



**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA PREDIÇÃO DE PREÇOS DE  
AÇÕES POR INDICADORES FINANCEIROS**

**APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN PREDICTION OF  
SHARE PRICES BY FINANCIAL INDICATORS**

**Eunice Henriques Pereira Vilela**

Universidade Federal de Uberlândia, Uberlândia, MG, Brasil  
eunice.hvilela@gmail.com

**Antonio Sergio Torres Penedo**

Universidade Federal de Uberlândia, Uberlândia, MG, Brasil  
drpenedo@gmail.com

**Vinicius Silva Pereira**

Universidade Federal de Uberlândia, Uberlândia, MG, Brasil  
viniciuss56@gmail.com

---

**Resumo**

O trabalho tem como objetivo desenvolver um modelo previsão de preços de ações negociadas na BM&FBovespa, utilizando, de forma conjunta, os indicadores tradicionais de rentabilidade, de liquidez e de endividamento utilizados em estudos empíricos sobre a temática, por meio de 8 indicadores. O modelo foi desenvolvido através das Redes Neurais Artificiais, uma metodologia relativamente nova e pouco aplicada na área de finanças. Os dados foram extraídos da base de dados Econômica, com séries trimestrais, o período de análise compreende os anos de 2012 a 2017 e a amostra é composta por 371 companhias. Como resultado, o modelo de rede neural artificial proposto apresentou desempenho satisfatório, entretanto não se pode concluir que os indicadores de desempenho são capazes de, sozinhos, fornecer informações suficientes para a rede.

**Palavras-chave:** Redes Neurais Artificiais; Indicadores de Desempenho; Previsão do Preço de Ações.

### **Abstract**

*The objective of this paper is to develop a proposal for BM & FBOVESPA trading prices, using the alignment of profitability, liquidity and indebtedness rules in studies on the principles of a strategy, using 8 indicators. The model was developed through Artificial Neural Networks, a relatively new and poorly applied methodology in the area of finance. The data were extracted from the Economática database, with quarterly, the period of complete analysis of the years from 2012 to 2017 and the measurement is done by 371 companies. As a result, the neural network model was adopted as a satisfactory performance model, although it is not able to model neural networks.*

**Keywords:** Artificial Neural Networks; Performance indicators; Stock Price Forecast.

## **1. Introdução**

Conhecido como o pai da macroeconomia, Keynes (1982), defendia que as decisões de investimento se baseiam nas expectativas dos investidores, que buscam sempre a maximização de seus lucros. De acordo com ele, expectativas constituem um guia que orienta os empresários na decisão de investir.

No mercado de capitais, uma das importantes decisões de investimento refere-se à decisão de compra e vendas de ações, com base no preço praticado e no preço futuro. Entretanto, nesse mercado, muitas vezes as expectativas dos investidores acabam sendo frustradas por variações repentinas no preço das ações.

Por essa razão, estudos que buscam compreender e prever variações no preço de ações são recorrentes tanto na área de finanças quanto em áreas como estatística, matemática e computação. No Brasil, existem trabalhos como os de Procianoy e Antunes (2001) que analisam os efeitos das decisões de investimento das empresas sobre os preços de suas ações, Galdi e Lopes (2008) sobre a relação entre o lucro contábil e o preço das ações; e Schiehll (1996) a respeito do efeito da divulgação das demonstrações financeiras no mercado de capitais. Além de diversos estudos internacionais sobre o tema (Schöneburg, 1990; Wang, 2002; Patel, 2015) existem trabalhos que buscam verificar relação entre indicadores contábeis e de desempenho e o valor de mercado das empresas (Toledo Filho *et al.*, 2012; Silva & Santos, 2015; Kuhl, 2007; Barbosa & Silva, 2014; Oliveira *et al.*, 2017).

Com o desenvolvimento de novos softwares e tecnologias na área de inteligência artificial a ciência da computação vem assumindo cada vez mais papel de destaque nessa busca. Modelos de redes neurais para predição de preço de ações já foram utilizados por diversos pesquisadores, dentre os quais se destacam, Muller (1996), Freitas e Silva (1999), Cartacho (2001), Freitas e Souza (2002), Mello (2004), Oliveira Jr. (2007) e Amoroso (2009). Kara, Boyacioglu e Bayakan (2011), por exemplo, propuseram modelos de previsão baseado em Redes Neurais que utilizam dez indicadores técnicos dos modelos propostos.

Diante desse cenário de crescente interesse por novos modelos de previsão, o objetivo deste trabalho é desenvolver um modelo neural para previsão de preços de ações negociadas na BM&FBovespa, utilizando os indicadores de desempenho econômico-financeiros das empresas. Busca-se, com isso, verificar se o desempenho empresarial medido pela cotação das ações reflete o desempenho medido pelos indicadores econômico-financeiros, através da comparação dos resultados com os preços reais. Assume-se como pressuposto para elaboração do modelo neural que os indicadores de desempenho econômico-financeiros são a melhor forma de se medir o desempenho empresarial (Kuhl, 2007).

Para configuração do modelo foram definidos como variáveis de entrada os indicadores de desempenho econômico-financeiros: Giro do Ativo, Retorno sobre o ativo, Retorno sobre o patrimônio líquido, Margem Líquida, EBITDA, Margem EBITDA, Liquidez corrente e Participação do capital de terceiros. Os dados utilizados foram extraídos da base Economática, sendo estes dados trimestrais de 371 empresas listadas na BM&FBovespa entre 2012 e 2016.

Foi utilizado como base para definição das variáveis, a pesquisa de Oliveira, Viana Júnior, Ponte e Domingos (2017), que investigaram a relação entre os indicadores de desempenho e o valor de mercado das companhias listadas na BM&FBovespa, por meio da análise de seis variáveis de desempenho em correlações de Pearson e regressões lineares múltiplas com dados em painel. Este estudo se utilizou apenas das variáveis que se referem à rentabilidade e a lucratividade. Para complementar o modelo foram incluídas também variáveis referentes à liquidez e endividamento, com base no estudo de Kuhl (2007).

O presente estudo busca, portanto, contribuir para a literatura acerca do tema analisando de forma conjunta os indicadores tradicionais de rentabilidade, de liquidez e de endividamento utilizados em estudos empíricos, através do uso de redes neurais artificiais, metodologia ainda recente e pouco aplicada a estudos com essa abordagem.

## **2. Referencial teórico**

## 2.1. Desempenho empresarial e indicadores de desempenho

O desempenho empresarial é tema recorrente em qualquer empresa, uma vez que reflete sua estratégia administrativa e por consequência seu sucesso, de acordo com Oliveira et al.(2017), estando, dessa forma intrinsecamente interligado à administração estratégica.

O termo desempenho, no sentido *lato*, conforme Carnut e Narvai (2016) refere-se a um conjunto de características ou capacidades de comportamento e rendimento de um indivíduo, organização ou grupo de seres humanos, de animais ou de outros seres vivos, de máquinas ou equipamentos, produtos, sistemas, empreendimentos ou processos, em especial quando comparados com metas, requisitos ou expectativas previamente definidos.

Estritamente ao conceito de desempenho empresarial cabem diversas definições e discussões. A corrente mais antiga e tradicional descreve o desempenho como superação de metas (Cameron, 1981; Kanter & Brinkerhoff, 1981). Entretanto, em meados dos anos 1970 surgiram duas novas correntes, conforme Santos (2008). A primeira, apresentada por Seashore e Yuchtman (1967), defendia que o desempenho da organização era função da eficiência de suas estruturas e processos, e, a segunda pregava que o desempenho era função da capacidade da empresa de obter recursos do ambiente e se adaptar a ele.

Existem também estudos que discutem a definição da análise e mensuração do desempenho, como o de Neely et al. (1995), que definiram como sendo o processo de se quantificar uma ação, no qual a mensuração é o processo de quantificação por meio da coleta, análise e interpretação dos dados obtidos, e a ação é aquilo que provoca o desempenho. É através desta avaliação que os gestores identificam as falhas das organizações e se preparam para enfrentar as mudanças no ambiente empresarial. Sendo papel fundamental dos avaliadores a definição dos indicadores adotados.

Os indicadores de avaliação de desempenho organizacional, adotando nessa pesquisa, conforme Oliveira *et al.* (2017) são instrumentos gerenciais amplamente abordados na Contabilidade Gerencial, pois expõem a situação econômico-financeira das empresas, sendo, dessa forma, de extrema importância para o processo de tomada de decisão.

De acordo com Omaki (2005) e Macedo e Corrar (2010), apesar das limitações, o uso de indicadores econômico-financeiros continua sendo a prática mais comum e mais estudada por pesquisadores como estimador coerente de mensuração do desempenho organizacional. Tal análise visa extrair informações das demonstrações financeiras e dos demais relatórios, a fim de interpretar quantitativamente os efeitos das decisões tomadas pela empresa (Costa *et al.*, 2011, p. 15).

De modo geral, os indicadores de desempenho podem ser classificados como econômicos ou financeiros. Sendo que o primeiro tipo revela a situação econômica da empresa, estando intrinsecamente relacionado com os resultados econômicos e geralmente representado pelos indicadores de rentabilidade. E o segundo expressa o desempenho voltado à geração de caixa, e que de forma habitual tem por referência o EBITDA (em inglês, *Earnings Before Interest, Taxes, Depreciation and Amortization*), indicador que representa a geração operacional de caixa da companhia.

## **2.2. Avaliação de empresas e valor de mercado das ações**

O conceito de *Valuation* ou Avaliação de Empresas vem se destacando, conforme Padovani *et al.* (2011), no meio corporativo devido à grande importância de se conhecer adequadamente o valor de um empreendimento, seja para aplicá-lo em casos de fusões, aquisições, acompanhamento do desempenho dos administradores ou até mesmo como ferramenta de gestão para tomada de decisões.

A avaliação de empresas envolve não somente variáveis objetivas como preço de ações e o próprio patrimônio das empresas, mas também variáveis subjetivas como credibilidade no mercado, valor da marca da empresa ou de seus produtos (Müller & Teló, 2017). O processo de avaliação de uma empresa é tido como complexo, isto porque a qualidade das informações utilizadas conforme Perez e Famá (2003) é condição *sine qua non* para a eficiência do produto final.

São vários os métodos adotados para o cálculo do valor de uma empresa, e várias formas de classificá-los, que variam de autor para autor. Cornell (1994, pp 10-11) identifica quatro modelos de avaliação de empresas bastante utilizados, que seriam: a) avaliação pelo valor de livro ajustado, b) avaliação de ações e dívidas, c) avaliação por múltiplos de mercado e d) avaliação pelo fluxo de caixa descontado.

Copeland, Koller e Murrin (2002), por outro lado, enumeram formas indiretas de indicar o valor de uma empresa, sendo elas: o lucro por ação, o retorno sobre o patrimônio líquido e o valor de mercado adicionado (sigla e significado em inglês, MVA – *Market Value Added*), entre outros. Já segundo Damodaran (2005, p.11), seriam três as abordagens para a avaliação: a Avaliação por Fluxo de Caixa Descontado; a Avaliação Relativa e; a Avaliação de direitos contingentes.

No entanto, conforme Padovani *et al.* (2011) apesar da diversidade conceitos e técnicas de avaliação prescritos na teoria das finanças e também na teoria da contabilidade são as transações ocorridas de fato em um mercado, influenciadas por vários fatores

circunstanciais, que determinam verdadeiramente o preço de um ativo. Com afirmam Perez e Famá (2003), enquanto o valor é relativo e depende de vários fatores, muitos deles subjetivos, o preço é único, exato e preciso, e reflete fielmente a mensuração financeira de uma transação de compra e venda de determinada empresa.

Por esse motivo, Perez e Famá (2003) destacam o modelo de avaliação com base no valor das ações em bolsas de valores, um método simples e válido apenas para sociedades anônimas de capital aberto e cujas ações sejam negociadas em bolsa. Que tem como premissa básica a teoria de eficiência do mercado, e apura o chamado valor de mercado da empresa.

Sobre o preço de uma ação em bolsa de valores, Galdi e Lopes (2008) afirmam que este é função de um conjunto de fatores que interagem formando a expectativa do mercado sobre o desempenho futuro da empresa e da economia. Assim, de todos os índices que podem ser utilizados para julgar o desempenho de uma empresa de capital aberto, o preço das ações é o mais identificável (Damodaran, 2002, p. 29), sendo que estes, em um mercado racional, tentam refletir os efeitos a longo prazo de decisões tomadas pela empresa.

A análise das variações do valor das ações e sua tendência podem ser feitas a partir de duas abordagens, a fundamentalista e a técnica. Mas, conforme Kuhl (2007) é difícil encontrar no mercado, analistas de investimento que utilizem apenas de uma das abordagens acima, mas sim, simultaneamente, já que a primeira serve para determinar em quais ações investir e a segunda, em qual momento.

A análise fundamentalista envolve, além da própria empresa, diferentes contextos e aspectos que influenciam o seu desempenho como, o ambiente econômico, nacional e internacional, o setor de atividade a que pertence a empresa e a comparação com outras empresas do mesmo setor. Já a análise técnica baseia-se nas variações ocorridas nos preços e nos volumes negociados, com objetivo de prever o comportamento dos preços das ações a partir da utilização de gráficos que demonstram os movimentos ascendentes ou descendentes dos preços (Kuhl, 2007).

Por outro lado, existem as teorias do passeio aleatório dos preços das ações (*handon walk*) e a hipótese do mercado eficiente (HME), propostas por Eugene Fama em 1965 e 1969, respectivamente. Segundo ele os preços das ações apresentam um comportamento randômico que não pode ser previsto com base no seu comportamento histórico e, tampouco, em informações disponíveis no mercado, já que qualquer informação é rapidamente absorvida pelo mercado.

Para Fama (1970) os preços representam um sinal preciso do verdadeiro valor dos ativos, e os seus retornos devem apresentar independência serial, sendo impossível para

qualquer investidor usar estratégias ou informações diferenciadas para obter vantagens no mercado de capitais antes dos demais investidores, mesmo que estas informações sejam de caráter privado da empresa emitente do título.

A hipótese de mercado eficiente (Fama, 1970) estabelece que um mercado é eficiente quando os preços dos títulos que o compõem refletem integralmente todas as informações disponíveis naquele momento, não havendo possibilidade de se obter lucros anormais, devido à homogeneidade de informações disponíveis para todos os investidores. Sendo que, segundo Sharpe *et al.* (1995) qualquer disparidade substancial que houver entre o preço e o valor de uma ação indica que existem ineficiências no mercado de capitais.

### **2.3. Utilização de redes neurais artificiais em finanças**

Conforme Paiva (2014), inúmeros autores já se dedicaram à procura de dados passados que permitissem explicar e inferir valores futuros do mercado acionário possibilitando, assim, ganhos extraordinários. Convencionalmente seus estudos costumam se basear nos fundamentos da HME que defende que a tarefa de prever preços futuros, tendo como base comportamentos passados de um ativo financeiro, é um procedimento ineficaz, pois a distribuição de uma série financeira advém de um movimento browniano, que é concebido por características randômicas e independentes.

Entretanto, em dissonância a concepção da HME, alguns resultados de importantes estudos que sugerem que o mercado acionário não é aleatório, permitindo que, uma vez identificados padrões de comportamento seja possível delinear modelos de previsibilidade. Frente a essas lacunas têm se destacado nos últimos anos, avanços no ramo nas finanças computacionais (Paiva, 2014).

Almeida (1995) afirmava já na década de 1990 que as redes neurais estavam propondo soluções a problemas de várias áreas de administração, como finanças, marketing, vendas e compras, entre outras. Recentemente, em seu estudo bibliométrico Santos *et al.* (2016) destacaram a existência de problemas em finanças e contabilidade que não podem ser resolvidos facilmente através de técnicas tradicionais, como a previsão de falências e as estratégias para negociação em bolsas de valores. Concluindo assim que nestes casos o uso de métodos de inteligência computacional como as redes neurais artificiais seria uma das alternativas mais viáveis.

Neste contexto, Paiva (2014) destacou que os modelos baseados em técnicas de inteligência artificial apresentam-se como bastante interessantes, graças a sua capacidade de tratar dados complexos, imprecisos e volumosos. Em suas palavras, “os estudos dessa técnica,

em questões no âmbito das finanças tem se mostrado bastante eficientes, principalmente em decorrência da possibilidade de trabalhar com dados ruidosos, além de prever sistemas não lineares”.

A rede neural artificial é uma técnica de inteligência sofisticada estruturada sob a dinâmica de processamento de dados inspirada na arquitetura do cérebro humano. Conforme Haykin (2001), esta pode ser entendida como um processador maciço, paralelo, distribuído e constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Assemelhando-se ao cérebro humano em dois aspectos: 1) O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; 2) Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O grande apelo por estes modelos, de acordo com Vicente (2002) é compreendido pela sua capacidade de “aprender”, generalizar ou extrair regras automaticamente de conjuntos de dados complexos. O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado. Além de sua estrutura, a rede neural também extrai poder computacional de sua capacidade de aprender e generalizar. A generalização para Haykin (2001) se refere ao fato da rede produzir saídas adequadas para entradas que não estavam presentes durante o treinamento.

As redes neurais artificiais utilizam o processamento distribuído, onde muitos elementos chamados neurônios ou unidades de processamento comunicam-se através de arestas exibindo um peso associado a cada uma destas. Cada uma dessas unidades efetua um certo número de operações e transmite seus resultados às unidades vizinhas. De acordo com Bosaipo (2001), estas operações consistem na multiplicação do valor de cada entrada pelo respectivo peso associado e na posterior soma para resultar em um valor. Geralmente este valor é passado através de uma função de ativação.

De forma similar ao ser humano, as redes neurais artificiais são capazes de aprender comportamentos através de exposição de exemplos dos mesmos. Este processo é denominado treinamento da rede. A informação é armazenada na rede e é incorporada à mesma durante a fase de treinamento (Bosaipo, 2001).

Diversos estudos internacionais vêm buscando utilizar modelos de redes neurais artificiais para solucionar problemas tradicionais na área de finanças. Como o trabalho de Odom e Sharda (1990) que desenvolveu um modelo de rede neural para previsão de falência

usando dados financeiros de várias empresas. O de Chung, Tan, e Holdsworth (2008) que criaram um modelo de previsão de insolvência usando análise discriminativa multivariada e rede neural artificial para a indústria financeira na Nova Zelândia. E o de West (2000) que utiliza as redes neurais para criação modelos de avaliação de risco de crédito.

Quanto ao uso de redes neurais para realizar previsões sobre ações em bolsas de valores, o trabalho de Kimoto, Asakawa e Takeoka (1990) criou um sistema de previsão de tempo de compra e venda de ações na Bolsa de Valores de Tóquio; Yoon e Swales(1991) desenvolveram um modelo de previsão do desempenho do preço das ações. Já Goçken et al. (2016) utilizam modelos de redes neurais para avaliar a eficácia do uso de indicadores técnicos, como a média móvel simples de preço próximo e o preço de fechamento do momento no mercado acionário turco. E Peng e Jiang (2015) aplicaram os métodos populares de incorporação de palavras e redes neurais profundas para alavancar as notícias financeiras para prever os movimentos dos preços das ações no mercado.

### **3. Metodologia**

#### **3.1. Variáveis**

Esta seção é dedicada à construção do modelo de redes neurais artificiais para estimação dos preços das ações das empresas selecionadas com base nos indicadores financeiros. A descrição detalhada e a estruturação do modelo foram estimadas no *software* Matlab 8.5.0.197613 R2015a.

A primeira etapa do trabalho consistiu na seleção e coleta de dados. Foi utilizada uma série de dados trimestrais referentes a 8 indicadores financeiros de 371 empresas listadas na BM&FBovespa, que apresentavam posição ativa em 8 de abril de 2017. Os dados são referentes ao período de 31 de março de 2012 a 31 de março de 2017, num total de 7420 observações, extraídas na base de dados Economática.

Após a extração, os dados foram padronizados. A padronização é um recurso bastante utilizado na estatística que consiste em subtrair de um valor de uma variável (conjunto de dados) a sua média e dividir o resultado pelo desvio padrão do conjunto ou variável. As oito variáveis utilizadas no modelo foram escolhidas com base na teoria e respectiva bibliografia pesquisada. O objetivo da escolha foi incluir indicadores de rentabilidade, de liquidez e de endividamento. A Figura 1 apresenta as variáveis utilizadas, o tipo de indicador, e os estudos que os utilizaram.

<b>Variável</b>	<b>Indicador</b>	<b>Fundamentação</b>
Giro do ativo (GA)	Rentabilidade e Lucratividade	Brunozi <i>et al.</i> (2016); Matarazzo (2003); Oliveira <i>et al.</i> (2017) Padoveze (2004); Iudícibus (2007)
Retorno sobre o ativo (ROA)	Rentabilidade e Lucratividade	Matarazzo (2003); Olinquevitch e Filho (2004); Assaf Neto (2010); Costa <i>et al.</i> (2011); Oliveira <i>et al.</i> (2017).
Retorno sobre o patrimônio líquido (ROE)	Rentabilidade e Lucratividade	Alves <i>et al.</i> (2013); Matarazzo (2003); Olinquevitch e Filho (2004); Padoveze (2004); Iudícibus (2007); Assaf Neto (2010); Oliveira <i>et al.</i> (2017)
Margem líquida (ML)	Rentabilidade e Lucratividade	Matarazzo (2003); Olinquevitch e Filho (2004); Padoveze (2004); Iudícibus (2007); Assaf Neto (2010); Costa <i>et al.</i> (2011); Oliveira <i>et al.</i> (2017)
EBITDA (EBT)	Rentabilidade e Lucratividade	Aillón <i>et al.</i> (2013); Frezatti e Aguiar (2007); Iudícibus (2007); Málaga (2012); Oliveira <i>et al.</i> (2017)
Margem EBITDA (ME)	Rentabilidade e Lucratividade	Aillón <i>et al.</i> (2013); Costa <i>et al.</i> (2011); Oliveira <i>et al.</i> (2017)
Liquidez Corrente (LC)	Liquidez	Kuhl (2007); Correia <i>et al.</i> (2014); Machado (2009)
Participação do Capital de Terceiros (PCT)	Endividamento	Kuhl (2007); Kayo (2012); Muller e Teló (2017)

**Figura 1 - Variáveis e Fundamentação**

Fonte: elaboração própria, baseado no trabalho de Oliveira, *et al.* (2017).

Segundo Finocchio (2014), os dados devem ser separados em duas categorias: os de treinamento e os de teste. Os dados de treinamento são utilizados para o treinamento da rede, e, os dados de teste são utilizados para verificar o desempenho no referente às condições reais

de utilização e a capacidade de generalização da rede. Nesse estudo foram realizadas 1000 observações aleatórias como dados de treinamento e as 6420 restantes como dados de teste.

### 3.2. Configuração da rede

A segunda etapa consiste a especificação da configuração da rede para que se possa executar a estruturação do modelo. Como destaca Finocchio (2014), existem algumas metodologias na condução dessa tarefa. Porém, normalmente, parte dessas escolhas é feita de forma empírica, uma vez que definição da configuração de redes neurais é ainda considerada uma arte que requer grande experiência dos projetistas.

O tipo de rede neural utilizada foi o *Multilayer Perceptron* (MLP) ou Rede de múltiplas camadas. Uma rede MLP é constituída por um conjunto de nós fonte, os quais formam a camada de entrada da rede (*input layer*), uma ou mais camadas escondidas (*hidden layers*) e uma camada de saída (*output layer*). Sendo que, com exceção da camada de entrada, todas as demais são constituídas por neurônios e apresentam capacidade computacional.

O método de aprendizagem utilizado foi o *feed forward backpropagation*. O algoritmo de aprendizagem *backpropagation* baseia-se na heurística do aprendizado por correção de erro, em que o erro é retro propagado da camada de saída para as camadas intermediárias da rede (Nardo Junior, 2005). Durante seu treinamento a rede opera em uma sequência de dois passos, fase *forward* e fase *backward*.

Na fase *forward*, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída ficando com os pesos sinápticos todos fixos. Enquanto na fase *backward*, a saída obtida é comparada á saída desejada para esse padrão. Se não estive correta, o erro é calculado e propaga a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retro propagado, no caminho do fluxo de sinal nas conexões sinápticas.

Os pesos sinápticos são, então, ajustados de forma que a resposta obtida aproxime-se mais do padrão de resposta desejado. A saída desejada para o padrão, denominada *target* deve ser fornecida a rede. Nesse trabalho o padrão utilizado foram às cotações médias das ações no trimestre.

Além do tipo de rede neural e do algoritmo de aprendizagem, algumas outras funções devem ser definidas para criar toda a arquitetura da rede. As funções de transferência ou funções de adaptação são definidas para que se obtenha a saída desejada que será apresentada a rede.

De acordo Finocchio (2014), normalmente são empregadas redes com duas ou três camadas de neurônios, as primeiras com funções de transferência sigmoidais e a última com função de transferência linear. Com base nessas definições, nesse trabalho foi adotada uma rede com duas camadas intermediárias, sendo a função de transferência escolhida para a primeira camada a função *losing* e para a segunda a função *pureling*.

A função de adaptação de pesos e bias, o que segundo Nardo Junior (2005), é utilizada para definir o tipo de treinamento que será aplicado aos neurônios que fazem parte do sistema, de forma a proporcionar o ajuste dos pesos de entrada para proporcionar a saída desejada. A função de adaptação utilizada nesse trabalho foi a LEARNNGDM, que é uma função de aprendizado gradiente descendente para pesos.

Também foi utilizada a função de treino de rede TRAINLN, que é responsável por aplicar o treinamento em uma rede neural. A medida de desempenho de rede adotada foi a MSE – *Mean Square Error* (Erro Quadrado Médio) que é a soma das diferenças ocorridas na saída gerada comparando-se a entrada, e elevando ao quadrado cada diferença calculada e multiplicando pelo inverso do total de elementos treinados.

O último passo dessa fase é definir a quantidade de neurônios da camada escondida da rede neural. O método utilizado para definição do número de neurônios da rede foi o modelo de Kolmogorov, definido pela equação:

$$n_2 = 2 \cdot n_1 + 1$$

onde:

$n_1$  – representa o número de variáveis de entradas da rede.

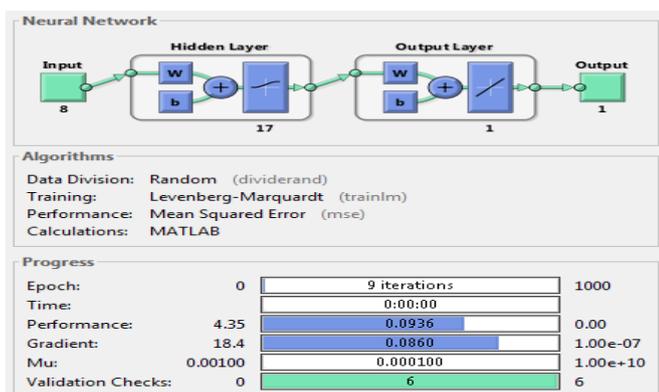
De acordo com o método de Kolmogorov chega-se ao número de 17 neurônios na primeira camada escondida da rede. Na segunda camada escondida a quantidade de neurônios é definida pelo próprio *software* Matlab.

### 3.3. Treinamento

A terceira etapa do trabalho consiste no treinamento da rede propriamente dito. Nesta fase, seguindo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. Para Finocchio (2014) é importante considerar, nesta fase, alguns aspectos tais como a inicialização da rede, o modo e o tempo de treinamento.

Uma boa escolha dos valores iniciais dos pesos da rede, segundo Finocchio (2014), isso pode diminuir o tempo necessário para o treinamento. Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada.

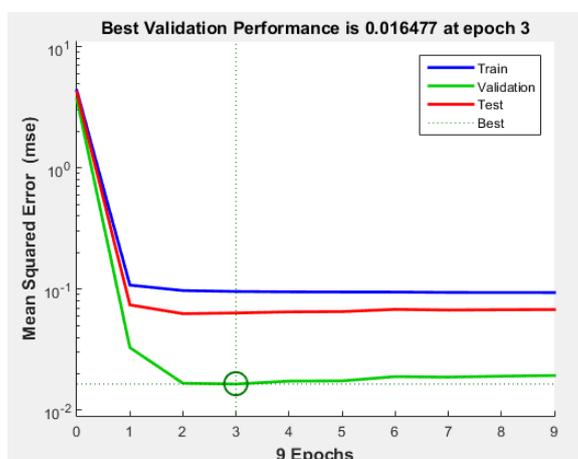
Os principais critérios de parada do algoritmo de aprendizagem são o número máximo de ciclos e o erro quadrático médio por ciclo. O treinamento deve então ser encerrado quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena. A seguir apresenta-se o modelo neural treinado conforme a arquitetura descrita anteriormente e seu desempenho no treinamento:



**Figura 2 - Tela de treinamento e estimação da RNA**

**Fonte: Matlab 8.5.0.197613 R2015a**

Como pode ser observado na figura 2, o modelo apresentou desempenho satisfatório e fez 9 interações instantaneamente, ou seja, com um gasto de tempo computacional mínimo. Na figura 3 foi plotada a performance do modelo que permite uma melhor visualização de seu desempenho, destacando que o modelo chegou a seu melhor resultado com 3 épocas de treinamento.



**Figura 3: Performance do Modelo**

**Fonte: Matlab 8.5.0.197613 R2015a**

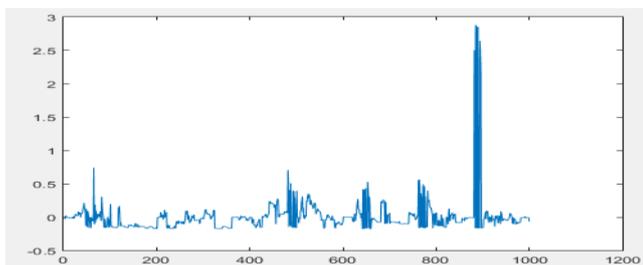
Uma época de treinamento, conforme Finocchio (2014) corresponde a cada iteração feita pela rede ao longo da pesquisa rumo ao erro mínimo entre saída calculada e saída real (convergência). O erro mínimo é alcançado através de reajustes das variáveis livres (pesos e bias dos neurônios).

#### 4. Discussão de Resultados

Nessa seção serão comparados e analisados os dados de saída obtidos através do modelo neural arquitetado, buscando identificar se os indicadores de desempenho das empresas são bons parâmetros para prever o preço de suas ações.

Após a rede ter sido treinada, chega-se a etapa de simular utilizando o conjunto de teste para determinar o desempenho da rede com dados que não foram previamente utilizados. É nessa fase que a rede fornece as saídas (*outputs*) e o erro para o conjunto de entradas fornecido.

Uma análise dos erros permite avaliar a eficácia do modelo desenvolvido. Na área de trabalho do *software* Matlab é possível plotar graficamente a sequência de dados gerados pela rede neural para uma melhor visualização dos resultados.

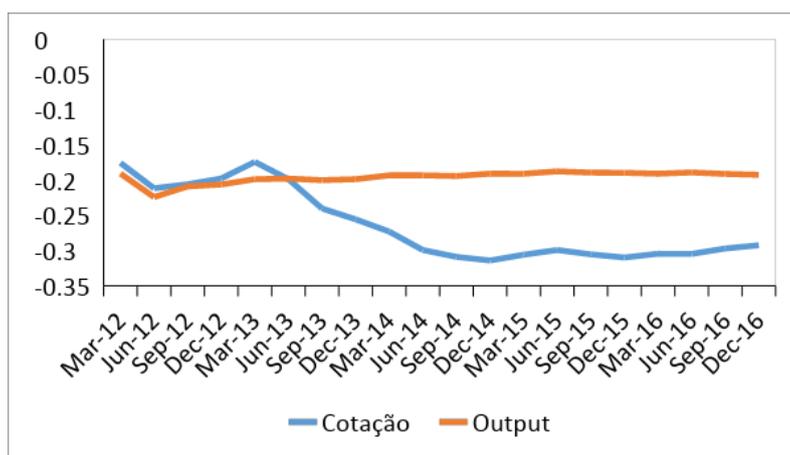


**Figura 4 – Estimações da Amostra com os Respectivos Erros**

**Fonte: Matlab 8.5.0.197613 R2015a**

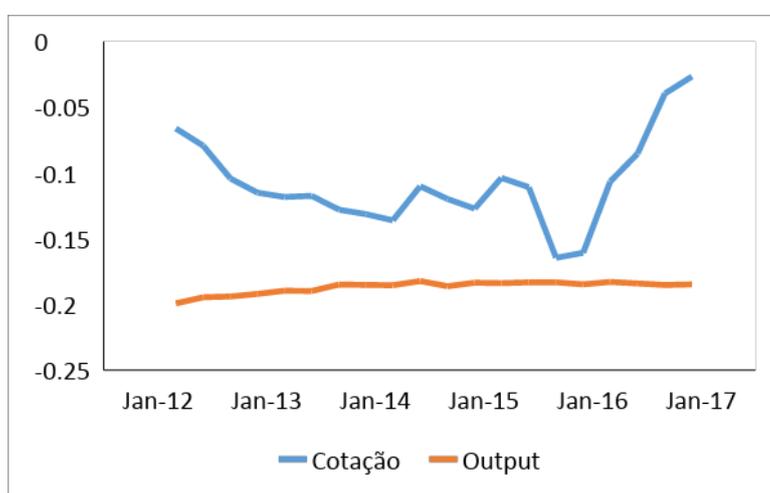
Observando a figura 4 percebe-se que o erro, na maioria das saídas, se manteve muito próximo de zero, sendo que o erro aumenta à medida que a estimacão se afasta muito da amostra. Assim partir dos dados apresentados, pode-se observar que o modelo consegue apresentar um grau de aderência robusto.

Para visualizar os resultados reais de maneira mais clara, optou-se pela elaboracão de gráficos comparativos entre as saídas da rede neural e o preço das açoes extraídos da base Economática de algumas das empresas consideradas no modelo. Os valores utilizados são os obtidos após a padronizacão dos dados. A escolha das empresas representadas graficamente se deu de maneira aleatória.



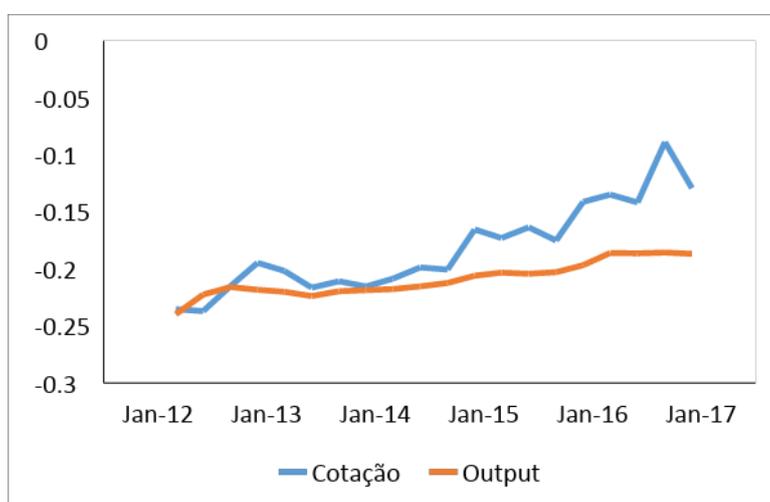
**Figura 5- Ação Springs**

**Fonte: Elaboração própria com dados no Economática e Matlab**



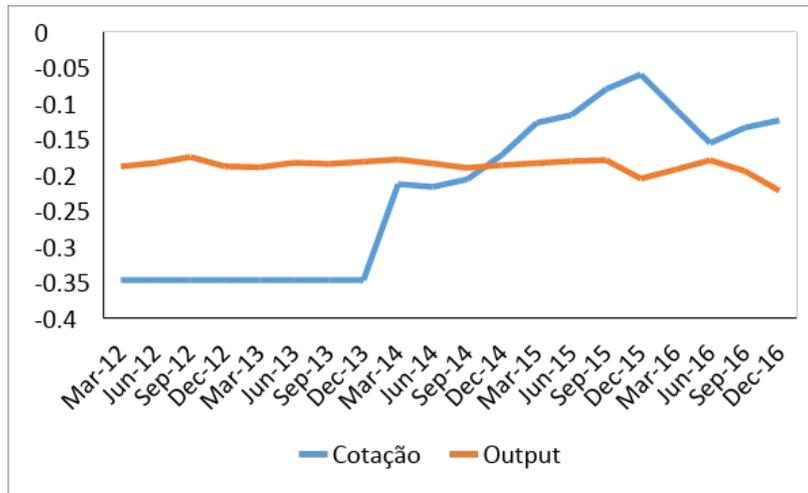
**Figura 6 - Ação CPFL Energia**

**Fonte: Elaboração própria com dados no Economática e Matlab**



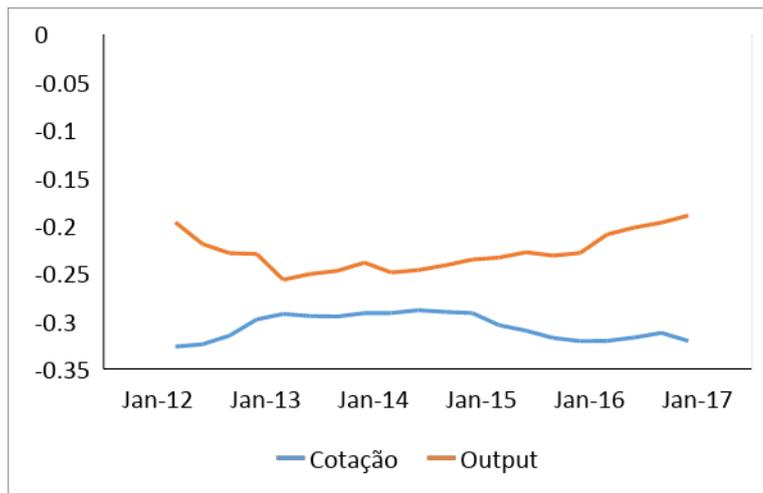
**Figura 7 - Ação Lojas Americanas**

**Fonte: Elaboração própria com dados no Economática e Matlab**



**Figura 8 - Ação Klabin S/A**

**Fonte: Elaboração própria com dados no Economática e Matlab**



**Figura 95 – Ação Portobello**

**Fonte: Elaboração própria com dados no Economática e Matlab**

Como pode ser observado nos gráficos acima, nem sempre os *ouptus* gerados pela rede neural acompanharam o sentido da variação de preços das ações. No geral, os valores fornecidos pela rede neural variam menos que os preços reais das ações. Um dos fatores que pode justificar essa imprecisão do modelo é a existência de fatores externos às empresas que ocasionam variações na demanda pelas ações, e conseqüentemente, alteração nos preços, que as redes neurais não conseguem prever. Tais como fatores macroeconômicos, políticos ou até mesmo de informações disponibilizadas.

## 5. Considerações Finais

O modelo de rede neural artificial proposto apresentou uma performance satisfatória durante o tempo decorrido entre seu treinamento e a realização de previsões dos preços das ações, sem que houvesse necessidade de ajuste dos pesos entre as conexões do modelo.

Nos casos em que não houve variações bruscas foi possível alcançar previsões extremamente próximas dos valores observados. Entretanto, as redes neurais apresentam desvios de menor magnitude quando comparados a outros métodos de previsão. Dessa forma, pode-se afirmar que os modelos baseados em Redes Neurais Artificiais não são capazes de identificar mudanças bruscas na tendência, e preveem desvios menores nos preços das ações, sendo capazes portanto, de realizar a previsões quando esses valores oscilam dentro de um padrão de normalidade.

Assim, a respeito da capacidade dos indicadores de desempenho empresarial serem utilizados como variáveis para previsão do preços das ações, tem-se que eles, explicam apenas em parte a variação dos preços das ações das empresas, as outras variações – aquelas que fogem da normalidade e, portanto a rede não é capaz de prever – geralmente estão associadas a fatores extrínsecos às ações, que afetam o mercado como um todo independentemente do desempenho econômico-financeiro das empresas. Entretanto, conforme ressaltaram Oliveira *et al.* (2017), podem haver também elementos intrínsecos a cada companhia, como a estrutura de capital, o capital intelectual, e a governança corporativa.

Há que se considerar também fatores psicológicos dos investidores, que muitas vezes fazem movimentos de compra e venda de ações que não podem ser justificados por ferramentas matemáticas. Nesses casos encontra-se a grande limitação das redes neurais. Apesar de sua arquitetura baseada no cérebro humano, os neurônios artificiais não são capazes de prever conexões baseadas em emoção.

Assim, mesmo considerando as limitações do modelo é possível afirmar o trabalho contribui para a literatura acerca da temática ao analisar de forma conjunta os indicadores tradicionais de rentabilidade com indicadores financeiros, de liquidez e de endividamento utilizados em estudos empíricos sobre a temática, através do uso de redes neurais artificiais, metodologia essa relativamente nova na área.

Destaca-se também a observação de uma amostra maior de empresas do que as comumente usadas em pesquisas desta natureza no Brasil, geralmente restritas a uma empresa ou a empresas de determinado setor econômico. Como limitação deste estudo destaca-se que a utilização de uma grande amostra de empresas gerou uma base de validação muito extensa,

que tende a aumentar os desvios. Recomenda-se que em estudos futuros sejam testados novos modelos e ajustes de rede no intuito de avaliar novas formas de interação das variáveis de desempenho, bem como a análise de efeitos sazonais e outras anomalias que possam ser relevantes no comportamento dos preços das ações.

## Referências

- Almeida, F. C. (1995). Desvendado o uso de redes neurais em problemas de administração de empresas. *Revista de Administração de Empresas*, 35(1), 46-55.
- Alves, J. F. V., Luca, M. M. M. de., Cardoso, V. I. C. & Vasconcelos, A. C. (2013). Relação entre desempenho econômico e desempenho ambiental de empresas no Brasil e na Espanha. *Revista Ambiente Contábil*, 5(2), 151-172.
- Amoroso, E. D. (2009). *Um estudo de caso sobre mineração de dados como instrumento de aprendizado para o investidor do mercado de ações*. Dissertação (Mestrado em Gestão do Conhecimento e Tecnologia da Informação) – UCB, Brasília.
- Assaf, A. Neto. (2010). *Finanças Corporativas e Valor*. (5a ed.). São Paulo, Atlas.
- Barbosa, G. C. & Silva, C. A. T. (2014). Utilização dos indicadores contábeis no processo de avaliação de empresas: A percepção de professores de contabilidade e de analistas de investimento. *Revista Ambiente Contábil*, 6(2), 170.
- Bosaipo, C. R. (2001). Aplicação das redes neurais na previsão do comportamento de mercados financeiros. *Revista de Informação e Tecnologia*.
- Cameron, K. (1981). Domains of organizational effectiveness in Colleges and Universities. *Academy Of Management Journal*, Nova Iorque, 24(1), 25-47.
- Carnut, L. & Narvai, P. C. (2016). Avaliação de desempenho de sistemas de saúde e gerencialismo na gestão pública brasileira. *Saúde e Sociedade*, 25(2), 290-305.
- Cartacho, M. S. (2001). *A utilização de um modelo híbrido Algoritmo Genético/Redes Neurais no processo de seleção de carteiras*. 2001. Dissertação (Mestrado em Administração) – Faculdade de Ciências Econômicas, UFMG, Belo Horizonte.
- Chung, K. C., Tan, S. S. & Holdsworth, D. K. (2008). *Insolvency prediction model using multivariate discriminant analysis and artificial neural network for the finance industry in New Zealand*.
- Copeland, T., Koller, T. & Murrin, J. (2002). *Avaliação de Empresas – Valuation: Calculando e gerenciando o valor das empresas*. (3a ed.). Tradução: Allan Vidigal Hastings. São Paulo, Makron Books Ltda.

- Cornell, B. (1994). *Corporate Valuate Tools for Effective Appraisal and Decision Making*. New York, Mc Graw Hill Co.
- Correia, L. F., Amaral, H. F. & Bressan, A. A. (2008). O efeito da liquidez sobre a rentabilidade de mercado das ações negociadas no mercado acionário brasileiro. *Revista de Administração e Contabilidade da Unisinos*, 5(2), 111-118.
- Costa, L. G. T. A. et al. (2011). *Análise econômico-financeira de empresas*. (3a ed.). Rio de Janeiro, GFV.
- Damodaran, A. (2002). *Finanças corporativas aplicadas: manual do usuário*. Bookman.
- Damodaran, A. (2005). *Avaliação de Investimentos – Ferramentas e técnicas para a determinação do valor de qualquer ativo*. Rio de Janeiro: Qualitymark
- Oliveira, F. A. de., Zárate L. E., Reis M. A. & Nobre C. N. (2011). *The use of artificial neural networks in the analysis and prediction of stock prices*. In: Systems, Man, and Cybernetics (SMC), 2011 IEEE International Conference on. IEEE. p. 2151-2155.
- Fama, E. F. (1970). *Multiperiod consumption-investment decisions*. The American Economic Review, p. 163-174.
- Finocchio, M. A. F. (2014). *Noções de Redes Neurais Artificiais*. Apostila. Universidade Tecnológica Federal do Paraná.
- Freitas, A. A. C. & Silva, I. N. (1999). Análise Técnica de Títulos Financeiros Através de Redes Neurais Artificiais. In: *CONGRESSO BRASILEIRO DE REDES NEURAI*, 4, 1999, São José dos Campos. *Anais do IV CBRN. São José dos Campos: ITA*, p. 67-71.
- Freitas, S. O. & Souza, A. A. (2002). Utilização de um modelo baseado em Redes Neurais para a precificação de opções. In: *ENCONTRO DA ASSOCIAÇÃO NACIONAL DE PÓSGRADUAÇÃO E PESQUISA EM ADMINISTRAÇÃO*, 26, 2002, Salvador. *Anais do XXVI ENANPAD*. Salvador: ANPAD.
- Frezatti, F. & Aguiar, A. B. (2007). EBITDA: possíveis impactos sobre o gerenciamento das empresas. *Revista Universo Contábil*, 3(3), 7-24.
- Galdi, F. C. & Lopes, A. B. (2008). Relação de longo prazo e causalidade entre o lucro contábil e o preço das ações: evidências do mercado latino-americano. *Revista de Administração-RAUSP*, 43(2).
- Goçken, M., Özçalıcı, M., Boru, A. & Dosdogru, A. T. (2016). Integrating metaheuristics and artificial neural networks for improved stock price prediction. *Expert Systems with Applications*, 44, 320-331.
- Haykin, S. (2001). *Redes Neurais: princípios e prática*. Porto Alegre, Bookman.
- Iudícibus, S. (2007). *Análise de balanços*. (8a ed.). São Paulo, Atlas.

- Kara, Y., Boyacioglu, M. A. & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert systems with Applications*, 38(5), 5311-5319.
- Kanter, R. M. & Brinkerhoff, D. (1981). Organizational performance: recent development in measurement. *Annual Review Of Sociology*. Palo Alto, 7, 321 – 349.
- Kayo, E. K. (2002). *A estrutura de capital e o risco das empresas tangível e intangível-intensivas: uma contribuição ao estudo da valoração de empresas*. Tese de Doutorado. Universidade de São Paulo.
- Keynes, J. M. (1982). *A teoria geral do emprego, do juro e da moeda*. São Paulo, Atlas.
- Kimoto, T., Asakawa K., Yoda M. & Takeoka M. (1990). *Stock market prediction system with modular neural networks*. In: *Neural Networks, 1990.*, 1990 IJCNN International Joint Conference on. IEEE, p. 1-6.
- Kuhl, M. R. (2007). *O mercado de capitais reflete no preço das ações o desempenho empresarial medido por indicadores contábeis?*.
- Macedo, M. A. S. & Corrar, L. J. (2010 jul-set). Análise do Desempenho Contábil-Financeiro de Seguradoras no Brasil no Ano de 2007: um Estudo Apoiado em Análise Hierárquica (AHP). *Revista Contabilidade Vista & Revista*, ISSN 0103-734X, Universidade Federal de Minas Gerais, Belo Horizonte, 21(3), 135-165.
- Machado, M. A. V. (2009). *Modelos de precificação de ativos e o efeito liquidez: evidências empíricas do mercado acionário brasileiro*.
- Mueller, A. (2017). *Uma Aplicação de Redes Neurais Artificiais na Previsão do Mercado Acionário*. 1996. Dissertação (Mestrado em Engenharia de Produção) - UFSC, Santa Catarina.
- Müller, A. N. & Teló, A. R. Modelos de avaliação de empresas. *Revista da FAE*, 6(2).
- Nardo, A Jr. (2005). *Aplicação de Redes Neurais utilizando o software MATLAB*.
- Neely, A., Gregory, M. & Platts, K. (1995). Performance measurement system design: a literature review and research agenda. *International journal of operations & production management*, 15(4), 80-116.
- Odom, Marcus D. & Sharda, R. (1990). *A neural network model for bankruptcy prediction*. In: *Neural Networks, 1990.*, 1990 IJCNN International Joint Conference on. IEEE, p. 163-168.
- Oliveira, W. Jr. (2007). *Estudo comparativo entre modelos lineares e redes neurais artificiais como tecnologias geradoras de previsões de valores financeiros*. Dissertação (Mestrado em Gestão do Conhecimento e Tecnologia da Informação) – UCB, Brasília.

- Oliveira, J. F., Viana, D. B. C. Jr., Ponte, V. M. R. & Domingos, S. R. M. (2017). Indicadores de desempenho e valor de mercado: Uma análise nas empresas listadas na BM&FBovespa. *Revista Ambiente Contabil*, 9(2), 240.
- Olinquevitch, J. L. & Filho, A. S. (2004). *Análise de balanços para controle gerencial*. (4a ed.). São Paulo, Atlas.
- Omaki, E. T. (2005). Recursos Intangíveis e Desempenho em Grandes Empresas Brasileiras: avaliações dos recursos intangíveis como estimadores de medidas de desempenho financeiras. In: *Encontro da Associação Nacional de Pós-Graduação e Pesquisa em Administração*, 29., 2005, Brasília. *Anais do XXIX ENANPAD*. Brasília: ANPAD, CD-ROM.
- Padovani, I. R., Maziero J. A., Vieira, L.B. & Medeiros, M. C. (2011). *Valuation - Avaliação de Empresas, Marfrig Alimentos S/A*. Centro Universitário Católico Salesiano Auxilium – Monografia.
- Paiva, F. D. (2014). *Redes neurais para decisões no mercado de ações brasileiro*.
- Patel, J., Shah, S., Thakkar, P. & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert Systems with Applications*, 42(1), 259-268.
- Peng, Y. & Jiang, H. (2015). *Leverage financial news to predict stock price movements using word embeddings and deep neural networks*. arXiv preprint arXiv:1506.07220.
- Perez, M. M. & Famá, R. (2003). Métodos de avaliação de empresas e o balanço de determinação. *Caderno de Pesquisas em Administração*, São Paulo, 10(4), 47-59.
- Procianoy, J. L. & Antunes, M. A. (2001). *Os efeitos das decisões de investimento das empresas sobre os preços de suas ações no mercado de capitais*. Campinas (Brasil): XXV ENANPAD, p. 163-83.
- Seashore, S. E. & Yuchtman, E. (1967). Factorial analysis of organizational performance. *Administrative Quarterly Science*, Nova Iorque, 12(3), 377-395.
- Santos, J. B. (2008). *Uma proposta de conceituação e representação do desempenho empresarial*. Tese de Doutorado.
- Santos, M. A., Souza, D. H. S., Penedo, A. S. T. & Martins, E. S. (2016). Aplicação de redes neurais no Brasil: um estudo bibliométrico. *Biblionline*, 12(2), 101-116.
- Sharpe, W. F., Alexander, G. J. & Bailey, J. V. (1995). *Investments*. Prentice Hall, Englewood, New Jersey. (5th ed.).
- Schiehll, E. (1996). *O efeito da divulgação das demonstrações financeiras no mercado de capitais brasileiro: um estudo sobre a variação no preço das ações*.

- Schöneburg, E. (1990). Stock price prediction using neural networks: A project report. *Neurocomputing*, 2(1), 17-27.
- Silva, C. T. R. & Santos, D. F. L. (2015). Desempenho financeiro e valor de mercado do setor de telefonia no Brasil. *Revista Ciências Administrativas*, 21(1), 42-67.
- Toledo, J. R. Filho., Krespi, N. T. & Theiss, V. (2012). Relação entre preço das ações e os indicadores contábeis: uma análise das empresas da BM&FBovespa. *Espacios*, 33(4).
- Vicente, R. (2002). *Redes Neurais para Inferência Estatística*. FEA/USP.
- Wang, Y. F. (2002). Predicting stock price using fuzzy grey prediction system. *Expert systems with applications*, 22(1), 33-38.
- West, D. (2000). Neural network credit scoring models. *Computers & Operations Research*, 27(11-12), 1131-1152.
- Yoon, Y. & Swales, G. (1991). *Predicting stock price performance: A neural network approach*. In: System Sciences, 1991. Proceedings of the Twenty-Fourth Annual Hawaii International Conference on. IEEE, p. 156-162.