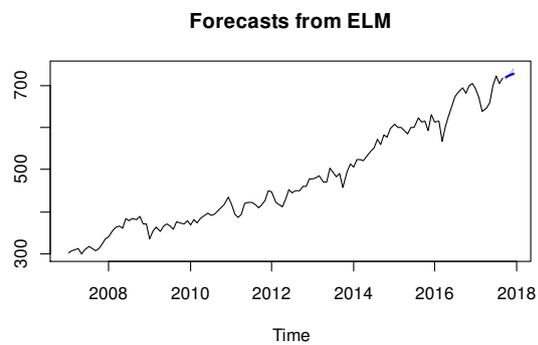
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 12 - Previsões da produção de derivados de petróleo (total) de outubro até dezembro de 2017



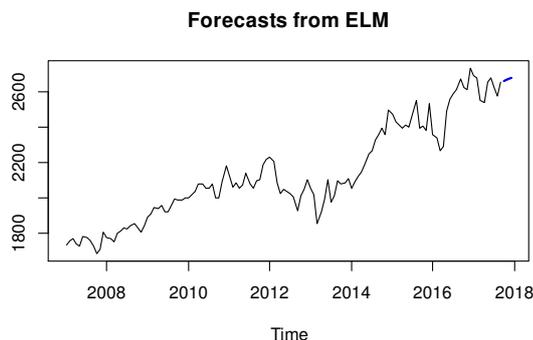
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 13 - Previsões da produção de gás natural de outubro até dezembro de 2017



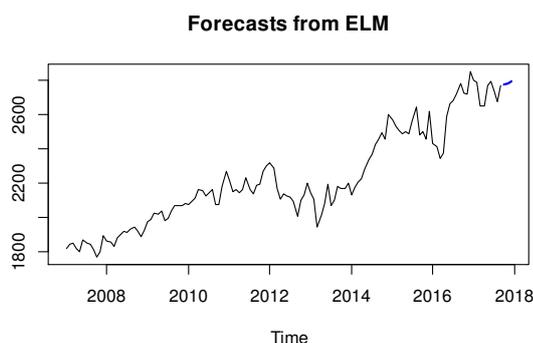
Fonte: Elaborado pelos autores através do software R e com base em dados do BCB (2017)

Figura 14 - Previsões da produção de óleo bruto de outubro até dezembro de 2017



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

Figura 15 - Previsões da produção de derivados de petróleo (total) de outubro até dezembro de 2017



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

Os parâmetros das redes neurais MLP e ELM foram gerados onde, nós ocultos é o número de nós na camada escondida; Repetições é o número de treinamento da rede neural e inputs é o número de entradas da arquitetura da rede neural todos estes parâmetros são demonstrados na tabela 2.

Tabela 2 - Parâmetros das redes neurais

Modelo	Nós ocultos	Repetições	Raios univariados	Inputs
MLP	5	20	(1,3,4,7,9,10)	17
MLP	5	20	(2,3,12)	3
MLP	5	20	(2,3,12)	3
ELM	100	20	(1,3,4,7,9,10)	17
ELM	100	20	(2,3,12)	3
ELM	100	20	(2,3,12)	3

Fonte: elaborada pelos autores

Os modelos de redes neurais descritos foram utilizados para gerar as previsões de 3 meses da produção de gás natural (figura 1); produção de óleo bruto (figura 2) e produção de derivados de petróleo, total (figura 3). As observações e previsões de MLP e ELM em números para os meses de outubro até dezembro de 2017 podem ser visualizadas na tabela 3.

Tabela 3 - Comparação dos valores previstos com dados reais

Ano-2017							
Rede Neural	Séries Temporais	Outubro	Dados reais (Outubro)	Novembro	Dados reais (Novembro)	Dezembro	Dados reais (Dezembro)
MLP	Prod. de gás natural	703.614	721	736.901	713	769.314	717
MLP	Prod. de óleo bruto	2690.234	2.627	2686.579	2.595	2742.572	2.653
MLP	Prod. de petróleo, total	2831.176	2.742	2836.487	2.705	2919.065	2.766
ELM	Prod. de gás natural	720.347	721	723.694	713	727.042	717
ELM	Prod. de óleo bruto	2660.560	2.627	2668.120	2.595	2675.681	2.653
ELM	Prod. de petróleo, total	2773.767	2.742	2781.534	2.705	2789.301	2.766

Fonte: elaborada pelos autores

Os critérios de avaliação MAPE e MAD apresentam a precisão dos modelos em comparação com os dados reais. Uma característica óbvia na tabela 4, é que as previsões do modelo ELM superou a rede neural MLP nas três séries temporais testadas, outra informação importante extraída dos resultados de acuracidade é que as previsões de ambos os modelos MLP e ELM apresentaram um MAPE inferior a 10% que de acordo com Lewis (1982) este resultado é interpretado pela classificação do autor como previsão altamente precisa.

Tabela 4 - Critérios de avaliação

Modelo	Séries Temporais	MAPE	MAD	Ranking
MLP	Prod. de gás natural	4.353%	31.200	5°
MLP	Prod. de óleo bruto	3.104%	81.462	4°
MLP	Prod. de petróleo, total	4.548%	124.576	6°
ELM	Prod. de gás natural	0.997%	7.129	1°
ELM	Prod. de óleo bruto	1.650%	43.120	3°
ELM	Prod. de petróleo, total	1.610%	43.867	2°

Fonte: elaborada pelos autores

Portanto, o 1º lugar no ranking de desempenho de previsões é do modelo ELM, o segundo e terceiro melhor desempenho individual também fica com o método ELM, isto com base nos resultados das medidas de erro MAPE e MAD como pode ser observada na tabela 4. Mas na avaliação geral de precisão ambas as redes neurais tiveram resultados de previsões excelentes, pois, de acordo com as diretrizes de Lewis (1982), os resultados de MAPE entre 10% e 20% são interpretados como previsão precisa.

5. Considerações finais

Quanto aos resultados obtidos na pesquisa, mostrou-se que a rede neural ELM tem o melhor desempenho de precisão, ou seja, fornece previsões, mais precisas da produção de gás natural, produção de óleo bruto e produção de petróleo, porém na análise geral os dois métodos MLP e ELM são viáveis para previsão de curto prazo. Isto indica que os planejadores de petróleo podem utilizar as redes neurais MLP e ELM aplicadas neste estudo como apoio as decisões de planejamento de produção.

Os resultados obtidos demonstraram que ELM tem a capacidade de prever as séries temporais testadas nesta investigação de forma precisa e confiável. A limitação da pesquisa está em previsões de curto prazo num único horizonte de previsão (3) meses fora da amostra. Para superar essa limitação sugere-se a trabalhos futuros executar as previsões de curto, médio e longo prazo para constatar o nível de generalização dos resultados verificados.

Referencias

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.**

BANCO CENTRAL DO BRASIL (BCB). Sistema Gerenciador de Séries Temporais – v2.1: consultar séries. Disponível em: < <https://goo.gl/MXPZo1> >. **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.

CLAVERIA, Oscar; TORRA, Salvador. Forecasting tourism demand to Catalonia: Neural networks vs. time series models. **Economic Modelling**, v. 36, p. 220-228, 2014.

CRONE, Sven F.; KOURENTZES, Nikolaos. Feature selection for time series prediction—A combined filter and wrapper approach for neural networks. **Neurocomputing**, v. 73, n. 10, p. 1923-1936, 2010.

DE OLIVEIRA, Fagner A.; NOBRE, Cristiane N.; ZÁRATE, Luis E. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index—Case study of PETR4, Petrobras, Brazil. **Expert Systems with Applications**, v. 40, n. 18, p. 7596-7606, 2013.

FAN, Xinghua; WANG, Li; LI, Shasha. Predicting chaotic coal prices using a multi-layer perceptron network model. **Resources Policy**, v. 50, p. 86-92, 2016.

FARAWAY, Julian; CHATFIELD, Chris. Time series forecasting with neural networks: a comparative study using the air line data. **Journal of the Royal Statistical Society: Series C (Applied Statistics)**, v. 47, n. 2, p. 231-250, 1998.

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

HUANG, Guang-Bin; ZHU, Qin-Yu; SIEW, Chee-Kheong. Extreme learning machine: theory and applications. **Neurocomputing**, v. 70, n. 1-3, p. 489-501, 2006.

HUANG, Guang-Bin; ZHU, Qin-Yu; SIEW, Chee-Kheong. Extreme learning machine: a new learning scheme of feedforward neural networks. In: **Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on**. IEEE, 2004. p. 985-990.

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: 05 Jan. 2018.**

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.

KAASTRA, Iebling; BOYD, Milton. Designing a neural network for forecasting financial and economic time series. **Neurocomputing**, v. 10, n. 3, p. 215-236, 1996.

KARCHERE, Alvin J. Forecast Error and Planning. **Business Economics**, v. 11, n.3, p. 70-73, 1976.

KAZMIER, Leonard J. **Estatística aplicada à economia e administração**. 1. ed. São Paulo: McGRAW-Hill do Brasil, 1982.

KOURENTZES, Nikolaos. nnfor: Time Series Forecasting with Neural Networks. R package version 0.9.2, 2017. **Disponível em:** < <https://goo.gl/hTnKmb> > **Acesso em: 05 Jan. 2018.**

KOURENTZES, Nikolaos; BARROW, Devon K.; CRONE, Sven F. Neural network ensemble operators for time series forecasting. **Expert Systems with Applications**, v. 41, n. 9, p. 4235-4244, 2014.

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.

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

MIYAOKA, Julia; HAUSMAN, Warren H. How improved forecasts can degrade decentralized supply chains. **Manufacturing & Service Operations Management**, v. 10, n. 3, p. 547-562, 2008.

MOREIRA, Daniel Augusto. **Administração da produção e operações**. 2. ed. São Paulo: Cengage Learning, 2011.

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.

SAGAERT, Yves R. et al. Temporal big data for tire industry tactical sales forecasting. **Interfaces**, 2017.

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

STUNDNER, M. et al. How data-driven modeling methods like neural networks can help to integrate different types of data into reservoir management. In: **SPE Middle East Oil Show**. Society of Petroleum Engineers, 2001.

TONG, Howell. Threshold models in time series analysis: some reflections. **Journal of Econometrics**, v. 189, n. 2, p. 485-491, 2015.

WHITE, Halbert. Learning in artificial neural networks: A statistical perspective. **Neural computation**, v. 1, n. 4, p. 425-464, 1989.

ZHANG, G. Peter; BERARDI, V. L. Time series forecasting with neural network ensembles: an application for exchange rate prediction. **Journal of the Operational Research Society**, v. 52, n. 6, p. 652-664, 2001.