

Aplicação de redes neurais artificiais na análise financeira das empresas do setor de petróleo

Com o crescimento da tecnologia da informação e inteligência artificial, uma série de novas tecnologias surgiram para facilitar a gestão empresarial dos setores econômicos, como é o caso da indústria petrolífera, que possui uma grande influência no crescimento econômico brasileiro. A matéria-prima possui um alto custo de extração e é classificada como um insumo raro para ser encontrada na natureza. As redes neurais são importantes para aumentar a quantidade de petróleo extraída com maior segurança, não apenas para os colaboradores envolvidos no processo, mas também para o meio ambiente. Isso acontece porque a tecnologia, apesar de funcionar de maneira simples, quando acompanhada de uma análise estatística, é capaz de processar diversos dados, fomentando informações importantes para melhorias a exploração de petróleo. Ademais, diversos problemas ambientais são corroborados pela emissão do petróleo na atmosfera, inclusive, contribuindo para fenômenos como a acidificação dos oceanos e aquecimento global. Nesse contexto, essa pesquisa aborda sobre a aplicação das redes neurais artificiais na análise financeira das empresas do setor de petróleo no ano de 2018. O método de pesquisa utilizado foi descritivo e quantitativo para proporcionar validação científica a essa pesquisa. Apresenta-se as conclusões com os principais resultados obtidos nesse artigo, assim como algumas limitações do método aplicado e perspectivas de pesquisas futuras.

Palavras-chave: Redes neurais artificiais; Petróleo; Análise financeira.

Application of artificial neural networks in the financial analysis of companies in the oil sector

With the growth of information technology and artificial intelligence growth, a series of new technologies emerged to assist and improve business management of economic sectors, such as the petrol industry, which significantly influences the Brazilian economic growth. The raw material has a high cost of extraction and is also classified as a rare commodity to be found in nature. The neural networks have great importance in increasing the amount and security of petrol extraction, not only for employees involved in the process but also for the environment. It happens because the technology, accompanied by statistical analysis, can process numerous data besides working simply, providing crucial information for improvements in petroleum exploration. Furthermore, several environmental problems are corroborated by oil emissions into the atmosphere, including contributing to phenomena such as ocean acidification and global warming. Within this context, the present research addresses the usage of neural networks for the petrol companies' financial analysis in 2018. The research's methodology is descriptive and quantitative to provide scientific validation. Conclusions are presented with the main results achieved during the research, the methodology's main limitations and future research perspective.

Keywords: Artificial neural networks; Petroleum; Financial analysis.

Topic: **Finanças Empresariais**

Received: **13/04/2022**

Approved: **26/05/2022**

Reviewed anonymously in the process of blind peer.

João Bosco Arbués Carneiro Júnior 
Universidade Federal de Rondonópolis, Brasil
<http://lattes.cnpq.br/5073023761658236>
<https://orcid.org/0000-0001-7094-2245>
jbacj@hotmail.com

Mariana Carolina Ribeiro dos Santos Silva 
Universidade Federal de Mato Grosso, Brasil
<http://lattes.cnpq.br/9129236523882749>
<https://orcid.org/0000-0002-0573-309X>
marih_ribeiro@hotmail.com

Regina Rodrigues Nagayama 
Universidade Federal de Rondonópolis, Brasil
<http://lattes.cnpq.br/5025311338253261>
<https://orcid.org/0000-0002-9726-2511>
renagayama@gmail.com

Thamiris da Silva Porto Vona 
Universidade Federal de Rondonópolis, Brasil
<http://lattes.cnpq.br/5522393958851131>
<https://orcid.org/0000-0001-8573-9119>
thamiris.vona@hotmail.com



DOI: 10.6008/CBPC2179-684X.2022.002.0005

Referencing this:

CARNEIRO, J. B. A. J.; SILVA, M. C. R. S.; NAGAYAMA, R. R.; VONA, T. S. P.. Aplicação de redes neurais artificiais na análise financeira das empresas do setor de petróleo. **Revista Brasileira de Administração Científica**, v.13, n.2, p.58-69, 2022. DOI:
<http://doi.org/10.6008/CBPC2179-684X.2022.002.0005>

INTRODUÇÃO

Em 1943, um neurofisiologista Warren McCulloch e o matemático Walter Pitts, da universidade de Illinois, fizeram uma analogia entre as células nervosas e o processo eletrônico num artigo publicado no *Bulletin of Mathematical Biophysics* com o título: *A Logical Calculus Of Nethe Ideas Immanent in Nervous Activity* (Um cálculo lógico das ideias imanentes na atividade nervosa). Em 1949, o biólogo e psicólogo, que estudava o comportamento dos animais, o mesmo que reforçava as teorias de que o condicionamento psicológico estava presente em qualquer parte dos animais, pelo fato de que esta é uma propriedade de neurônios individuais.

As ideias de Hebb não eram pioneiras, mas ele propôs um princípio de aprendizado em sistemas nervosos complexos, ou seja, uma lei que descreve o funcionamento quantitativo da sinapse e do processo de treinamento humano. Os pioneiros, tiveram uma ideia de que despertou muita curiosidade de outros pesquisadores. Um grande exemplo, foi na primeira conferência de inteligência artificial, em 1956. Onde foi apresentado um projeto, que consistia numa simulação de centenas de neurônios. Seu modelo consistia numa simulação de centenas de neurônios interconectados através de um sistema que verifica como a rede responderia aos estímulos ambientais.

O mundo das Redes Neurais (RNAs) só abriu portas para serem usados de diversas formas, visando melhor a vida do homem. Unindo tecnologia com aprendizado do cérebro humano. As RNAs podem ser conhecidas como redes neurais artificiais (ANNs) ou redes neurais simuladas (SNNs), elas formam um subconjunto e se localizam no núcleo dos algoritmos de *deep learning*. Sua inspiração veio através do estudo do cérebro humano, ou seja, imitando a maneira como os neurônios biológicos enviam sinais uns para os outros.

A análise financeira é uma importante ferramenta que procura facilitar o entendimento dos números apresentados nos relatórios financeiros contábeis, para tomarem as decisões baseadas nas estatísticas dos dados coletados, que, projetados com o auxílio das informações geradas pela análise, podem diminuir o risco de erros, corrigindo e evitando prejuízos (IUDÍCIBUS, 2017). Essa análise é medida em um determinado período, o desempenho de uma organização, comparando sua evolução ao longo dos anos, com empresas do mesmo setor de atividade (MARQUES et al., 2015).

O objetivo geral dessa pesquisa é aplicar as Redes Neurais Artificiais (RNA) com a análise financeira. Como objetivos específicos, a pesquisa irá conceituar e realizar um apanhado histórico da utilização de redes neurais.

O método de pesquisa utilizado foi quantitativo, por meio de uma revisão literária de cunho descritivo e exploratório, para tanto, serão consultados livros, teses, dissertações, artigos e páginas virtuais sobre o tema, partindo de autores renomados e atualizados, para proporcionar um excelente embasamento teórico para o texto. Considerando que a ciência é baseada na autocrítica, essa é uma maneira de conseguir sintetizar novas ideias para a esfera acadêmica e trazer novas conclusões sobre o mesmo tema, algo essencial para a construção do conhecimento científico (SEVERINO, 2017).

Nesse contexto, a utilização de método de RNAs pode fornecer propostas rápidas, inteligentes sobre medidas adequadas, destinadas a trazer as condições de volta a um estágio de perfuração ideal. Portanto, a inteligência artificial tem sido bastante empregada na indústria do petrolífera, causando grandes impactos na economia de tempo, mitigação de riscos e redução de custos, fatores que influenciam diretamente no desempenho dessa indústria.

A relevância dessa pesquisa se dá pela importância econômica do setor tanto para indústria, quanto para o dia a dia das pessoas, portanto, investir em técnicas que facilitem processos como o craqueamento, destilação fracionada do petróleo, perfuração de camadas espessas, dentre outros fatores. Logo, essa é uma área em expansão, assim, o estudo das redes neurais na indústria *offshore* é um assunto essencial considerando o rápido crescimento de tecnologias, principalmente no contexto da economia e indústria 4.0.

REVISÃO TEÓRICA

Antes de abordar as redes neurais de forma mais específica, é preciso entender como funciona um neurônio biológico. Basicamente, essas células do sistema nervoso são compostas por dendritos, corpo celular, axônio e terminações do axônio. O cérebro humano possui diversos neurônios, dessa maneira, o conhecimento de uma célula nervosa para outra é transportado por meio das sinapses, passando pelos dendritos, corpo celular, axônio e finalmente chega às terminações do axônio (FURTADO, 2019).

É válido lembrar, que as redes neurais possuem um funcionamento com modelagem simples, nesse contexto, para a criação de uma unidade logística, é criada um sistema simulado das sinapses nervosas. Esse funcionamento pode ser observado na (Figura 1).

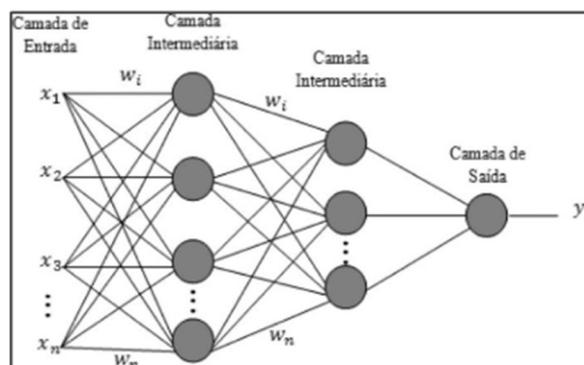


Figura 1: Arquitetura de Rede Neural Artificial MLP. **Fonte:** Adaptado de Silva et al. (2010).

Vale ressaltar, que a finalidade da criação de uma rede neural artificial é feita basicamente para melhorar o transporte de conhecimento para que o sistema criado possibilite melhores decisões no que está se querendo determinar, seja para prever ou classificar algum método ou processo. No caso da indústria *offshore*, na qual estão envolvidos os hidrocarbonetos e derivados do petróleo, a tecnologia de ponta e as redes neurais são fundamentais nos procedimentos envolvidos, considerando não apenas os riscos que os profissionais estão expostos, mas o alto valor que o petróleo possui no mercado, nessa perspectiva, a sua extração precisa ser realizada de forma otimizada, e com a melhor tecnologia envolvida no mercado (NEIS, 2019).

As aplicações dessas redes são vastas, não apenas para a extração e processos relacionados com o refinamento do petróleo, mas também com previsões de preços do hidrocarboneto no mercado, que pode ser estipulado por meio de séries temporais, por exemplo (SILVA et al., 2018).

Em uma rede neural simples, existem entradas (em uma só camada), os pesos, e a presença das funções soma e ativação, vale ressaltar, que podem existir diversas funções e ativação e dependendo da explicação, uma delas pode ser melhor do que a outra¹.

Em regra, esse modelo aprende através das entradas, que são embutidas na rede e multiplicadas pelos pesos (que são dependentes do número de entradas), sendo elas armazenadas na variável soma. De forma simplificada, as redes neurais se comportam da seguinte maneira: seus pesos são as sinapses presentes no sistema e possuem a finalidade de amplificar ou diminuir um sinal de entrada, portanto, os conhecimentos de uma rede neural dependem, exclusivamente, dos pesos nela presentes. Isso indica que quanto maior for a configuração dos pesos, melhor será a precisão dessa rede neural.

Esse método de inteligência artificial pode possuir diversas aplicações, como a sua incorporação no setor energético brasileiro – indústria de petróleo – a etapa é necessária para realizar uma previsão ou classificação, assim, por meio dessa tecnologia, são realizados os tratamentos de dados, isto posto, a aplicação de conhecimentos estatísticos são fundamentais para se obter melhores decisões do modelo observado, algo importante na indústria *offshore*.

De acordo com Furtado (2019), as redes neurais artificiais, são compreendidas como um modelo computacional que é capaz de simular a estrutura e os aspectos funcionais de uma sinapse nervosa. Então, essa tecnologia pode ser relacionada aos processos que ocorrem no cérebro humano e o processamento de informações que ocorre no local. Cada conexão entre neurônios é capaz de emitir um sinal, portanto, um neurônio artificial que recebe um sinal pode processá-lo em conjunto a outros neurônios. Assim, as informações podem seguir de forma estruturada, pois, redes neurais se modificam e aprendem, baseadas nas entradas e saídas.

O petróleo é considerado a principal fonte de energia da humanidade, porém, ele já era utilizado por povos antigos, para práticas como a pavimentação de estradas, lubrificante, aquecimento, dentre outras. Todavia, do século XIX até o momento, a utilização desse hidrocarboneto vem crescendo, como consequência, ganhou uma dimensão de consumo crítica, uma vez que o mundo literalmente pararia se essa matéria-prima cessasse (FURTADO, 2019).

A formação desse combustível é oriunda da deposição no fundo de lagos e mares de restos de animais e vegetais comportados ao longo de milhares de anos, esses rejeitos eram cobertos por sedimentos, que posteriormente se transformavam em rochas. Devido a circunstância da ação do calor e da alta pressão provocada pelo empilhamento dessas camadas, o petróleo pode ser encontrado em cavidades existentes no subsolo.

Quimicamente, esse composto é classificado como oleoso, inflamável, com cheiro característico e,

¹ https://repositorio.ufc.br/bitstream/riufc/48092/1/2019_capliv_acbsantosgafarias.pdf

em regra, menos denso que a água. Por consequência, ele consiste fundamentalmente de átomos de carbono, hidrogênio e enxofre, sobre a forma de hidrocarbonetos. Contudo, a presença de enxofre na gasolina vem diminuindo nos últimos anos (LOURAL et al., 2019).

É preciso lembrar que a utilização do petróleo não é limitada a produção de gasolina, portanto, além dos combustíveis, também são derivados desse elemento os óleos lubrificantes, graxa, vaselina etc. Assim, nenhuma máquina ou equipamento pode trabalhar de forma assertiva, sem a devida lubrificação. Além disso, adubos químicos e polímeros também são derivados desse hidrocarboneto. Esse componente também influencia a indústria têxtil, pois, são vários os tecidos derivados do petróleo, como é o caso do nylon e poliéster (ROMERO, 2018).

A análise acima demonstra a importância do petróleo para o mundo, logo, o ser humano terá muito trabalho para substituir esse componente, não apenas como matriz energética, mas em cada um de seus usos. Logo, a incorporação de tecnologias como as redes neurais para facilitar a trabalhabilidade, preservação e maleabilidade desse elemento heterogêneo, certamente, é um dos pilares para preservá-lo por um maior período, como será mais bem abordado a seguir.

Essa tecnologia pode ser relacionada como uma ferramenta estatística não linear, onde relações complexas entre a entrada e saída de dados são modeladas ou padrões são encontrados. Por essa análise, redes neurais foram criadas como um sistema capaz de prever e incorporar padrões de dados, que são capazes de observar imprevistos e aumentar a performance de um sistema (FURTADO, 2019).

No setor petrolífero, uma maior previsão da sua extração, assim como melhorias assertivas em sua produção sempre foram desafios para esse setor. Através das redes neurais, é possível desenvolver modelos de previsão da produção desse hidrocarboneto, algo que possibilita uma redução do seu custo de produção e uma maior eficiência em sua extração (FARIAS, 2018).

Considerando o alto valor agregado do petróleo, as redes neurais são uma possibilidade de mitigar custos e tornar a sua extração eficiente e eficaz, algo que não poderia ser realizado apenas com a manufatura, assim, fica evidente a importância das redes neurais profundas para essa área da indústria *offshore* (FARIAS, 2018).

As etapas do desenvolvimento de um sistema de redes neurais são a criação e seleção de um parâmetro de treinamento, diferentes tipos de funções de ativação, algoritmos para treinamento, coleta de dados, processamento de dados e cálculo de erros. O último, pode ser um dos pilares do gerenciamento de riscos durante a extração do petróleo, que em grande parte encontra-se *offshore*. A seleção de parâmetros, no que lhe concerne, é outro processo importante para a indústria do petróleo, pois afeta o desempenho da previsão de modelo (PAVÓN et al., 2019).

METODOLOGIA

O objeto deste estudo foi a avaliação do desempenho das empresas na indústria de petróleo e química no Brasil no ano de 2018 advindos de um importante indicador sendo o EBITDA. Teve como foco na análise da aplicação de redes neurais artificiais na indústria, considerando os avanços que a tecnologia teve

nos últimos anos e a importância desse composto orgânico para a economia no Brasil.

Em relação aos procedimentos metodológicos, este trabalho classifica-se como pesquisa descritiva, com dados secundários, por lidar com informações obtidos de informes gerenciais históricos de órgãos públicos como Resultados das Operações Financeiras das Empresas, um total de 21 observações. Esses dados foram concedidos pela Revista Exame 500 Maiores Empresas de 2018.

Quanto ao método, o estudo classificou-se como quali-quantitativo, que expressa em números, informações com o intuito de classificar, analisar e ordenar resultados e qualitativa que contribui no processo de compreensão do acontecimento social segundo a conduta dos agentes sociais em seu meio e posicionamentos.

Para realizar a relação da análise nos 5 setores da economia no setor petrolífero e químico no Brasil, recorreu-se aos conceitos de Redes Neurais Artificiais (RNA), considerando como base a variável preditiva a rentabilidade sobre vendas (em %), capital circulante líquido (em US\$ milhões), liquidez geral (em US\$ milhões) e endividamento geral (em %), nos setores petrolíferos e químico e o fator ano (no período relacionado à coleta dos dados) nas bases consideradas no ano de 2018.

De acordo com Braga et al. (2014), as principais características das RNA são: i) organização de dados; ii) adaptação do modelo por experiência; iii) capacidade de aprendizado; iv) armazenamento distribuídos; v) tolerância a falhas; vi) habilidade de generalização; vii) controle e otimização de sistemas; viii) processamento de sinais e predição. Essas características das RNA conduzem à busca por processos que possam realizar a predição de fenômenos biológicos como a dos índices zootécnicos, que geram dados satisfatórios próximos de valores reais. Neste estudo, as variáveis independentes (preditoras) e a variável dependente (preditiva) estão resumidas no quadro 1.

Quadro 1: Variáveis independentes e dependentes do estudo da economia Brasileira, por setor financeiro, no período de 2018.

Setor	Variáveis Dependentes	Variáveis Preditiva
Indústria (ind)	EBITDA (ebt)	Rentabilidade sobre Vendas (Rentabilidade)
		Capital circulante líquido (CCL)
		Liquidez Geral (LG)
		Endividamento Geral (EG)

RESULTADO E DISCUSSÃO

Os dados utilizados nesta pesquisa foram apresentados no ano de 2018 conforme observa-se na tabela 1. A correlação de Pearson linear é um teste que mede a relação estatísticas entre duas variáveis. Se seus elementos não forem lineares, seu coeficiente não irá ser representado adequadamente. Suas variáveis na planilha possuem uma alta correlação, porém negativa entre elas com valores inferiores 0,7, como já esperado, por conta de sua vez o EBITDA, Capital Circulante e Endividamento são altamente correlacionados entre si. Se função utilizada fosse mediante a regressão linear, o resultado estaria prejudicado, tendo em vista que as covariáveis possuem forte correlação entre elas, entretanto, com a utilização das RNAs esta situação não gera problemas à predição

Foi adotado o método do software SPSS para criar e validar o modelo de RNAs. Definir a etapa ser

trabalhada na RNA é a primeira parte, no qual a escolhida foi a Percepttron Multicada, com uma camada camuflada e as variáveis apuradas de forma padronizadas. A tabela 3 demonstra o resumo de processamento de casos da RNA predita.

Tabela 1: Variáveis EBITDA, Rentabilidade sobre Vendas, Capital Circulante Líquido, Endividamento Geral.

EMPRESA	EBITDA (EM US\$ MILHÕES)	RENTABILIDADE SOBRE VENDAS (EM %)	CAPITAL CIRCUL. LÍQUIDO (EM US\$ MILHÕES)	LIQUIDEZ GERAL (EM NO. INDICE)	ENDIVIDAMENTO GERAL (EM %)
Braskem	1477,8	7,5	448,2	0,43	83,2
Basf	188,8	2,9	-108,6	1,08	60,7
Syngenta	285,4	7	950,4	2,07	42,3
Bayer	147,8	6	429,4	1,31	71,2
DuPont	-66,3	-16,6	362	1,19	74
Hydro Alunorte	-42,3	-21,7	-464	0,62	58,7
Heringer	-38,8	-20,6	-368,4	0,55	133
Fertipar	43,4	17,9	113,1	1,59	27
Oxiteno Nordeste	94,9	9,1	164	3,26	20,7
Innova	105,7	5,1	5,3	0,94	43,6
Fertilizantes Tocantins	47,4	0,1	-82,8	0,88	95
Adama Brasil	62,5	7,4	183	1,09	73,8
Arlanxeo	85,3	10,4	173	2,38	29,3
Nufarm	53,6	2,6	109,1	1,33	66
Refinaria Riograndense	4,5	0,3	-4	0,78	82,1
Petroquímica Suape	88,1	14,5	146,5	4,49	12,7
Iharabras	64,3	14,2	344,6	3,35	28,8
Elclor	72,1	11,8	54	0,73	74,7
Aysta LifeScience	59,1	7,2	107,3	1,48	56,6
Evonik	35,8	1,6	76,3	1,71	29,1
Produquímica	67,2	10,4	83,6	1,13	53,2

Tabela 2: Correlação linear de Pearson (r) entre variáveis, Capital Circulante Líquido EBITDA, Endividamento Geral, Liquidez Geral e Rentabilidade e sobre Vendas.

		Capital Circulante Líquido	EBITDA	Endividamento Geral	Liquidez Geral	Rentabilidade sobre Vendas
Capital Circulante Líquido	Correlação de Pearson	1	,388	-,312	,324	,477*
	Sig. (bilateral)		,082	,169	,153	,029
	N	21	21	21	21	21
EBITDA	Correlação de Pearson	,388	1	,108	-,169	,215
	Sig. (bilateral)	,082		,640	,463	,348
	N	21	21	21	21	21
Endividamento Geral	Correlação de Pearson	-,312	,108	1	-,757**	-,600**
	Sig. (bilateral)	,169	,640		,000	,004
	N	21	21	21	21	21
Liquidez Geral	Correlação de Pearson	,324	-,169	-,757**	1	,491*
	Sig. (bilateral)	,153	,463	,000		,024
	N	21	21	21	21	21
Rentabilidade sobre Vendas	Correlação de Pearson	,477*	,215	-,600**	,491*	1
	Sig. (bilateral)	,029	,348	,004	,024	
	N	21	21	21	21	21

*. A correlação é significativa no nível 0,05 (bilateral). **. A correlação é significativa no nível 0,01 (bilateral).

Tabela 3: Resumo de processamento de casos da RNA.

Amostra			N	Porcentagem
	Treinamento		15	76,2%
Testes		5	23,8%	
Válido		21	100%	
Excluídos		0	0%	
Total		21	100%	

Como abordado em material e métodos, de maneira aleatória, o próprio software exibe informações sobre a rede neural referente a quantidade de variáveis utilizadas como treinamento e testes. O resumo de

processamento de casos mostra que 15 (76,2%) casos foram atribuídos à amostra de treinamento e 5 (23,8%) à amostra de testes, em que se pode notar percentuais distintos. A tabela 4 exhibe as informações da rede, tratando os aspectos de sua edificação.

Tabela 4: Informações de rede.

Camada de entrada	Covariáveis	1	Rentabilidade sobre vendas
		2	Capital Circulante Líquido
		3	Liquidez Geral
		4	Endividamento Geral
	Número de unidades		4
Métodos de reescalonamento para covariáveis		Padronizado	
Camadas ocultas	Número de camadas ocultas		1
	Número de unidades na camada oculta 1ª		1
	Função de ativação		Tangente hiperbólica
Camada de saída	Variáveis dependentes	1	EBITDA
	Número de unidades		1
	Métodos de reescalonamento para dependentes de escala		Padronizado
	Função de ativação		Identidade
	Função de erro		Soma dos Quadrados

A camada de entrada é formada pelas quatro variáveis independentes, rentabilidade sobre vendas, capital circulante líquido, liquidez geral e endividamento geral. A tabela de informações da rede, exhibe sobre a rede neural e é útil para garantir que as especificações estejam corretas. As variáveis independentes foram reescaladas pelo método padronizado, no qual é subtraído a média do desvio padrão. Uma unidade de saída separada é criada para cada uma das variáveis dependentes de escala. Eles são redimensionados pelo método normalizado ajustado, que requer o uso da função de ativação da tangente hiperbólica para a camada de saída. Na tabela 5 se observa este comportamento de associação das variáveis e os valores neste intervalo.

A camada de saída procede na variável dependente, que neste estudo, foi o EBITDA, e como covariáveis rentabilidade sobre vendas, capital circulante líquido, liquidez geral e endividamento geral. O método de reescalonamento foi convencionalizado, a função de apuramento foi a identidade, ou seja, utiliza valores reais e os retorna idênticos. O erro de soma de quadrados é relatado porque as variáveis dependentes são escala e utiliza-se para medir a qualidade da RNA. Visualiza-se a figura 2 do diagrama de rede.

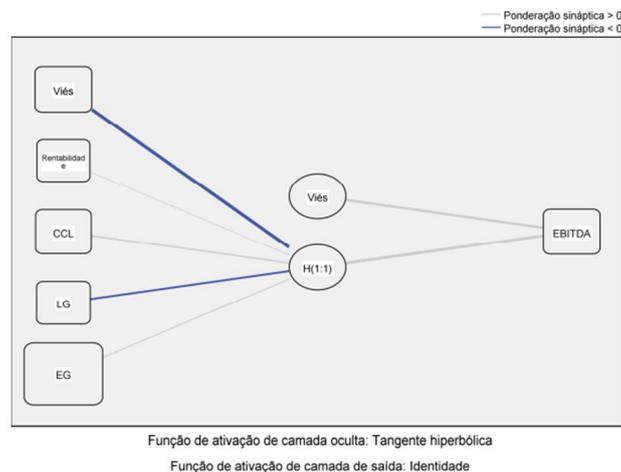


Figura 2: Diagrama de rede.

Na figura 2 repara-se presença do comportamento das ponderações sinápticas. A ponderações

sinápticas mostram a associação entre as variáveis com ajustes realizados pelas RNAs e pelos fatores incluídas no modelo. Na tabela 5 demonstra os valores das ponderações sinápticas do modelo predito.

Tabela 5: Estimativas de parâmetro.

Preditor		Predito	
		Camada Oculta 1	Camada de saída
		H (1:1)	EBITDA
Camada de entrada	(Viés)	-3,789	
	Rentabilidade	,902	
	CCL	1,166	
	LG	-1,532	
	EG	1,002	
Camada Oculta 1	(Viés)		2,650
	H (1:1)		2,939

Os valores previstos na camada de entrada foram processados de forma padronizada, portanto seus valores variam entre -3 e 1, enquanto os valores na camada de saída processados pela função de identidade, representando assim os valores determinados por associação. Os valores apresentados na Tabela 5 foram obtidos treinando a RN. Ressalta - se aqui que o procedimento para realização de RNA é único e as etapas para processar a rede e os resultados obtidos são os resultados da execução neste momento. Devido à característica de aprendizado, os resultados coletados em execuções futuras não devem ser os mesmos, pois a cada execução a RNA "aprende" individualmente e não sistematicamente. É possível armazenar e armazenar o RNA "treinado" para que o modelo edificado possa ser utilizado para outros casos. A seguir, na Tabela 6, é apresentado um resumo do modelo onde pode ser observado o erro do modelo que é a principal métrica de verificação para RNAs.

Tabela 6: Sumarização do modelo.

Treinamento	Soma dos erros quadráticos	,232
	Erro relativo	,031
	Regra de parada usada	1 passos consecutivos sem diminuição de erros ^a
	Tempo de treinamento	0:00:00.00
Testes	Soma dos erros quadráticos	,018
	Erro relativo	,109

Variável Dependente: EBITDA, a. os cálculos de erro têm como base a amostra de teste

De acordo debatido no referencial teórico, o erro relativo é a soma dos quadrados dos erros da variável dependente. A Tabela 6 mostra que o erro do modelo de previsão é de 0,109 ou 10,9%, que é um valor relativamente baixo, indicando que a RNA pode ser usada para previsões confiáveis. Em seguida, foi calculado o desvio padrão da diferença entre os valores previstos e reais do EBITDA para mensurar os desvios encontrados entre essas variáveis com o auxílio do software SPSS.

Após a validação da RNA avaliada neste artigo, são expostas as Figuras 3 e 4, que revelam o comportamento do valor previsto para cada valor observado e o gráfico do valor residual para cada valor previsto da variável dependente, respectivamente. A conduta dos valores previstos em relação aos valores assistidos deve mostrar linearidade. Na Figura 3, observa que os pontos dispersos com linearidade visível. Figura 3: gráfico de valores estimados por observação. Figura 4: gráfico de remanescente para previsão. Na Ilustração 3, a análise de resíduos mostra que a presunção de normalidade é atendida porque o gráfico mostra a conduta em torno do horizonte centrado em zero sem caracterizar tendências positivos ou

negativas. Para completar as controvérsias sobre a validação do modelo previsto, a ilustração 5 e a Tabela 7 apresentam informações para analisar a significância das variáveis dependentes para a construção da RNA. A Tabela 7 mostra que a variável Capital Circulante Líquido foi a variável que melhor contribuiu para a predição da RNA, contribuindo para a estimativa de 0,205, ou, 20,5 %.

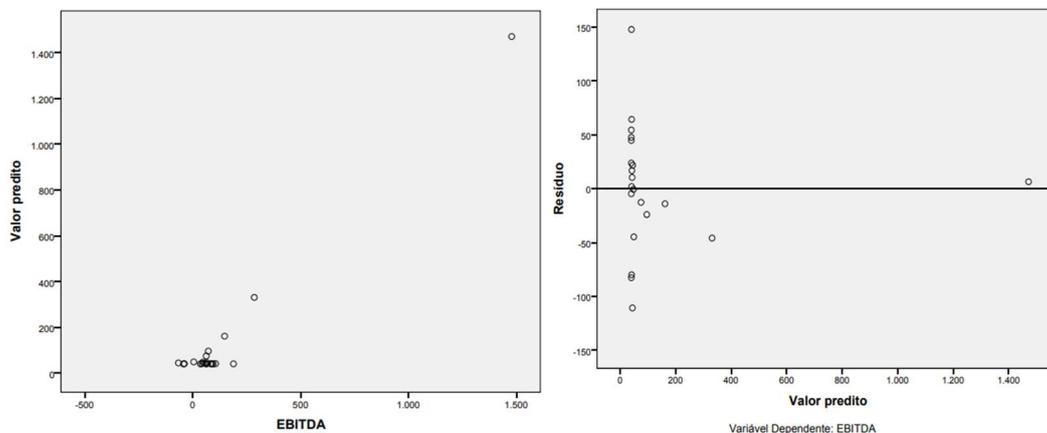


Figura 3 e 4: Gráfico do valor predito pelo valor observado e gráfico de resíduos por predito.

Tabela 7: Importância da variável independente.

	Importância	Importância normalizada
Rentabilidade sobre Vendas	,178	41,5%
Capital Circulante Líquido	,205	47,7%
Liquidez Geral	,186	43,2%
Endividamento Geral	,430	100,0%

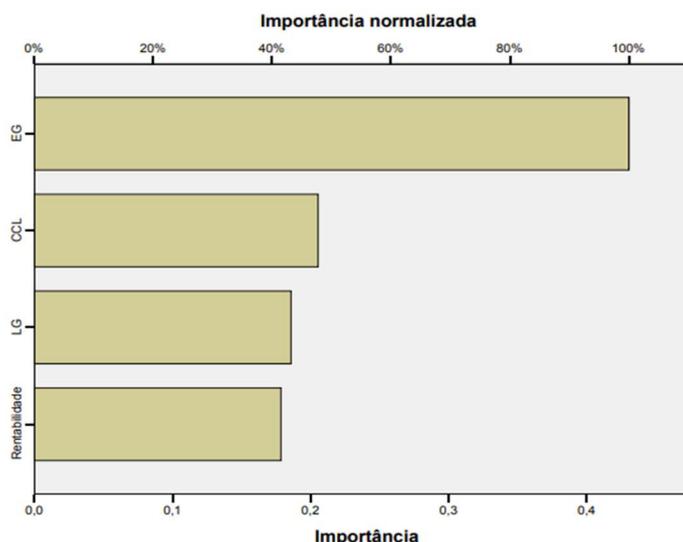


Figura 5: Gráfico da importância da variável independente.

A Ilustração 5 revela a significância de cada variável para a RNA. Essa análise é construída com base nos valores empregados para treinamento e testes, observa-se que o endividamento geral foi utilizado em sua totalidade enquanto as informações de rentabilidade concederam com até 41,5 %. Note que de forma diferente de outros modelos de previsão, sobretudo os esquemas econométricos, nesta situação a teoria sugere que uma variável de baixa importância deve ser retirada do modelo em RNA isso não é indicado, pois como já demonstrado, o modelo 'aprendeu' com essas quatro variáveis, em caso de remoção e/ou adição de variáveis, o modelo e a conduta dos pesos sinápticos se convertem sem nenhuma inspeção do pesquisador.

CONCLUSÃO

A pesquisa acima abordou sobre a aplicação das redes neurais artificiais na indústria petrolífera, a literatura indicou essa tecnologia como uma das que obteve maior crescimento nos últimos anos, apesar de sua estagnação no século passado, em decorrência de algumas limitações que foram contornadas por pesquisadores, como foi citado no breve histórico.

De início aplicou-se a correlação de Pearson para mensurar a relação entre as variáveis, da qual se concluiu que todas as variáveis apresentavam uma forte correlação positiva, o que era esperado, pois possuíam relações produtivas associadas. Observou-se que esse tipo de associação pode ser um problema caso a técnica de predição não fosse a RNA, pois pode haver problemas com a especificação do modelo e autocorrelação.

Logo em seguida, esta pesquisa procurou edificar e demonstrar o modelo de RNA previsto, então com o ingresso do EBITDA como variável dependente e variável preditiva a rentabilidade sobre vendas (em %), capital circulante líquido (em US\$ milhões), liquidez geral (em US\$ milhões) e endividamento geral (em %) (variáveis independentes) no software SPSS. Esse objetivo foi alcançado satisfatoriamente, pois os testes realizados apresentam valores e observações que imputam a RNA a capacidade de prever satisfatoriamente o EBITDA no Brasil.

O estudo mostra sua pertinência a partir do momento em que discutimos significantes atividades econômicas na região nacional. Isso se deve especialmente ao uso de tecnologia de inteligência artificial para avaliar EBITDA no Brasil. Portanto, esse modelo treinado e validado pode ser aplicado por órgãos públicos e pelos responsáveis do setor para tomar decisões sobre suas finanças. Por fim, sugere a realização de novos estudos, como inserção de novas variáveis no modelo, ou a utilização dos dados coletados para este artigo em outras técnicas de previsão a fim de comparar a capacidade preditiva.

REFERÊNCIAS

ABREU, I. G.; GONÇALVES, M. R.; OLIVEIRA, I. M.. Predição de séries temporais: estudo de caso utilizando técnicas de redes neurais artificiais para previsão da produção nacional de petróleo. *Interdisciplinary Scientific Journal*, v.5, n.1, 2018.

AGUIAR, F. G.. **Utilização de Redes Neurais Artificiais para detecção de padrões de vazamento em dutos**. Dissertação (Mestrado em Engenharia Mecânica) - Universidade de São Paulo, São Paulo, 2010.

ARAÚJO, M. G.. **Previsão da curva de produção para projeto exploratório utilizando redes neurais artificiais**. Dissertação (Mestrado em Engenharia Mecânica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2020

CARNEIRO, J. B. A. J.; SOUZA, C. C.. Aplicação de redes neurais artificiais na previsão do produto interno bruto do Mato Grosso do Sul em função da produção de cana-de-açúcar, açúcar e etanol. *Revista Ibero-Americana de Ciências Ambientais*, v.10, n.5, 2019.

FURTADO, A. T.. Indústria do Petróleo e Gás Natural: uma

vocação desperdiçada. *Cadernos do Desenvolvimento*, v.14, n.24, p. 55-175, 2019.

FURTADO, M. I. V.; FURTADO, R. C.. Estudo avaliativo da emissão de CO2 a partir de combustíveis fósseis utilizando Redes Neurais. *Conhecimento & Diversidade*, v.11, n.25, p.47-62, 2020.

GARRIDO, M. A.. **Otimização da locação de poços em reservatório de petróleo**. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, 2019.

LOURAL, M. S.; SILVA, C. G. R. S.; MORTARI, V. S.. A Petrobras como agente do desenvolvimento produtivo no Brasil: importância e esvaziamento. Encontro Nacional de Economia Industrial e da Inovação, 4. *Anais*. Campinas, 2019.

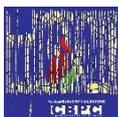
NEIS, Lucas Ribeiro et al. **Machine learning na área do petróleo: implementação de redes neurais para aprendizado de distribuições de probabilidade**. Trabalho de Conclusão de Curso (Graduação em Ciências da Computação) – Universidade Federal de Santa Catarina, Florianópolis, 2019.

SAMPAIO, T. P.. **Ajuste de histórico de produção usando Redes Neurais Artificiais**. Trabalho de Conclusão de Curso (Graduação em Engenharia de Petróleo) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009.

SILVA, F. F.. Um Comparativo de redes neurais artificiais e modelos tradicionais de séries temporais: uma previsão do preço do petróleo. **Interdisciplinary Scientific Journal**, v.4, n.4, 2018.

Os autores detêm os direitos autorais de sua obra publicada. A CBPC – Companhia Brasileira de Produção Científica (CNPJ: 11.221.422/0001-03) detêm os direitos materiais dos trabalhos publicados (obras, artigos etc.). Os direitos referem-se à publicação do trabalho em qualquer parte do mundo, incluindo os direitos às renovações, expansões e disseminações da contribuição, bem como outros direitos subsidiários. Todos os trabalhos publicados eletronicamente poderão posteriormente ser publicados em coletâneas impressas ou digitais sob coordenação da Companhia Brasileira de Produção Científica e seus parceiros autorizados. Os (as) autores (as) preservam os direitos autorais, mas não têm permissão para a publicação da contribuição em outro meio, impresso ou digital, em português ou em tradução.

Todas as obras (artigos) publicadas serão tokenizadas, ou seja, terão um NFT equivalente armazenado e comercializado livremente na rede OpenSea (https://opensea.io/HUB_CBPC), onde a CBPC irá operacionalizar a transferência dos direitos materiais das publicações para os próprios autores ou quaisquer interessados em adquiri-los e fazer o uso que lhe for de interesse.



Os direitos comerciais deste artigo podem ser adquiridos pelos autores ou quaisquer interessados através da aquisição, para posterior comercialização ou guarda, do NFT (Non-Fungible Token) equivalente através do seguinte link na OpenSea (Ethereum).

The commercial rights of this article can be acquired by the authors or any interested parties through the acquisition, for later commercialization or storage, of the equivalent NFT (Non-Fungible Token) through the following link on OpenSea (Ethereum).



<https://opensea.io/assets/ethereum/0x495f947276749ce646f68ac8c248420045cb7b5e/44951876800440915849902480545070078646674086961356520679561157909956429611009/>