

REDES NEURAIAS ARTIFICIAIS X REGRESSÃO COM DADOS EM PAINEL: PREVENDO O VALOR DE MERCADO DAS EMPRESAS

ARTIFICIAL NEURAL NETWORKS X REGRESSION WITH DATA IN PANEL: PREDICTING THE MARKET VALUE OF COMPANIES

Me. Valter Pereira da Silva¹
João Gonçalves Silva Muntaser²
Dr. Antonio Sergio Torres Penedo³
Dr. Vinícius Silva Pereira⁴

Resumo

O presente artigo vem com a proposta de realizar uma comparação entre ferramentas que possibilitem melhor previsão do valor de mercado: redes neurais artificiais ou regressão linear múltipla com dado em painel. Atualmente se tem o aperfeiçoamento matemático e estatístico, mas o erro pode ser causado pelo desconhecimento do pesquisador de todas as variáveis que impactam o elemento ou pela dificuldade de quantificação delas. Com isso, vêm as Redes Neurais Artificiais que, por sua característica não paralela e não paramétrica, é capaz de previsões mais assertivas, mesmo sem todas as variáveis. Para realizar esse estudo, foram coletados dados de 384 empresas listadas na BM&FBovespa, entre janeiro de 2011 a dezembro de 2015. Ao final do estudo se constatou que utilizar redes neurais artificiais minimiza o erro da previsão e independe da ponderação pela regressão linear múltipla com dados em painel.

Palavras-chave: Previsão; Redes Neurais Artificiais; Valor de Mercado

Abstract

This paper presents a comparison between which tool is best predicted: artificial neural networks or multiple linear regression with panel data. Despite the mathematical and statistical improvement present in the current time, the error can be caused by the lack of knowledge of the researcher, of all the variables that impact the element, or by the difficulty of quantifying them. With this comes the Artificial Neural Networks, which, due to its non-parallel and non-parametric characteristics, is capable of more assertive predictions, even without all the variables. For this, data were collected from the BM & FBovespa of 384 companies from January 2011 to December 2015. At the end of the study it was verified that using artificial neural networks minimizes the error of the prediction, and independent of the weighting by the multiple linear regression with data in panel

Keywords: Prediction; Neural networks; Market value

¹ Universidade Federal de Uberlândia – UFU / Faculdade de Gestão e Negócios - FAGEN

² Universidade Federal de Uberlândia – UFU / Faculdade de Gestão e Negócios - FAGEN

³ Universidade Federal de Uberlândia – UFU / Faculdade de Gestão e Negócios - FAGEN

⁴ Universidade Federal de Uberlândia – UFU / Faculdade de Gestão e Negócios - FAGEN

Introdução

A história da previsão está intimamente vinculada com a crença de destino. A partir do momento que o ser humano deixou de acreditar que se encontrava nas mãos dos deuses, começou a desenvolver mecanismos para controlar e prever seu futuro. Um mecanismo precursor para essas previsões foi a matemática simples, que foi se desenvolvendo para a estatística, aperfeiçoando assim essas ferramentas (BERNSTEIN, 1997).

Atualmente, se tem o aperfeiçoamento matemático e estatístico, porém o erro continua presente nas fórmulas. Esse erro pode ser causado pelo desconhecimento do pesquisador de todas as variáveis que impactam o elemento ou pela dificuldade de quantificação delas. Com isso, vêm as Redes Neurais Artificiais (RNA) que, por sua característica não paralela e não paramétrica, possibilitam previsões mais assertivas, mesmo sem todas as variáveis. Existem estudos comprovando que essa ferramenta produz menos erro que as Regressões Lineares Múltiplas, amplamente utilizadas nos estudos de finanças (HAYKIN, 2001; PALIWAL, KUMAR, 2009)

Nesta perspectiva, o objetivo geral deste trabalho consiste em avaliar qual ferramenta possibilita minimizar o erro de previsão do valor de mercado de 384 empresas listadas na bolsa de valores brasileira (BM&FBovespa), entre janeiro de 2011 e dezembro de 2015.

O trabalho se justifica por apresentar um detalhamento das medidas de comparação entre as ferramentas, tendo em vista a deficiência encontrada em diversos artigos financeiros que comparam essas formas de cálculo (PALIWAL, KUMAR, 2009). Além de comparar as ferramentas, será feita uma interseção entre elas, procurando apontar se a junção delas provocaria um melhoramento do resultado.

Com isso, esse artigo busca analisar estudos semelhantes sobre o tema, descrevendo melhor uma RNA, bem como a sua utilização no universo financeiro. Para tanto, descreveu-se como foram desenvolvidas as três ferramentas do estudo em questão, apresentando-se, em seguida, os resultados, a conclusão e as referências.

Referencial Teórico

Nesta seção, dividida em duas subseções, será feita uma descrição conceitual sobre redes neurais, bem como serão mencionados trabalhos que utilizaram essa metodologia na previsão do mercado financeiro.

Redes Neurais

Haykin (2001) define Rede Neural Artificial (RNA) como um processador maciço e paralelamente distribuído, com propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso através de uma unidade de processamento simples. Segundo o autor, redes neurais são semelhantes ao cérebro humano, visto que seu conhecimento é adquirido pela rede mediante um processo de aprendizagem, a partir de seu ambiente, em que esse conhecimento é armazenado devido a forças de conexão entre neurônios, denominados pesos sinápticos.

A respeito desse processo de aprendizagem, Barreto (2002) afirma que redes neurais possuem a capacidade de aprender por exemplos, de modo que são feitas interpolações do que foi aprendido. No aprendizado conexionista, o objetivo não é obter regras, mas determinar a intensidade de conexões entre neurônios. Visto que o conhecimento é armazenado nas conexões, o uso de RNA está intimamente ligado ao que se chama de conexionismo.

Cavalheiro *et al.* (2010) afirma que as redes neurais apresentam duas fases distintas em sua metodologia, a aprendizagem e o teste. Segundo os autores, na fase de aprendizagem são apresentados estímulos na entrada da rede, denominados padrões de treinamento que farão que o método encontre os mesmos dados que serão testados na fase de teste. Nessa fase de teste, é demonstrada a capacidade de generalização da rede, pois seus resultados deverão ser significativos, visto que seus pesos foram ajustados na fase anterior.

Kovács (2002) comenta que neurônios que recebem diretamente as entradas da rede constituem o que se chama de camada de entrada; neurônios que recebem como entradas as saídas daqueles da camada de entrada constituem a segunda camada e assim sucessivamente até a camada final, denominada camada de saída. As camadas internas que não são nem as de entrada nem as de saída são referidas como camadas ocultas.

Malik e Nasereddin (2006) afirmam que a camada oculta está entre a camada de entrada e a camada de saída e sua finalidade é identificar atributos especiais dos dados. Além disso, segundo os autores, o desenvolvimento de uma rede neural depende da composição da sua arquitetura, que é definida pela quantidade de neurônios que fazem parte das camadas de entrada e de saída, bem como do número de camadas ocultas e da quantidade de neurônios que a compõe.

Dentre os diversos tipos de redes neurais existentes, Haykin (2001) destaca três deles: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes. O autor afirma que redes alimentadas adiante com camada única

são a forma mais simples de uma rede multicamadas, em que se tem uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios, mas não vice-versa.

O segundo tipo de RNA é a rede alimentada diretamente com múltiplas camadas. Esse modelo se distingue do anterior pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos. Pela adição de uma ou mais camadas ocultas, é possível extrair estatísticas de ordem elevada, de modo que a rede adquira uma perspectiva global apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais (CHURCHLAND E SEJNOWSKI, 1992). Já as redes recorrentes se distinguem das redes neurais alimentadas adiante por terem no mínimo um laço de realimentação. Uma rede recorrente pode, por exemplo, consistir de uma camada de neurônios com cada um deles alimentando seu sinal de saída de volta para as entradas de todos os demais neurônios (HAYKIN, 2001).

Redes Neurais na previsão do mercado financeiro

O primeiro modelo para a previsão do mercado de ações que utilizou redes neurais foi desenvolvido por White (1988). O autor utilizou uma rede neural sem realimentação para analisar os retornos diários e detectar mudanças nos preços das ações da IBM, com o objetivo de testar a teoria do mercado eficiente proposta por Fama (1970), que afirma que os preços das ações de um ativo refletem as informações disponíveis sobre a instituição emissora, impossibilitando aos investidores qualquer ganho anormal. Embora os resultados encontrados por White (1988) não tenham alcançado níveis altos de predição, a pesquisa destacou o potencial existente para este tipo de análise.

Um estudo posterior conduzido por Freitas e Silva (1999) utilizou uma rede neural artificial para auxiliar na tomada rápida de decisões a partir da análise técnica de títulos financeiros. Mais especificamente, foi utilizada uma rede LVQ (*Learning Vector Quantization*) que é capaz de reconhecer e detectar os movimentos e oscilações do mercado financeiro. Os dados utilizados para o treinamento da rede foram reais e levaram em consideração expectativas sobre fatores de ordem econômica. Os resultados de simulação obtidos pelos autores confirmam que a rede pode ser usada eficientemente em problemas desse tipo.

Mais recentemente, a pesquisa de Ferreira et al. (2011) utilizou redes neurais como estratégia de previsão de preços no contexto do agronegócio. Foram utilizados dados de quatro *commodities*, a soja, o boi gordo, o milho e o trigo, no período de 1992 a 2006. A metodologia adotada durante a pesquisa foi o modelo de rede neural *perception*, que segundo Hair et al.

(2005), é o mais frequentemente utilizado. A pesquisa concluiu que o modelo apresenta uma alta capacidade preditiva, podendo, portanto, afirmar que a prática do uso de redes neurais artificiais pode ser agregada ao processo decisório referente ao comportamento dos preços de commodities agrícolas.

O trabalho de Ferreira, Vasconcelos e Adeodato (2005) apresentou um novo método de previsão a partir de séries temporais, que realiza um processo evolutivo com o intuito de procurar um número mínimo necessário de dimensões a serem consideradas no problema de determinar as características espaciais da série histórica. O método proposto consiste em um modelo híbrido inteligente, composto de uma rede neural artificial. O erro médio obtido com o modelo foi de 1,85, o que sugere que redes neurais são capazes de prever a série do mercado de ações com precisão significativa.

A pesquisa de Oliveira, Nobre e Zárate (2013) propôs o desenho de um modelo baseado em RNA que permitiu prever o comportamento dos preços das ações da Petrobrás no curto prazo, pela combinação de análise técnica, fundamentalista e de séries temporais. Os autores obtiveram níveis de predição acima de 84% em todos os modelos construídos, sendo de 93,62% o melhor resultado na previsão de preços da PETR4.

Metodologia

Nesta seção, serão descritos quais os dados e por que foram utilizados para alimentar e treinar a rede. Em seguida, será explicitado como se dá a regressão linear múltipla, para posteriormente ser abordada a rede neural e apresentado o resultado da junção das duas ferramentas.

Dados

Neste artigo tomou-se como base o estudo de Oliveira, Nobre e Zárate (2013), no qual se buscou a previsão do preço da ação da Petrobrás PETR4. Adotou-se esse estudo pelo fato de ele ter passado por uma validação externa, com especialistas de mercado, bem como uma interna, com a regressão linear múltipla, para assim selecionar as variáveis, além de ter adotado uma visão abrangente buscando ter variáveis de análise técnica e fundamentalista. Outro ponto de relevância do estudo é a busca de dados mensais, o que foi também replicado neste artigo.

É válido lembrar que foram utilizadas diversas variáveis ligadas ao setor petrolífero no estudo supracitado. Como o foco deste artigo eram todas as empresas listadas na bolsa de valor

brasileira, algumas dessas variáveis foram excluídas. As informações usadas constam do Quadro 1.

Quadro 1. Dados, formas de cálculo e fonte

Nome	Definição	Fonte
Preço de abertura	Preço de abertura da ação no mês em questão.	Econômica
Preço de fechamento	Preço de fechamento da ação no mês em questão.	Econômica
Preço mínimo	Preço mínimo da ação no mês em questão.	Econômica
Preço máximo	Preço máximo da ação no mês em questão.	Econômica
Média móvel	Média móvel dos preços da ação no mês em questão.	Econômica
Bandas de Bollinger	Bandas de desvio padrões de 10 pontos percentuais acima e abaixo de média móvel em relação aos preços de fechamento, auferindo-se o caminho do ciclo do comportamento do título.	Econômica
Volume	Resultado da soma das cotações de fechamento no mês em questão dividida pela quantidade de dias deste mês.	Econômica
Índice On Balance Volume (OBV)	Relaciona o volume com as mudanças de preços: quando o preço da ação fecha o período em baixa, o valor do volume do período é subtraído ao indicador; quando o preço da ação fecha o período em alta, o valor do volume do período é somado ao indicador; e quando o preço da ação é estável durante o período, o volume do período não é adicionado nem subtraído do indicador.	Econômica
Índice do Nível de Emprego Formal	Índice do Banco Central que mede a quantidade de vagas de empregos formais preenchidas.	BACEN
Preço do Petróleo Brent	Preço do petróleo extraído no Mar do Norte e comercializado na Bolsa de Valores de Londres.	Econômica
Vendas de automóveis	Quantidade mensal de automóveis novos vendidos no Brasil. Considera apenas os veículos comerciais leves.	ANFAVEA
Índice de Confiança do Consumidor	Mede a confiança do consumidor na sua capacidade de compra e na situação do país, abordando expectativas em relação à inflação, ao desemprego e a rendimentos futuros.	FGV
Estoques Finais Petróleo EUA	Quantidade de óleo e produto que está disponível em armazenamento nos Estados Unidos.	Econômica
Participação de investidores	Percentual de participação do maior investidor nas distribuições públicas de ações da amostra.	Econômica
Taxa de juros CDI	Taxa calculada com base nas operações de emissão de depósitos entre bancos prefixados e representa as condições de liquidez do mercado.	BACEN
Taxa de juros Selic	Taxa do Sistema Especial de Liquidação e Custódia (SELIC) que é tida como referência para as operações financeiras de crédito no mercado.	BACEN
Índice de Commodities energéticas do Brasil	Verifica as variações de preços de produtos básicos com cotação internacional (commodities) para avaliar os efeitos na inflação do Brasil.	BACEN
Índice The New York Stock Exchange (NYSE)	Índice que reflete o valor de mercado das ações comercializadas na Bolsa de Valores de Nova York	Econômica
Moving Average Convergence Divergence (MACD)	Oscilador de média móvel que utiliza a relação entre 2 médias móveis exponenciais de 12 e 26 períodos. O sinal de compra é gerado quando a média móvel de 12 (rápida) períodos cruza de baixo para cima a média de 26 (lenta) períodos, estando abaixo da linha de gatilho (média de 9 períodos da diferença entre as medias 12/26). O sinal de venda por sua vez é disparado quando a média móvel mais rápida (12) cruza para baixo da média mais lenta de (26), estando acima da linha de gatilho.	Econômica
Indicador Momentum	Mede o quanto o preço de uma ação mudou durante certo período de tempo, a partir da diferença entre o preço de fechamento atual e o preço de fechamento de n dias atrás.	Econômica
Faixa Percentual de Williams	Determina as zonas de compra ou venda de um ativo, através de possíveis pontos de mudança.	Econômica

Oscilador Estocástico	Técnica de mensuramento da velocidade dos preços baseada na teoria de que à medida que os preços sobem os fechamentos têm a tendência de se posicionarem mais próximos das altas do período. Similarmente, se os preços descem, os fechamentos tendem a se aproximarem das baixas. Este indicador varia entre 0 e 100. A região de sobrecompra fica próxima a 100 e a região de sobrevenda próxima a 0.	Economática
Índice de Força Relativa	Mede a evolução da relação de forças entre compradores e vendedores ao longo do tempo. Sua utilização possibilita observar o enfraquecimento de uma tendência, rompimentos, suporte e resistência antes de se tornarem aparentes no gráfico de barras. O estudo é desenhado em uma faixa paralela, com o formato de uma curva simples e seu domínio está entre 0 e 100.	Economática
Variação Percentual Dólar	Cotação da moeda norte-americana (US\$) em paridade com a moeda brasileira (R\$), utilizado como parâmetro de pagamento nas transações com exportações e importações de produtos do e para o Brasil.	BACEN

Fonte: Elaborado pelos autores

Regressão Linear Múltipla

Nesta seção descreve-se o mecanismo para desenvolvimento da regressão com dados em painel utilizado neste estudo. Para a realização da regressão, foi utilizado o *software* Stata. Houve winsorização de algumas variáveis, pois nem todas possuíam uma distribuição normal. A Tabela 1 apresenta as variáveis que sofreram impacto e winsorização.

Tabela 1. Winsorização

Variáveis	Winsorização
Preço de abertura	0,070
Preço mínimo	0,085
Preço máximo	0,065
Oscilação da média móvel	0,150
Faixas de Bollinger	0,155
Volume	0,220
Índice de expectativas futuras	0,055
Índice OBV	0,195
Momentun	0,130
Preço de fechamento	0,070
Williams percent range	0,020
Percentual de variação do dólar	0,040
MACD	0,170
Valor de Mercado	0,220

Fonte: Elaborada pelos autores

Após a normalização dos dados, foi feito o teste de VIF para verificar se havia multicolineariedade, tendo sido identificado esse problema em quatro variáveis: Selic; CDI; preço de fechamento; e preço mínimo. Diante disso, optou-se por excluir essas variáveis,

eliminar o problema de multicolineariedade, ficando todos os valores individuais de VIF menor do que dez e a média desses valores em 3,7.

Para identificar qual modelo de regressão seria utilizado, foram realizados os seguintes testes: Breusch-Pagan, Chow e Hausman. Tais testes apontaram que o melhor modelo é de regressão de efeito fixo. Foram ainda testados mais dois modelos, o teste de Woodridge e de Wald, para avaliar se existia autocorrelação e heterocedasticidade, respectivamente. Foram identificados ambos os problemas, os quais foram corrigidos por meio da opção robust, do *software* Stata.

O resultado da regressão se encontra na Tabela 2.

Tabela 2. Resultado da regressão

Valor de Mercado	Coef,
Peço de Abertura	37059,63***
Preço Máximo	-4.190.641
Oscilação das Médias Móveis	-47856,19
Faixas de Bollinger	30992,25***
Volume	1108026***
Índice de expectativas futuras	55640,7***
Índice OBV	0,1861942
Momentun	-10964,64
Williams percent range	1802403***
Percentual de variação do dólar	-5446,49
MACD	141171,9
Índice de confiança do consumidor	-4.242.364**
Índice Stochastic	-5.417.765
Força relativa do indicador	1.847.318
Participação do maior investidor	4.074.872
NYSE índice dow Jones	-374.219
Constante	-1334208
$R^2 = 0,4887$	
Os asteriscos *, ** e ***, representam significância aos níveis de 10%, 5% e 1%, respectivamente.	

Fonte: Elaborada pelos autores

Observa-se que foram identificadas seis variáveis que impactam o Valor de Mercado das empresas: Peço de Abertura; Faixas de Bollinger; Volume; Índice de expectativas futuras; Williams percent range; e Índice de confiança do consumidor.

Rede Neural Artificial

Após saber como foi realizado o processo da regressão, nesta seção será apresentada a segunda ferramenta utilizada para a construção da Rede Neural Artificial.

O *software* utilizado para a construção da rede foi o Matlab versão 2015. Para a inserção dos dados no sistema, foi preciso uma normalização desses dados entre zero e um, para que não houvesse valores muito discrepantes (HAYKIN, 2001). Para a normalização foi utilizada a fórmula a seguir:

$$X_i = \left(\frac{X - \text{Mínimo}}{\text{Máximo} - \text{Mínimo}} \right) * (1 - 0) + 0$$

Onde: X_i é o valor normalizado; X é o valor a ser normalizado; mínimo é o menor valor da amostra; Máximo é o maior valor da amostra.

Após tratamento, os dados foram inseridos no Matlab e foi utilizada uma rede voltada para *backpropagation* alimentada para a frente. Esse tipo de rede foi selecionado por sua comprovada eficiência para previsão com inserção de dados financeiros (PALIWAL, KUMAR, 2009) e por sua habilidade de retroprogramação, que permite voltar aos pesos e adaptá-los, conseguindo, desse modo, uma previsão mais assertiva.

Em razão da complexidade dos dados financeiros, ou seja, eles não serem linearmente separáveis, foi selecionada uma rede com duas camadas ocultas, esperando-se assim conseguir uma separação melhor dos dados, por meio de duas camadas ocultas que possuem mais capacidade do que apenas uma.

Para a seleção de neurônios nas camadas ocultas, foram feitos diversos testes, iniciando-se com uma rede com número de neurônios igual a quantidade de variáveis da rede e alternando-as com 15 neurônios a mais e 15 a menos, buscando a que apresentasse melhor desempenho.

Já para as funções de ativação, foram selecionadas as seguintes: da camada de entrada para a primeira camada oculta foi utilizada a função linear; da primeira para a segunda, e da segunda para a camada de saída, foi utilizada a tangente hiperbólica. Após terem sido testadas todas as combinações, foram selecionadas essas funções de ativação por apresentarem melhor desempenho.

Para o algoritmo de treinamento, optou-se por utilizar o Gradiente descendente *backpropagation*. A escolha desse algoritmo se deu por apresentar determinadas características

e principalmente pela sua função de trabalhar com o erro local e não global, que, na perspectiva dos dados financeiros, é mais válido.

Os parâmetros são representados na Tabela 3.

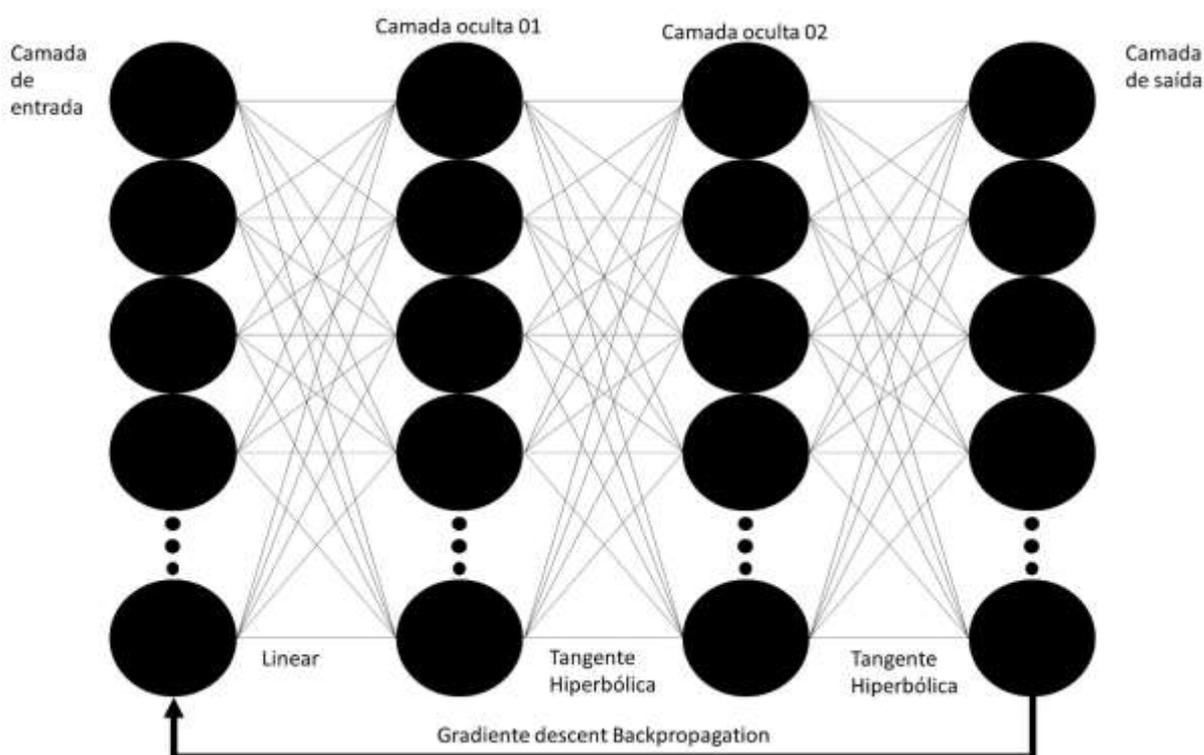
Tabela 3. Parâmetros da Rede Neural Artificial

Parâmetro	Valor
Épocas	6000
Mínimo gradiente	1e-6
Máximo de erro	6

Fonte: Elaborada pelos autores

Uma ilustração da Rede Neural Artificial é representada pela Figura 1.

Figura 1. Demonstração da Rede Neural Artificial



Fonte: Elaborada pelos autores

Regressão Linear Múltipla + Rede Neural Artificial

A terceira ferramenta a ser utilizada trata-se da junção das duas ferramentas anteriores. Em vez de se confrontar as formas de previsão, optou-se pela interseção dessas ferramentas de modo a avaliar se outra seria constituída com melhor desempenho, após a junção de sistemas. Esse achado representa uma contribuição deste artigo para o estudo de redes neurais.

Para o cumprimento desse objetivo, foi rodada a regressão como apresentado na seção Regressão linear múltipla. Em seguida, foram selecionadas as seis variáveis que deram relevância à regressão e, com elas, implementada a rede neural, seguindo os mesmos procedimentos descritos para a construção da Rede neural artificial, a fim de se alcançar melhores resultados.

Medidas Comparativas

Nesta seção serão descritas quais as fórmulas usadas para avaliar o desempenho das redes e identificar qual delas é a melhor. É válido salientar que foi utilizada a medida de desempenho presente no artigo de Oliveira, Nobre e Zárate (2013).

A primeira medida é o Erro Médio Percentual Absoluto (MAPE), o qual utiliza a média dos erros percentuais, ou seja, quanto menor o valor, melhor o desempenho. O MAPE se torna didático pelo fato de mostrar o erro por meios percentuais, como apresentado a seguir:

No Target, na rede neural, se considera o Valor de Mercado, o Output representa a saída da

$$MAPE = 100 X \left(\frac{\sum \left| \frac{Target_t - Output_t}{Output_t} \right|}{n} \right)$$

ferramenta de previsão e o termo n indica a quantidade de observações da amostra.

Como segunda medida tem-se o Erro Quadrático Médio (MSE), que é a média da soma dos erros ao quadrado. Ele mede a capacidade de previsão do modelo por meio do erro, ou seja, quanto mais próximo de zero for o valor do MSE, melhor a previsão da rede. A fórmula é representada a seguir:

$$MSE = \left(\frac{\sum (Target_t - Output_t)^2}{n} \right)$$

Como terceira forma de avaliação tem-se o coeficiente U de Theil, que demonstra se a previsão feita pelo modelo representa melhor medida do que uma previsão ingênua ou trivial. Caso o coeficiente represente valor igual ou maior que um, nada difere na escolha do modelo ou de escolha aleatória. O contrário é demonstrado quando o valor for menor do que um. A forma de cálculo do coeficiente é mostrada a seguir:

$$THEIL = \frac{\sqrt{\frac{\sum (Target_t - Output_t)^2}{n}}}{\sqrt{\frac{\sum Target_t^2}{n}} + \sqrt{\frac{\sum Output_t^2}{n}}}$$

Como última medida de desempenho, tem-se a Porcentagem Correta de Previsão Direcional (POCID), que objetiva a mensuração da porcentagem de acerto quanto a tendência da amostra. Quanto mais próximo o valor de 100, melhor será o modelo. A representação matemática se dá por:

$$POCID = 100 \times \left(\frac{\sum D_t}{n} \right)$$

Sendo que $D = 1$, se $(target - target-1) (output - output-1) > 0$ e $D = 0$, se $(target - target-1) (output - output-1) < 0$.

Após a apresentação dos mecanismos de avaliação de desempenho das redes, na seção a seguir serão apresentados os resultados das ferramentas de predição de valor de mercado.

Resultados

Nesta seção será mencionado o desenvolvimento do modelo de previsão para a Regressão e para a RNA, bem como a análise dos resultados.

Para realizar a previsão da ferramenta de RLM, foram utilizadas as variáveis independentes, as quais foram multiplicadas pelos seus respectivos betas, obtendo-se o somatório com a adição da constante e, assim, a aproximação do valor da variável dependente. A Regressão foi subdividida em duas, uma com todas as variáveis e outra com as variáveis que deram significância. Já para a RNA, os valores de *input* foram inseridos no Matlab e, por meio da rede neural artificial, gerado um *output*, que foi a previsão da rede. Para a rede com todas as variáveis foram utilizados 30 neurônios na camada oculta; para a ponderada pela regressão, a rede teve 15 neurônios na camada oculta.

A Tabela 5 apresenta os resultados das previsões.

Tabela 4. Desempenho das ferramentas do estudo

	RNA Cheia	RNA+RLM	RLM Cheia	RLM Ponderada
MAPE	0,5825785	0,5301642	0,770295851	2,647904523
MSE	0,0568452	0,0588307	0,202026272	0,245435367
THEIL	0,1813775	0,1843263	0,339031359	0,388455865
POCID	40,825397	39,216931	36,16931217	38,62433862

Fonte: Elaborada pelos autores

Ao analisar as ferramentas, pode-se concluir que todas as metodologias são mais eficazes que uma previsão trivial, já que em todos os casos o Theil foi menor que um. Ao se fazer uma avaliação mais detalhada, observa-se que os modelos de RNA apresentam menores MAPE e MSE do que os modelos de RLM, como também maiores POCID, demonstrando um melhor desempenho.

Em ambos os modelos, observa-se que a RLM Cheia obteve valores menores em MAPE, MSE e Theil demonstrando ser a melhor solução. Porém, quando se chega ao POCID, obtém-se valor menor, indicando que a RLM Ponderada vem a ser a solução mais adequada. Como maioria dos resultados apontou para a RLM Cheia, esta ferramenta foi considerada a de melhor previsão.

Já na RNA, a RNA Cheia obteve melhores resultados de desempenho em MSE, THEIL e POCID, o que não ocorreu em RNA+RLM no MAPE. Observou-se pequena diferença em todos os resultados, não demonstrando claramente qual a vantagem de se optar por um modelo ou outro. Considera-se então, como no caso da RLM, que a RNA Cheia é uma ferramenta de previsão superior à ponderada.

Entre todas as ferramentas analisadas, os resultados indicam que a RNA com todas as variáveis é a melhor ferramenta de previsão do valor de mercado das empresas listadas na BM&FBovespa entre janeiro de 2011 e dezembro de 2015.

Conclusão

Conclui-se que uma RNA com o todas as variáveis minimizam o erro na previsão do valor de mercado das empresas listadas na BM&FBovespa, entre janeiro de 2011 e dezembro de 2015. Esse resultado pode contribuir para que gestores realizem previsões mais assertivas de seus dados financeiros, pois contam com uma ferramenta mais precisa do que os tradicionais métodos estatísticos.

Este estudo, entretanto, apresenta limitações, a serem superadas em pesquisas futuras. A primeira delas é com relação ao período analisado, compreendido entre janeiro de 2011 e dezembro de 2015. Estudos devem ser realizados em períodos de maior abrangência. A segunda limitação diz respeito à realidade abordada, tendo em vista que são necessárias pesquisas não só nas empresas listadas na BM&FBovespa, mas também em empresas de diferentes realidades e comportamentos. Por fim, a terceira limitação consiste nas ferramentas de previsão abordadas. Neste artigo, foram comparadas duas ferramentas e a interseção entre elas, mas existem outras possibilidades e metodologias de previsão de valores financeiros, como também metodologias

com limitações, como é o caso da quantidade de dados excluídos, visto que uma RNA não pode ter *missing value* ou todas as exigências da RLM.

Estudos que comparem a realidade brasileira com a de outros países, a comparação de mais ferramentas e de metodologias de previsão de valores financeiros, além das abordadas no estudo, são sugestões para pesquisas futuras a fim de analisar a utilização de redes neurais artificiais para erro de previsão.

Referências

- BARRETO, Jorge M. Introdução às redes neurais artificiais. In: ESCOLA REGIONAL DE INFORMÁTICA, V.; 2002, Santa Maria. **Anais [...]** Santa Maria: SBC, 2002.
- BERNSTEIN, Peter L. **Desafio aos deuses**: a fascinante história do risco. Gulf Professional Publishing, 1997.
- CAVALHEIRO, Everton Anger et al. Previsibilidade de Mercados: Um Estudo Comparativo Entre Bovespa e S&P500. In: SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO, 17., 2010, Bauru. **Anais....** Bauru: Simpep, 2010. p. 1 - 10.
- CHURCHLAND, P. S.; SEJNOWSKI, T. **The computational brain**. Cambridge, MA: MIT Press, 1992.
- FAMA, Eugene F. **Efficient capital markets**: a review of theory and empirical work. *The Journal of Finance*, v. 25, n. 2, May 1970.
- FERREIRA, L. et al. A. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **Revista de Administração e Inovação**, v. 8, n. 4, p. 6-26, 2011.
- FERREIRA, T. A. E.; VASCONCELOS, G. C.; ADEODATO, P. J. L. A new evolutionary method for time series forecasting. In: GENETIC EVOLUTIONARY COMPUTATION CONFERENCE, X.; 2005, Washington. **Anais [...]** Washington: GECCO, 2005.
- FREITAS, A. A. C.; SILVA, I. N. Análise técnica de títulos financeiros através de redes neurais artificiais. In: CONGRESSO BRASILEIRO DE REDES NEURAIAS, IV.; 1999, São José dos Campos. **Anais [...]** São José dos Campos: ITA, 1999.
- HAIR, J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. **Análise multivariada de dados**. Porto Alegre: Bookman, 2005.
- HAYKIN, Simon. **Redes Neurais**: princípios e práticas. Trad. Paulo Martins Engel. 2.ed. Porto Alegre: Bookman, 2001.
- KOVÁCS, Z. L. **Redes neurais artificiais**: fundamentos e aplicações. Editora Livraria da Física, 2002.
- OLIVEIRA, Fagner A.; NOBRE, Cristiane N.; ZÁRATE, Luis A. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index – Case study of PETR4, Petrobras, Brazil. **Expert Systems with Applications**. v. 40, p. 7596 – 7607, 2013.
- MALIK, F.; NASEREDDIN, M. Forecasting output using oil prices: A cascaded artificial neural network approach. **Journal of Economics and Business**, v. 58, n. 2, p. 168-180, 2006.
- PALIWAL, Mukta; KUMAR, Usha A. A Neural networks and statistical techniques: a review of applications. **Expert Systems with Applications**. v. 36, p. 2-17, 2009.
- WHITE, H. Economic prediction using neural networks: The case of IBM daily stock returns. **Proceedings of the IEEE International Conference on Neural Networks**, p. 451–45, 1988.