



## PREVISÃO DO POTENCIAL DE PRODUÇÃO EM PLATAFORMAS MARÍTIMAS: COMPARAÇÃO ENTRE MÉTODOS ESTATÍSTICOS E REDES NEURAIAS

Vitor Hugo Pinheiro Marques (PUC-RIO) marques.hugo@petrobras.com.br  
Fernando Luiz Cyrino (PUC-RIO) Cyrino@puc-rio.br  
Antônio Orestes de Salvo Castro (UFRJ) Orestes@ime.uerj.br  
Gabriel Alcântara Bomfim (Petrobras) Alcantara.ep@gmail.com

### Resumo

O trabalho tece análise de séries temporais no potencial de produção de óleo em plataformas marítimas. O estudo contempla o desafiador cenário de amadurecimento da Bacia geográfica de campos, essas que possuem um declínio de produção natural difícil de prever. O modelo aplica decomposição com STL, de modo a ajustar a série histórica com retirada da tendência para a aplicação dos métodos de previsão, e com sua posterior reincorporação para análise do erro. Esse tratamento é realizado devido à alta presença de tendência de declínio da série histórica. Compara-se a previsão de métodos estatísticos (ETS, ARIMA, *Prophet*) com métodos de redes neurais que fazem uso de aprendizado de máquina (MLP, RBF e ELM). É verificado que o MLP e o ELM apresentaram os menores erros em relação aos demais. Atribui-se os melhores resultados ao alto processamento computacional dos métodos de aprendizado de máquina, e principalmente, devido a metodologia que separa a tendência do restante da série histórica, dessa forma os métodos de redes neurais conseguem interpretar melhor os dados remanescentes que são não lineares.

**Palavras-Chaves:** Produção de óleo. Séries Temporais. Métodos de previsão.

### 1. Introdução

De acordo com a International Energy Agency (2021), o Brasil terminou o ano de 2021 como sétimo maior produtor de petróleo do mundo. No Brasil, os campos marítimos já produzem 97% do petróleo nacional (ANP, 2022).

Segundo Bomfim (2017) a previsão de produção é uma das etapas mais críticas do processo de planejamento de curto prazo das empresas de exploração e produção de petróleo (E&P). O



volume de petróleo que será produzido, denominado meta de produção, influencia diretamente todas as ações das empresas e tem um crítico impacto em relação ao mercado. Ele ainda explica que os reservatórios de petróleo são formações complexas resultantes de processos geológicos deposicionais ao longo de milhões de anos e, assim, qualquer descrição que se faça do reservatório terá uma boa dose de arbitrariedade.

Existem trabalhos relevantes na área de reservatório que trata sobre simulações e comparam previsões para verificar o modelo de séries temporais que melhor prevê o potencial dos poços, porém o grande número de variáveis consideradas na simulação estocástica de fluídos exige alto esforço computacional e duração, sendo comum que a informação do reservatório não seja utilizada no modelo corporativo que faz a análise de risco para o estabelecimento da meta de produção, e conseqüentemente não seja utilizada para as decisões estratégicas. Este trabalho se diferencia dos principais estudos sobre o tema ao integrar a análise da previsão do potencial histórico à análise corporativa de risco da previsão de potencial produtivo.

O Brasil teve por muito tempo o foco na exploração de campos terrestres. Atualmente o foco tem sido nos campos marítimos, em campos do pré-sal e pós-sal. Traçar previsões para plataformas mais novas tem desafios maiores devido à incerteza histórica. Dessa forma, o enfoque do trabalho é dado aos campos mais maduros brasileiros, mais especificamente para a região da Bacia de campos que teve início da produção comercial no ano de 1977. Ela ocupa uma área marinha de aproximadamente 100 mil quilômetros quadrados, localizada na região que vai do centro-norte do Estado do Rio de Janeiro até o sul do Estado do Espírito Santo.

Ferreira (2016) discute a maturidade de campos de produção maduros, analisando suas curvas de produção e taxas de declínio de diferentes campos nela concentrados. Esses campos maduros possuem desafios de declínio de potencial e elevação de perdas históricas devido ao amadurecimento dos campos e desgastes de equipamentos.

Castro et al. (2010) propôs um modelo para avaliar o risco da previsão de produção considerando quatro entidades de entrada: Potencial Produtivo Instalado, Entrada de Novos Poços, Parada Programada para Manutenção e Eficiência Operacional. O objetivo do simulador foi identificar, avaliar e quantificar de forma antecipada as incertezas presentes no ambiente para suportar o processo de determinação da meta de produção de óleo para o horizonte de doze meses. O modelo é utilizado até hoje pela empresa em estudo.

O trabalho é realizado através do software R. Ele analisa a aplicação de series históricas, especificamente nos dados de entrada do potencial de produção, comparando os métodos estatísticos com os métodos baseado em redes neurais.

## 2. Objetivo

O objetivo do trabalho é realizar projeções do potencial com maior acurácia. Busca-se obter o método de previsão com maior acurácia para ser disponibilizado ao modelo de simulação de análise de risco da produção de petróleo.

O estudo compara a aplicação de séries temporais no potencial de produção das plataformas marítimas em grande empresa de energia brasileira, avaliando os seguintes métodos:

- Estatísticos: Suavização exponencial, ARIMA e *Prophet*;
- Redes neurais: *Multilayer Percepton*, *Radial Basis Function*, e *Extreme Learning Machine*.

## 3. Revisão bibliográfica

A literatura apresenta estudos de séries temporais e aprendizado de máquina na área de óleo e gás, os quais buscam verificar como interpretar de forma mais precisa o conjunto de dados.

### 3.1. Séries temporais no potencial produtivo

Uma série temporal permite que o pesquisador descubra, com alguma margem de erro, os valores futuros de uma série a partir de seus valores anteriores (TEALAB, 2018).

Makridakis (2018) compara métodos estatísticos com métodos de *Machine Learning* (ML) utilizados na competição M3. Ele comenta que o último é muito mais sofisticado e computacionalmente exigente do que o primeiro, porém não garante ser mais preciso.

Correia (2021) analisa a aplicação de séries temporais especificamente em 3 poços marítimos de petróleo, comparando o modelo estatístico ARIMA com redes neurais recorrentes. Ele ressalta que a área de óleo e gás tem apresentado progressiva aderência à ciência de dados para tornar as tomadas de decisões orientadas a dados. O monitoramento e previsão da produção de óleo e gás proporcionam informações úteis para o melhor manejo econômico de

um poço ou de um campo de petróleo. Os resultados mostraram que os modelos de redes neurais obtiveram melhor desempenho de previsão quando comparados com o ARIMA.

De acordo com Fan (2021) a previsão precisa da produção do poço é essencial para estender o ciclo de vida de um poço e melhorar a recuperação do reservatório. Na área de produção de petróleo, ainda que as séries tenham comportamento linear, é comum que os poços sejam fechados temporariamente por questões operacionais. Ele estabelece um novo modelo híbrido que considera as vantagens da linearidade e não linearidade, integrando o modelo ARIMA e o modelo de redes neurais *Long Short Time Memory* (LSTM). O ARIMA obtém bom desempenho nas curvas de declínio da produção constante, e o de redes neurais mostra vantagens em dados não lineares.

Yanrui (2022) utiliza previsão de séries temporais, motivado pelas flutuações históricas nas operações de poços de produção e reservatórios, com os dados de produção de petróleo em 65 poços localizados na Bacia Denver-Julesburg (EUA). Ele compara ARIMA, LSTM Network e Prophet, verificando que o ARIMA e LSTM têm desempenho melhor que o *Prophet* sob a suposição que nem todos os dados de produção de petróleo incluem influências sazonais.

As análises entre os métodos mais efetivos de previsão mostram que, para diferentes conjuntos de dados e aplicação em produção de óleo, métodos diferentes tiveram maior precisão. O alto número de poços e plataformas do presente estudo o torna mais complexo em exercer projeções. Assim, é importante avaliar diferentes aplicações de métodos de previsão.

Para os métodos estatísticos, foram selecionados os que, de acordo com a pesquisa, são os mais aplicados: Suavização exponencial e ARIMA, além do *Prophet* que é um modelo mais novo que também está sendo estudado na área de óleo e gás.

Dos modelos de redes neurais, os mais utilizados no domínio geofísico, são o MLP e RBF (AMIM, 2014). Além desses, o estudo avalia o ELM por ser um método de velocidade de aprendizagem rápida.

Busca-se aproveitar o uso de modelos de séries temporais, verificando alterações dos parâmetros, a fim de obter o menor erro de previsão.

## **3.2. Métodos de aprendizado de máquina baseados em redes neurais**

### **3.2.1. Multilayer perceptron (MLP)**

O método consiste em uma camada de entrada, uma camada de saída e uma ou mais camadas ocultas. Na função de ativação não linear, cada nó é chamado de neurônio ou elemento de processamento. Cada neurônio tem um valor que é calculado a partir de valores ponderados de seus neurônios de entrada anteriores e somados com valores de entrada para cada neurônio, e seus vieses são ajustados (Al-NAYMAT, 2016).

Aref (2020) comenta que os MLPs são treinados com base no algoritmo de retropropagação (BP) que segue um procedimento de aprendizado baseado na regra de correção de erros. A rede produz saídas processando os dados de entrada recebidos. O erro é calculado comparando os valores alvo e a saída da rede. Em seguida, os pesos e vieses são ajustados para minimizar o erro; o processo de treinamento continua até que a rede atinja um erro mínimo permitido pré-definido.

### **Número de processadores na camada escondida MLP:**

Hecht-Nielsen (1987) usa teorema de Kolmogorov para dizer que qualquer função de  $n$  variáveis pode ser representada por  $2n+1$  funções. ( $N_h \leq 2N + 1$ ), sendo  $N$  o número de entradas e  $N_h$  o número de processadores na camada escondida.

Li (1995) investiga como encontrar o número de unidades na camada escondida em rede neural *feedforward*. De acordo com a teoria, o número suficiente de unidades na camada oculta da rede neural de segunda ordem e nas redes neurais de primeira ordem são 4 e 7, respectivamente. Os resultados da simulação também mostram que a rede neural de segunda ordem é melhor que a de primeira ordem na convergência de treinamento.

De acordo com Sheela e Deepa (2013) vários pesquisadores tentaram e propuseram muitas metodologias para encontrar o número de neurônios escondidos ideal. A pesquisa aborda métodos encontrados para detectar o número ótimo de neurônios na camada escondida da rede neural. Eles sugerem a abordagem construtiva que começa com uma rede subdimensionada e, em seguida, adiciona neurônios ocultos adicionais.

### **3.2.2. Radial basis function (RBF)**

As redes RBF contém a camada de entrada, saída e função não linear. A primeira camada é a de entrada e o número de nós é determinado pelo número de parâmetros de entrada. A segunda camada é a escondida e o número de nós é determinado pelo treinamento real. A

terceira camada é a de saída e o número de nós é determinado de acordo com a saída. A relação entre as duas primeiras camadas é não linear e a relação entre as duas últimas camadas é linear (YAN, 2014).

Conforme Panchapakesan (1998) sua estrutura simples permite o aprendizado por etapas, reduz o tempo de treinamento tempo, e isso leva à aplicação de tais redes para muitos problemas práticos. Os parâmetros ajustáveis de tais redes são os centros de campo receptivo (a localização das funções de base), a largura (a propagação), a forma do campo receptivo e os pesos de saída lineares.

### **3.2.3. Extreme learning machine (ELM)**

Segundo Huang (2014) extreme learning machine (ELM) foi proposta para treinar redes neurais com uma única camada escondida *feedforward*. No ELM, os nós da camada escondida são iniciados aleatoriamente e, em seguida, fixados. O único parâmetro que precisa ser aprendido são os pesos entre a camada escondida e a camada de saída. Ele ainda cita que ELM têm três vertentes: menos invenção humana, alta precisão de aprendizagem e velocidade de aprendizagem rápida.

De acordo com Xia (2019) comparado com algoritmos tradicionais, o método ELM é fácil de usar e alcança solução globalmente ótima com alta velocidade de aprendizado e boa capacidade de generalização. No entanto parâmetros relevantes são fornecidos aleatoriamente, o que pode invalidar alguns nós da camada oculta e afetar a predição do modelo.

## **3.3. Métodos de previsão estatísticos**

### **3.3.1. Suavização exponencial**

Autores como Hyndman e Athanasopoulos (2021) desenvolveram métodos com pesos exponenciais. Observações recentes recebem um peso relativamente maior do que as mais antigas (MEIRA, 2021).

O método automático de previsão ETS usa trinta modelos e os distingue avaliando o erro (E), tendência (T) e sazonalidade (S);

### 3.3.2. ARIMA

Conforme desenvolvido por Box e Jenkins (1970), combina componentes Autorregressivos (AR) entre uma observação e um número de observações defasadas ( $p$ ), integrado (I) para tornar a série temporal estacionária medindo as diferenças de observações em diferentes tempos ( $d$ ), e processos de Média Móvel (MA) levando em consideração a dependência entre as observações ( $q$ ).

### 3.3.3. Prophet

O Modelo do Prophet (PFM) foi desenvolvido com o intuito de prever uma variável com precisão em relação ao tempo. A novidade deste modelo é de que não é necessário um número complexo de parâmetros para obter resultados relevantes (TAYLOR; LETHAM, 2017).

É necessário explicitar que o modelo é estimado usando uma abordagem bayesiana para permitir a seleção automática dos pontos de mudança e outras características do Prophet (HYNDMAN; ATHANSOPOULOS, 2021).

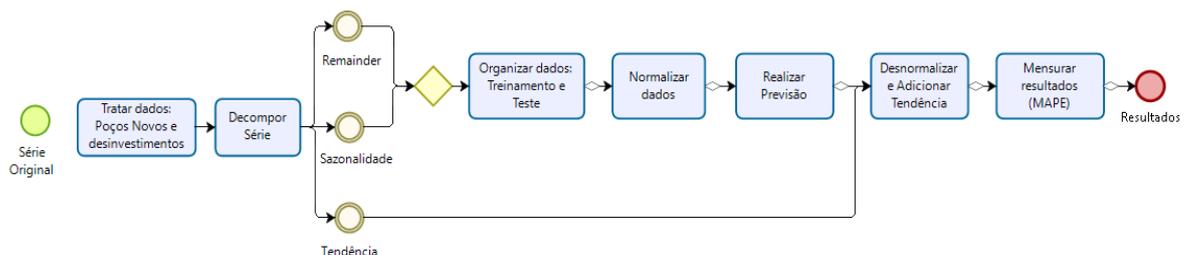
## 4. Metodologia

A metodologia de pesquisa consiste, primeiramente, em realizar pesquisas exploratórias. Foram levantados trabalhos relacionados nos sites: Scopus, Science Direct, e Google Scholar sobre temas como: Forecasting, Oil & gas, Well, e outros ligados às técnicas aplicadas.

A aplicação é desenvolvida através do software R, e os principais pacotes utilizados foram: dplyr, lubridate, ggfortify, ggplot2, tidyr, tsibble, forecast, nnfor e MLmetrics.

O trabalho é dividido em sete etapas que serão descritas a seguir. A metodologia aplicada é representada na Figura 1 onde cada diagrama representa uma etapa do trabalho.

Figura 1 – Metodologia aplicada no presente trabalho.



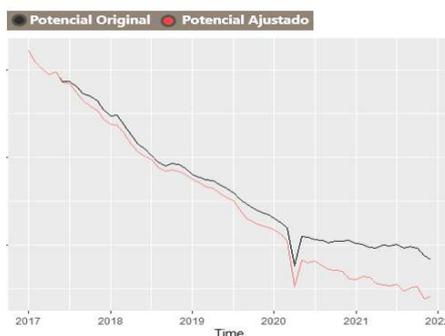
Fonte: Elaboração própria em software Bizzagi.

A análise dos dados históricos contempla avaliar o potencial de 23 plataformas marítimas da Bacia geográfica de campos. Os dados contemplam 56 meses, desde janeiro/2017 até agosto/2021. A soma do potencial mensal das plataformas forma uma série histórica única para análise. Ela é denominada como o potencial original.

As sete etapas aplicadas são explicadas abaixo:

- a) Tratar dados: pré-processamento da série original, considera retirada do potencial dos novos poços que iniciaram a produção durante o período da análise (56 meses), e a retirada das plataformas desinvestidas nesse mesmo período. O potencial original e o ajustado (utilizado para as previsões) podem ser visualizados no gráfico da Figura 2. O eixo y foi ocultado para preservar informações confidenciais da empresa.

Figura 3 – Curva de Potencial antes e após o tratamento dos dados (“etapa a”)



Fonte: Elaboração própria em software R.

- b) Decompor série: realização da decomposição STL, de modo a retirar a tendência da série histórica para a aplicação dos métodos de previsão, e posterior reincorporação da tendência para análise do erro. É importante dado a alta presença de tendência de declínio na série de potencial de produção.  
Decomposição STL configura-se como um método de suavização baseado em regressões locais para decompor a série temporal em tendência e componentes remanescentes. STL é utilizada para obter os componentes de tendência, sazonalidade e resíduos (BERGMEIR, 2016).
- c) Organizar dados: o conjunto de dados foram divididos em treinamento (Jan/17 à Ago/20 - 44 Meses), e teste (Set/20 à Ago/21 - 12 Meses).
- d) Normalizar dados: os dados foram normalizados, conforme metodologia para aplicação em redes neurais preconiza.
- e) Realizar previsão: aplicada para os 6 métodos de séries temporais em análise (Suavização exponencial, ARIMA, PROPHET, MLP, RBF e ELM).

- f) Desnormalizar dados: após previsão, os dados com aplicação de Redes Neurais são “desnormalizados” e, para todas as metodologias, a tendência é reinserida nas séries.
- g) Mensurar resultados: as previsões foram testadas repetidamente, sendo registrado em um plano de experimentos, para cada ajuste dos parâmetros, o erro mensurado.

Foi definido utilizar a média percentual absoluta do erro (MAPE) como métrica de erro devido a facilidade de interpretar porcentagens, sendo mais comum em aplicações corporativas. Como os dados de potencial são avaliados em um ano, nenhuma plataforma chega próximo de zero, não apresentando os principais problemas com o uso do MAPE como destacam (KOLASSA; MARTIN, 2011).

### 5. Análise dos resultados

Os testes realizados foram registrados em um plano de experimentos contendo: ID do cenário, método de previsão, hiperparâmetros alterados, e erro obtido.

A figura 04 mostra dois exemplos de cenários alterados no plano de experimentos preenchido: MLP à esquerda, indica ajustes nas camadas escondidas (hd), e RBF à direita, mostrando alterações no número de centros (k) e alcance do gamma (y).

Figura 4 – Exemplos de cenários registrados nos experimentos: Método MLP (esq.) e RBF (dir.)

Plano de Experimento (Potencial de produção)				Plano de Experimento (Potencial de produção)			
Cenário	Modelos		Métrica de erro	Cenário	Modelos		Métrica de erro
	MLP	Parâmetros	MAPE		RBF	Parâmetros	MAPE
36	x	hd=6,7	4,3%	1	x	k=9	9,64%
37	x	hd=6,8	6,53%	2	x	k=8	9,68%
38	x	hd=6,10	7,03%	3	x	k=7	9,72%
39	x	hd=7,2	9,14%	4	x	k=6	9,73%
40	x	hd=7,5	8,73%	5	x	k=5	9,73%
41	x	hd=7,8	7,26%	6	x	k=4	9,68%
42	x	hd=7,9	5,89%	7	x	k=3	9,55%
43	x	hd=7,10	5,44%	8	x	k=2	9,6%
44	x	hd=7,11	4,93%	9	x	k=11	9,73%
45	x	hd=7,12	6,88%	10	x	k=12	9,77%
46	x	hd=8,2	7,65%	11	x	k=10,y=1	9,59%
47	x	hd=8,5	8,92%	12	x	k=10,y=1,5	9,61%
48	x	hd=8,6	6,83%	13	x	k=10,y=2,0	9,64%

Fonte: Elaboração própria em Excel.

Para o MLP, as principais variações foram em relação a alteração do número de camadas, variando com uma camada única, com duas camadas, além de verificações em relação ao “lag” e ao número de iterações.

O teste para o número de processadores na camada escondida MLP, começou com um número baixo, conforme preconiza a abordagem construtiva, passando pela recomendação de Li (7 e 4 processadores nas camadas), continuando os testes até o número de 27 camadas (respeitando a recomendação de Hecht-Nielsen), dada as 56 entradas.

O melhor cenário obtido tem configuração de duas camadas escondidas, sendo 6 processadores na primeira camada escondida e 7 processadores na segunda camada escondida, e 50 iterações foi considerado como satisfatório. O melhor MAPE obtido corresponde a 4,3%, mostrando a alta acurácia que o modelo consegue obter.

Para o modelo RBF, as principais variações foram em relação ao número de centros clusterizados e o alcance do gamma. O melhor cenário obtido com configuração de 10 Centros e gamma 1,0. O melhor MAPE obtido corresponde a 9,59% ficando aquém dos demais métodos de redes neurais.

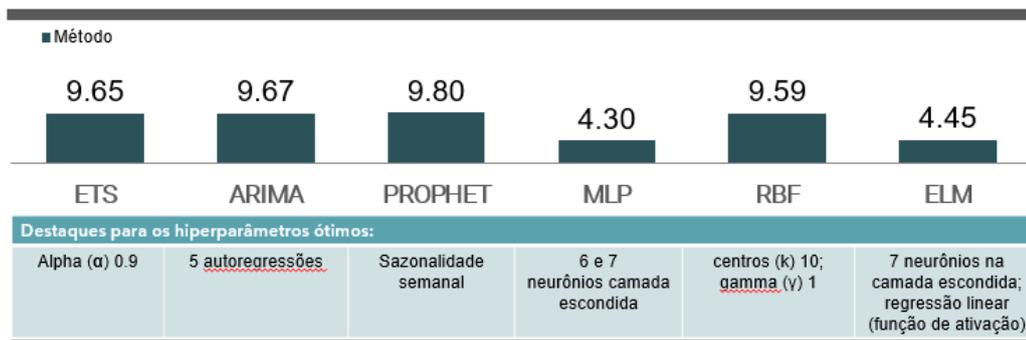
Os testes realizados com o ELM incluem como principais variações: alterações na topologia da camada única, tipo de regressão para pesos da camada de saída, alterações nos lags históricos e no número de iterações.

O melhor cenário foi com configuração de 7 camadas escondidas e uso de regressão linear, além de 50 iterações dadas como satisfatório. O MAPE obtido foi de 4,45%. O resultado foi muito próximo ao erro do MLP. Apesar dos pesos aleatórios do modelo, verifica-se que a média resulta em uma boa estimativa.

Em relação aos modelos estatísticos, o ARIMA teve como melhor resultado o uso de 5 autoregressões ( $p=5, d=0, q=0$ ), alcançando resultado de erro de 9,67%. O ETS teve alpha 0.9 como melhor configuração, fazendo uso de maior período histórico, com erro alcançado de 9,65%. O Prophet realizou testes principalmente em relação a alterações nas configurações de sazonalidade. Ao incluir a sazonalidade semanal ele obteve melhor resultado de 9,8%.

O resumo dos erros resultantes, segundo a metodologia aplicada, pode ser verificado na figura 05. Os modelos estatísticos configuraram seus melhores resultados muito próximos, se aproximando do erro obtido com o pior resultado para redes neurais. Destaque para a acurácia dos métodos MLP e RBF, alcançando erro de 4%.

Figura 5 – Resultados dos Método e seus principais hiperparâmetros



Fonte: Elaboração própria em software Excel.



Foram avaliados 141 cenários no total. Outros testes também foram realizados, porém não foram destacados devido à baixa alteração no resultado dos erros.

## 6. Considerações finais

Os métodos baseados em redes neurais e aprendizado de máquina apresentaram resultados melhores do que os que fazem uso de métodos estatísticos. Os resultados do MLP e do ELM se destacaram em relação aos demais, apresentando resultados menores em relação ao erro.

É possível relacionar o resultado com a metodologia proposta, dado que a retirada da tendência retira a linearidade da série, e métodos de *Machine Learning* conseguem interpretar melhor a não-linearidade do potencial ao excluir a sua tendência de declínio histórica.

Para trabalhos futuros recomenda-se fazer análise de outros métodos, como é o caso do Echo State Network (redes neurais) e do TBats (estatística), ou combinação com outras metodologias, como por exemplo, fazer uso de simulação e ensemble, além de se aprofundar em outras alterações de parâmetros. Também recomenda-se continuar fazer testes em períodos de séries histórico diferente, analisando a generalização dos resultados.

## REFERÊNCIAS

Al-Naymat, Ghazi. *et al.* **Classification of VoIP and non-VoIP traffic using machine learning approaches.** Journal of Theoretical and Applied Information Technology. 3192. Comprehensive Foundation (2nd ed.). Prentice Hall PTR, Upper Saddle River, NJ, USA. 2016.

Amin, Kahrizi; Hosein, Hashemi. **Neuron curve as a tool for performance evaluation of MLP and RBF architecture in first break picking of seismic data,** Journal of Applied Geophysics, Vol.108. P. 159-166. 2014.

ANP. **Brasil produz cerca de 3 milhões de bbl/d de petróleo em abril.** Boletim Mensal de Produção de Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. 2022. Publicado em 03/06/2022. Disponível em: <[https://www.gov.br/anp/pt-br/canais\\_atendimento/imprensa/noticias-comunicados/brasil-produz-cerca-de-3-milhoes-de-bbl-d-de-petroleo-em-abril](https://www.gov.br/anp/pt-br/canais_atendimento/imprensa/noticias-comunicados/brasil-produz-cerca-de-3-milhoes-de-bbl-d-de-petroleo-em-abril)>. Acesso em: 02 jan. 2023.

Aref Hashemi Fath, Farshid Madanifar, Masood Abbasi. **Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems.** Petroleum, Vol.6, P. 80-91. 2020.

Bergmeir, Christoph.; Hyndman, Rob. J. and Benítez, José. M. **Bagging exponential smoothing methods using STL decomposition and Box–Cox transformation.** International Journal of Forecasting, Vol.32. P. 303–312. 2016.

Bomfim, Gabriel Alcântara. **Modelagem da Data de Entrada em Produção de Poços de Petróleo Utilizando Inferência Fuzzy.** PUC-Rio, Rio de Janeiro, RJ. 2017.

Box, George. E. P. and Jenkins, Gwilym. M. **Time series analysis: Forecasting and control.** San Francisco: Holden-Day. 1970.



- Castro, Antônio Orestes de S.; Mattos, J. R. and Silva, S. B. P. **Job Risk - Análise Probabilística da Previsão de Produção de Óleo**. Seminário de Planejamento, Controle e Avaliação do Desempenho do E&P. Anais... Rio de Janeiro. 2010.
- Correia, Jaqueline Bitencourt. *et al.* **Comparing ARIMA and LSTM models to predict time series in the oil industry**. P. 129-136. 2021.
- Fan, Dongyan. *et al.* **Well production forecasting based on arima-lstm model considering manual operations**. Energy. Vol.220. 2021.
- Ferreira, Victor Marchesini. **Avaliação de métodos de recuperação melhorada de petróleo para campos marítimos no Brasil: o caso da Bacia de Campos**. Universidade Federal do Rio de Janeiro, COPPE, Rio de Janeiro, RJ. 2016.
- Hecht-Nielsen R. **Kolmogorov’s mapping neural network existence theorem**. Proceedings of the international conference on Neural Networks. vol.3. P. 11–14. 1987.
- Huang, Gao. *et al.* **Trends in Extreme Learning Machines: A Review**. Neural Networks. 2014.
- Hyndman, Rob J., and Athanasopoulos, George. **Forecasting: principles and practice**. 3rd edition, OTexts: Melbourne, Australia. 2021. Disponível em: <OTexts.com/fpp3>. Acesso em: 27 jan. 2023.
- International Energy Agency. **World Energy Outlook 2021, IEA**, Paris, França. 2021. Disponível em: <<https://www.iea.org/reports/world-energy-outlook-2021>>. Acesso em: 20 jan. 2023.
- Kolassa, Stephan; Martin, Roland. **Percentage Errors Can Ruin Your Day (and Rolling the Dice Shows How)**. Foresight: The International Journal of Applied Forecasting, International Institute of Forecasters, issue 23, p. 21-27, Fall. 2011.
- Li, Jin-Yan; Chow, T. W. S And Yu, Ying-Lin. **Estimation theory and optimization algorithm for the number of hidden units in the higher-order feedforward neural network**. Proceedings of the IEEE International Conference on Neural Networks. 1995. vol.3, P. 1229–1233.
- Makridakis, S; Spiliotis, E; Assimakopoulos, V. **Statistical and Machine Learning forecasting methods: Concerns and ways forward**. PLoS ONE. 13. 2018.
- Meira, Erick; Oliveira, Fernando Luiz Cyrino and Menezes, Lilian M. **Point and interval forecasting of electricity supply via pruned ensembles**. Point and interval forecasting of electricity supply via pruned ensembles, Energy, Vol. 232. 2021.
- Panchapakesan, C; Ralph D And Palaniswami, M. **Effects of moving the centers in an RBF network**. 1998. IEEE International Joint Conference on Neural Networks Proceedings. IEEE World Congress on Computational Intelligence. vol.2. p. 1256-1260. 1998.
- Sheela, K. Gnana; Deepa, S N. **Review on Methods to Fix Number of Hidden Neurons in Neural Networks**. Mathematical Problems in Engineering. 2013.
- Taylor Sean J; Letham Benjamin. **Forecasting at scale**. The American Statistician.2017, Vol. 72:1, P. 37-45.
- Tealab, Ahmed. **Time series forecasting using artificial neural networks methodologies: A systematic review**. Future Computing and Informatics Journal, Vol. 3, Issue 2”. 2018. P: 334-340.
- Xia, Luyue. *et al.* **Prediction of CO2 Solubility in Ionic Liquids Based on Multi-Model Fusion Method**. Processes Journal. Vol. 7. 2019.
- Yan, Mi. *et al.* **Optical fiber sensor system for monitoring leakage current of post insulators based on RBF neural network**. ICHVE International Conference on High Voltage Engineering and Application. 2014 P. 1-4.
- Yanrui, Ning; Hossein, Kazemi; Pejman, Tahmasebi. **A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet**. Computers & Geosciences, Vol. 164. 2022.