

Predição do movimento de preços das ações da COPEL com base em indicadores técnicos e redes neurais

Wagner Igarashi (UEM) wigarashi@uem.br
Lucas Georges Helal (UEM) luc4shelal@gmail.com
Deisy Cristina Corrêa Igarashi (UEM) dccigarashi@uem.br

Resumo:

Técnicas de aprendizagem de máquina tem sido utilizadas de modo recorrente na criação de modelos de predição. O objetivo deste trabalho é analisar a utilização de indicadores financeiros e de uma rede neural artificial para a predição de tendências no mercado mobiliário. Foi realizado um estudo de caso em dados públicos da COPEL, extraídos a partir da BM&FBovespa. O período analisado corresponde ao primeiro semestre de 2015. A previsão foi feita para 20 dias. A análise compara os valores reais do preço de fechamento da ação, com o preço previsto pela rede neural. Os resultados obtidos foram próximos das variações reais, indicando o movimento futuro do valor da ação da COPEL.

Palavras chave: predição do preço de ações, indicadores técnicos, redes neurais artificiais.

Prediction of COPEL stock price movement based on technical indicators and neural networks

Abstract

Machine learning techniques have been used in a recurring way in the creation of prediction models. The objective of this work is to demonstrate the use of financial indicators and an artificial neural network for the prediction of trends in the furniture market. A case study was carried out on public COPEL data, extracted from the BM & FBovespa. The period analyzed corresponds to the first half of 2015. The forecast was made for 20 days. The analysis compares the actual values of the closing price of the share, with the price predicted by the neural network. The results obtained were close to the actual variations, indicating the future movement of the value of the COPEL share.

Key-words: stock price prediction, technical indicators, artificial neural networks.

1. Introdução

O mercado financeiro e, mais especificamente o mercado acionário, tem atraído a atenção de diversos atores, sejam eles empresas, investidores, pesquisadores ou mesmo o próprio governo, seja por necessidade de recursos financeiros, por possibilidades de ganhos futuros, para entender o comportamento de mercado ou no direcionamento de decisões políticas. (MARONGONI, 2001; MURPHY, 2003; KANG;

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

WANG, EOM, 2017; YANG; ZHOU, 2016; TIWARI, ALBULESCU, YOON, 2017; GROSSE, 2017).

As empresas entram no mercado acionário de modo a angariar recursos financeiros para poderem ampliar seus negócios, o que é menos oneroso do que a realização de financiamento bancário (ODEDON, 2015). Por outro lado, investidores possuem o interesse em rentabilizar seu capital (BRIGHAM, HOUSTON, 2012), e são classificados em pelo menos dois tipos. Os arrojados que acreditam em novas empresas, fazem diversas operações diárias de compra e venda, assumem um maior risco de perdas financeiras, no entanto podem conseguir maiores lucros. Outro tipo de investidor é o considerado conservador, que investe, geralmente, em empresas mais estáveis dos segmentos de energia, siderurgia e metalúrgica (BM&FBovespa, 2017).

Neste cenário, a ação se torna um intermediador importante na relação entre empresas e investidores. Elder (2006) explica que uma ação é representada por um certificado emitido por determinada empresa, neste caso cada ação tem valor proporcional a quantidade de ações emitidas, por exemplo se a empresa emite 100 milhões de ações, e um determinado investidor no mercado compra 100 ações, ele passou a pertencer um milionésimo dessa organização. Entretanto caso a empresa não emita novas ações e uma pessoa deseja ser acionista do empreendimento, esta pessoa terá de fazer uma oferta de compra de suas ações, ofertando muitas vezes valores superiores ao valor de emissão da ação pela empresa.

O movimento de oferta e demanda faz com que o valor de uma ação flutue. Outros fatores impactantes neste movimento tem relação com outras variáveis de mercado, como políticas, mudanças de tecnologia, crise financeira mundial, dentre outras. Nenhuma empresa está livre de uma crise, porém alguns segmentos são mais estáveis. Os investidores, na tentativa de obter lucro, podem utilizarem-se de técnicas de previsão do valor, como médias dos valores de dias anteriores, análise da saúde financeira da empresa, notícias publicadas pelos diversos tipos de mídia, entre outras maneiras, para auxiliar na compra ou venda de uma ação.

Os analistas financeiros na tentativa de auxiliar os investidores, analisam a evolução dos preços de ações e dos índices de ações (SUJATHA, SUNDARAM, 2010) na busca de estratégias de investimentos bem sucedidas (VASHISTH, CHANDRA, 2010). Entretanto a preparação de modelos de previsão, as previsões em si e a formulação de estratégias de investimento são tarefas difíceis devido à complexidade inerente dos mercados de ações (WEN et al, 2010).

Diferentes abordagens podem ser aplicadas ao problema de previsão de índices de mercado, as quais podem ser agrupadas de acordo com a variável de previsão (o nível de preços, o retorno financeiro, a volatilidade dos preços, etc), as variáveis explicativas (o preço do petróleo, a taxa de mudança em relação ao dólar dos EUA, a evolução dos outros índices de mercado, etc) e a metodologia utilizada (modelos econométricos, sistemas de inferência difusa, séries temporais difusas, redes neurais artificiais). (RAUDYS, 2013; ARANGO, VELÁSQUEZ, 2014).

A literatura tem relatado casos de sucesso obtidos por sistemas inteligentes que operam junto aos mercados acionários (CHEN; CHEN, 2016; KIM et al, 2017), com o

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

objetivo de automatizar decisões de negociação, ou ainda na organização de portfólios ou carteira de ações. Mais especificamente, o estudo de técnicas de inteligência artificial pode auxiliar investidores na negociação do mercado de ações (QIU, SONG, AKAGI, 2016; CHONG, HAN, PARK, 2017).

No contexto apresentado, é delineada a seguinte questão de pesquisa: como o uso de uma técnica de aprendizagem de máquina pode contribuir na predição do valor de uma ação? Particularmente para a tomada de decisões na compra e venda das ações, são necessários sistemas que possam prever a natureza dos movimentos atuais nas bolsas de valores e que possibilite aos investidores uma maior certeza de lucro e um menor risco (SRINIVASAN; LAKSHMI, 2017; VERMA; CHOURE; SINGH, 2017). Neste contexto, a aplicação de redes neurais aliado à utilização de outros subsídios como os indicadores técnicos, podem auxiliar na previsão do movimento de preços de uma ação, auxiliando possíveis investidores.

Assim, o presente trabalho tem como objetivo analisar o uso de indicadores de análise técnica, aliado à utilização de um modelo de rede neural da área de aprendizagem de máquina, no processo de predição do movimento do preço de ações. Tais modelos podem auxiliar um investidor na tomada de decisão de compra ou venda de ações.

2. Materiais e métodos

Para o experimento foi utilizado um arquitetura computacional contemplando: Processador Intel(R) Core(TM) i5-3317U CPU 1.70GHz; Memória RAM 6,00GB; Disco Rígido 750GB; Sistema Operacional Ubuntu Trusty Tahr 14.04 LTS – 64 bits. Como linguagens de programação foram utilizados o Python e o Java.

Além disso, foi necessário utilizar bibliotecas específicas: Quandl - uma biblioteca que possibilita a extração de milhões de dados financeiros e econômicos, permitindo que usuários por meio de sua API possam acessar dados sobre empresas do mercado acionário (QUANDL, 2017). Especificamente foram extraídos os dados da Copel (Companhia Paranaense de Energia Elétrica) a partir do site da BM&FBovespa.

Para o processo de criação de um modelo de predição foi utilizada uma implementação em Java da Rede Neural Artificial Perceptron com função de ativação sigmóide e aprendizagem Backpropagation (RUSSELL, NORVIG, 2013). A estrutura da rede neural contempla seis neurônios na camada de entrada, quatro neurônios na camada intermediária e um neurônio na camada de saída. Os pesos foram inicializados aleatoriamente.

3. Experimento

A representação esquemática do experimento na Figura 1, é um guia para a compreensão das fases do protótipo, ele está definido em duas etapas: (a) o Back-end, composto pela comunicação via internet entre um servidor que contém os dados necessários para a extração dos valores, através da biblioteca QUANDL na linguagem de programação Python, para que ambas juntas seja possível a extração

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

e armazenamento dos valores, em seguida foi aplicado o processo de transformação do valores obtidos e os moldando para realizar o aprendizado na rede neural; (b) o Front-end, responsável pela previsão e visualização dos valores futuros.

Na etapa de Back-End é feita uma requisição via internet para o servidor em que estão armazenados os dados sobre preços de ações, este servidor envia os dados solicitados para o programa, que faz a extração dos valores que são armazenados, transformados e treinados para realização das previsões.

Existem diversos servidores que funcionam em conjunto com a API Quandl, entre eles os gratuitos como por exemplo: Central Bank of Brazil Statistical Database, YFinance, Google Finance e diversos outros. Como o trabalho necessita de informações da empresa brasileira COPEL, o servidor consultado foi o YFinance.

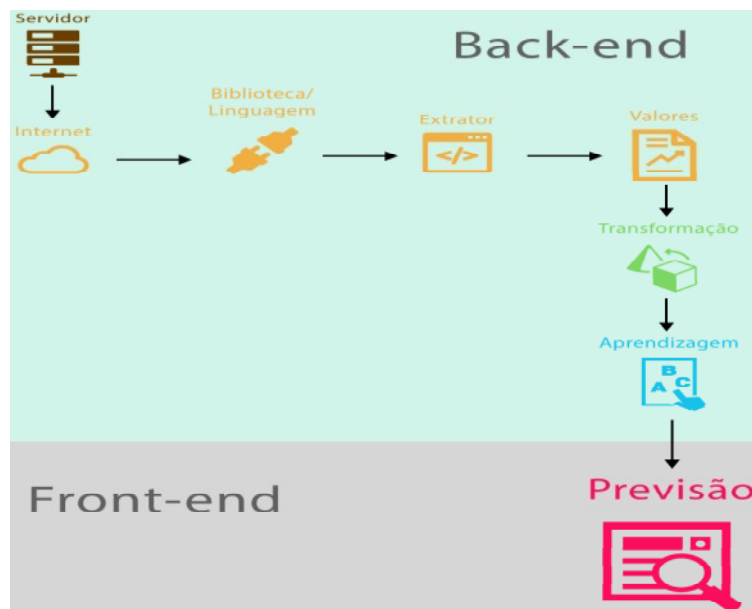


Figura 1 - Representação esquemática do experimento

O extrator de valores foi desenvolvido em Python, utilizando a biblioteca Quandl, contudo, esta possui suporte para diversas linguagens, além de ter uma documentação de como utilizá-la. Com o extrator foi possível construir a Application Programming Interface (API) de extração de valores, a partir da qual são informadas datas de início e fim, junto com código da ação, para então realizar o acesso ao servidor, e obter um arquivo com os dados da ação no período solicitado.

Os valores obtidos com o extrator, foram os da ação referente a empresa brasileira COPEL, sob o código de navegação junto à BM&FBovespa CPLE3, com o período inicial no dia 17 de dezembro de 2014 até o dia 29 de maio de 2015, completando um total de 114 dias. Ao invés de utilizar 100 dias para a extração de indicadores, foram extraídos 14 dias a mais para cálculo das técnicas (1 - a Média Móvel (MA) para 5 e 10 dias anteriores; 2 - a Rate of Change (ROC) para 5 e 10 dias anteriores; e o 3 - Relative Strength Index (RSI) para 7 e 14 dias). Os 114 dias foram utilizados

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

para extração de indicadores e treinamento da rede neural artificial. Depois do dia 29 de maio de 2015 ainda foram extraídos os valores reais dos 20 dias posteriores (1 de junho de 2015 até o dia 26 de junho de 2015 - Figura 2) para comparação com os valores obtidos na fase de predição utilizando redes neurais.

A figura 2 mostra os 20 valores (linhas) extraídos para a fase de previsão, sendo que a primeira coluna são as datas (Date), a segunda coluna são os valores de abertura da ação (Open) no dia, a terceira coluna se refere ao pico mais alto (High) da ação no dia, a quarta coluna ao pico mais baixo (Low) da ação no dia, a quinta coluna são os valores de fechamento da ação (Close), a coluna seis são os volumes (Volume) de negociação da ação no dia e por fim a sétima e última coluna representa o valor ajustado (Adjusted Close) para o preço de fechamento da ação.

Date	Open	High	Low	Close	Volume	Adjusted Close
2015-06-26	22.4	23.14	22.23	23.14	232400.0	23.14
2015-06-25	23.13	23.3	22.33	22.4	147700.0	22.4
2015-06-24	23.05	23.68	23.05	23.45	78400.0	23.45
2015-06-23	23.35	23.67	22.84	23.25	63100.0	23.25
2015-06-22	22.99	23.17	22.71	23.17	37000.0	23.17
2015-06-19	22.7	22.85	22.25	22.7	65800.0	22.7
2015-06-18	22.69	22.99	22.56	22.95	83100.0	22.95
2015-06-17	22.4	22.64	22.3	22.64	43900.0	22.64
2015-06-16	21.98	22.4	21.5	22.4	59000.0	22.4
2015-06-15	22.04	22.08	21.76	21.76	86900.0	21.76
2015-06-12	22.28	22.34	21.8	22.34	137300.0	22.34
2015-06-11	22.12	22.35	21.85	22.34	44800.0	22.34
2015-06-10	22.24	22.54	21.82	22.35	114900.0	22.35
2015-06-09	21.74	22.26	21.2	22.11	102100.0	22.11
2015-06-08	21.8	21.99	21.43	21.45	104100.0	21.45
2015-06-05	22.0	22.55	21.6	21.6	71700.0	21.6
2015-06-04	22.2	22.2	22.2	22.2	0.0	22.2
2015-06-03	21.93	22.35	21.73	22.2	131900.0	22.2
2015-06-02	21.98	22.33	21.75	22.17	148000.0	22.17
2015-06-01	21.7	22.15	21.45	21.95	194800.0	21.95

Fonte: BM&FBovespa (2017)

Figura 2 - Dados da Copel (01/06/2015-26/06/2015)

A transformação foi uma das etapas importantes para obtenção dos resultados finais deste trabalho. A primeira fase da etapa, foi selecionar apenas os valores de fechamento (Close) dos dados extraídos, pois a partir deles foram feitos os cálculos dos indicadores escolhidos: (1) a Média Móvel (Move Average - MA) para 5 e 10 dias anteriores; (2) a Rate of Change (ROC) para 5 e 10 dias anteriores; e o (3) Relative Strength Index (RSI) para 7 e 14 dias.

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

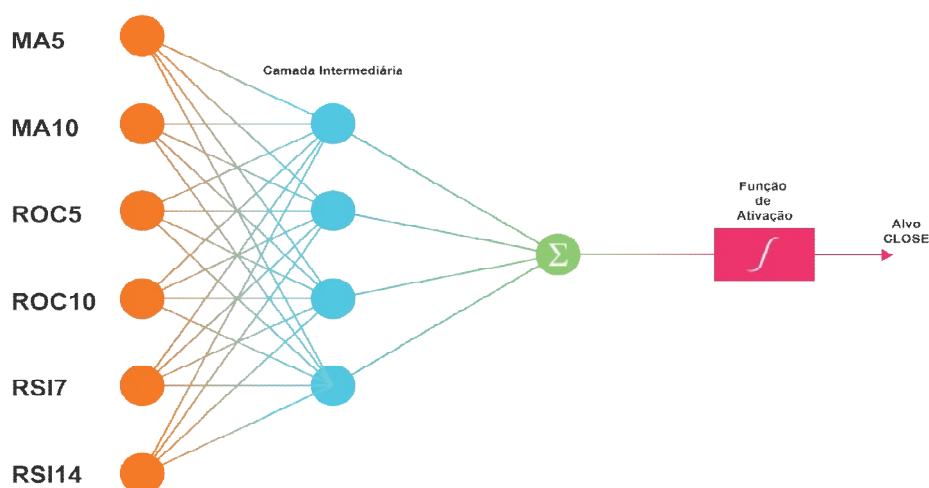
MA5	MA10	ROC5	ROC10	RSI7	RSI14	CLOSE
0,42	0,68	0,255709053	0	0,104561742	0,023825854	0,17
0,39	0,57	0,389196847	0,051343577	0,220042519	0,128187124	0,25
0,32	0,48	0,222644432	0,105903561	0,332547239	0,229967850	0,33
0,26	0,40	0,294619838	0,169556879	0,457029258	0,344542090	0,42
0,32	0,40	0,649178040	0,509089275	0,719176299	0,614360866	0,66
0,34	0,37	0,527748615	0,386373523	0,345709482	0,235168863	0,25
0,30	0,34	0,334644300	0,334260592	0,250663792	0,123287342	0,10
0,29	0,28	0,418539605	0,255912959	0,430990059	0,305830523	0,27
0,28	0,24	0,431666976	0,335748113	0,527955354	0,406756738	0,38
0,19	0,22	0,193755668	0,435596120	0,470990392	0,352366885	0,32

Fonte: dados primários

Figura 3 - Valores normalizados para a aprendizagem

A segunda fase, foi o cálculo destas médias de forma automatizada, para isso foi feito um código em Python para o cálculo desses indicadores. Por fim, uma terceira fase foi necessária, a normalização dos valores de fechamento e os indicadores, cada um dos parâmetros em um intervalo entre 0 e 1 (Figura 3).

A figura 3, ilustra 10 dos 100 dias utilizados nesta fase, sendo que as seis primeiras colunas são dadas como entrada da rede, são elas MA para 5 dias (MA5), MA para 10 dias (MA10), ROC para 5 dias (ROC5), ROC para 10 dias (ROC10), RSI para 7 dias (RSI7) e RSI para 14 dias (RSI14), respectivamente nesta ordem, e tendo como alvo a sétima e última coluna, o valor de fechamento (Close). Esse modelo de aprendizagem é considerado supervisionado, pois o alvo fechamento indica a resposta desejada para o padrão de entrada. Os dados foram aplicados na rede neural nesta etapa de aprendizado, para previsão dos 20 dias seguintes. A figura 4 ilustra como ficou a modelagem da rede.



Fonte: dados primários

Figura 4 - Valores normalizados para a aprendizagem

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

Para o processo de criação do modelo de predição (Figura 4) foi utilizada a Rede Neural Artificial Perceptron com função de ativação sigmóide e aprendizagem Backpropagation.

Após a sequência das etapas do back-end concluídas, inicia-se a última etapa do processo, a previsão. A previsão ocorre após o término do ciclo de aprendizagem da rede neural artificial, em que foram gerados 20 dias de previsões do preço da ação da COPEL e comparados com os valores reais.

Os resultados apresentados nesta seção são mostrados em valores normalizados e em valores reais por meio de desnormalização. Na fase de transformação, os indicadores financeiros foram calculados e podem ser observados parcialmente na tabela 2.

DATA	CLOSE	MA5	MA10	ROC5	ROC10	RSI7	RSI14
18/05/15	23,7	23,448	23,614	-1,659751	0,89399745	53,9082564	51,5818316
19/05/15	24,45	23,54	23,694	1,91746561	3,38266385	65,56962	57,9726162
20/05/15	24,05	23,73	23,724	4,11255411	1,26315789	56,6513258	53,8873876
21/05/15	23,62	23,894	23,726	3,59649123	0,08474576	48,3958436	49,8228151
22/05/15	23,3	23,824	23,676	-1,4799154	-2,1008403	42,9604666	46,9827248
25/05/15	24	23,884	23,666	1,26582278	-0,4149378	55,6673751	53,2594161
26/05/15	23,22	23,638	23,589	-5,0306749	-3,2096707	43,166194	46,6342121
27/05/15	22,76	23,38	23,555	-5,3638254	-1,4718615	37,3891472	43,2196719
28/05/15	22,2	23,096	23,495	-6,0118544	-2,631579	31,4173083	39,434236
29/05/15	21,5	22,736	23,28	-7,7253219	-9,0909091	25,4818941	35,2751492

Fonte: Dados primários

Tabela 1 – Dados de fechamento da Copel e seus respectivos índices, valores reais

Na fase de aprendizagem, os valores de fechamento e os indicadores calculados foram normalizados entre 0 e 1 e apresentados para a rede neural. A tabela 2 demonstra os dados normalizados.

DATA	CLOSE	MA5	MA10	ROC5	ROC10	RSI7	RSI14
18/05/15	0,61	0,54	0,65	0,38374329	0,56468128	0,61670509	0,55366894
19/05/15	0,8	0,57	0,68	0,55412776	0,67738001	0,83682668	0,77199734
20/05/15	0,7	0,64	0,69	0,65868082	0,58139863	0,66848367	0,63243366
21/05/15	0,59	0,69	0,69	0,63410051	0,52803449	0,51265199	0,49357565
22/05/15	0,51	0,67	0,67	0,39230895	0,42906068	0,41005303	0,39654963
25/05/15	0,69	0,68	0,67	0,52308971	0,50540643	0,64991047	0,61098027
26/05/15	0,49	0,61	0,64	0,22318466	0,37884753	0,41393637	0,38464339
27/05/15	0,37	0,52	0,62	0,20731654	0,45754386	0,304888	0,26799244

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

28/05/15	0,23	0,43	0,6	0,17645063	0,4050263	0,19216271	0,13867057
29/05/15	0,05	0,31	0,51	0,09483739	0,11251689	0,08012497	0

Fonte: Dados primários

Tabela 2 – Dados de fechamento da Copel e índices normalizados

Com a rede treinada, foram gerados 20 dias de previsões do preço da ação da COPEL e comparados com os valores reais, conforme a tabela 3.

Data	Valor Real	Valor Previsto
01/06/15	0,16	0,11651576
02/06/15	0,22	0,29935187
03/06/15	0,23	0,19712506
04/06/15	0,23	0,15246242
05/06/15	0,07	0,04235263
08/06/15	0,03	0,00251343
09/06/15	0,2	0,13068972
10/06/15	0,26	0,18797311
11/06/15	0,26	0,12368583
12/06/15	0,26	0,12400971
15/06/15	0,11	0,04916234
16/06/15	0,28	0,21752855
17/06/15	0,34	0,30717170
18/06/15	0,42	0,33401449
19/06/15	0,35	0,30360083
22/06/15	0,47	0,51705089
23/06/15	0,5	0,60392718
24/06/15	0,55	0,60392718
25/06/15	0,28	0,24160700
26/06/15	0,47	0,54480223

Fonte: Dados primários

Tabela 3 – Indicadores X Valores Previstos. Normalizados

Os valores normalizados obtidos podem ser observados na tabela 3, porém para fins de análise do comportamento da previsão, foi feita uma desnormalização utilizando o maior e o menor valor real no período de treinamento para trazer estes valores de 0 e 1 para algo próximo do que seria o real. A Tabela 4, mostra como ficou a comparação.

DATA	Valor Real	Valor Previsto
01/06/15	21,95	21,7544115
02/06/15	22,17	22,4674723
03/06/15	22,2	22,0687877
04/06/15	22,2	21,8946034


Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

05/06/15	21,6	21,4651753
08/06/15	21,45	21,3098024
09/06/15	22,11	21,8096899
10/06/15	22,35	22,0330951
11/06/15	22,34	21,7823748
12/06/15	22,34	21,7836379
15/06/15	21,76	21,4917331
16/06/15	22,4	22,1483613
17/06/15	22,64	22,4979696
18/06/15	22,95	22,6026565
19/06/15	22,7	22,4840432
22/06/15	23,17	23,3164985
23/06/15	23,25	23,655316
24/06/15	23,45	23,655316
25/06/15	22,4	22,2422673
26/06/15	23,14	23,4247287

Fonte: Dados primários

Tabela 4 – Valores – Real x Previsto

Em relação aos dados da tabela 4, foi criado o gráfico da figura 9, que mostra o comportamento de variação real e o predito pela rede neural para a ação da Copel.




Fonte: Dados primários

Figura 9 - Previsão de Valores (20 dias - Real)

A média de erro foi calculada através do módulo da diferença dos valores reais e preditos das ações, sendo somadas e divididas pela quantidade de dias, no caso 20 dias, que foi de R\$ 0,268. Considerando que o valor médio da ação foi de R\$ 22,43, o erro médio representa em torno de 1,2% do total do preço da ação. A figura 10, apresenta essa diferença em centavos para cada dia do valor real para o predito pela rede neural.

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018



Fonte: Dados primários

Figura 10 - Diferença em centavos do valor real x previsto

Em relação à figura 10, verifica-se que o menor erro ocorrido foi de 0 centavos, com 6 ocorrências e que o erro máximo verificado foi de aproximadamente 0,56 centavos com 2 ocorrências.

4. Conclusão

A intensidade de oscilação no mercado acionário é acentuada, fazendo que uma simples notícia sobre uma empresa, possa mudar o humor dos investidores e, assim, alterando imediatamente o preço de ações. A predição no mercado acionário está longe de ser algo simples. Porém predições com um certo nível de erro, podem ser significantes para esses investidores.

Deste modo, para responder a questão de pesquisa: como o uso de uma técnica de aprendizagem de máquina pode contribuir na predição do valor de uma ação? o presente trabalho buscou como objetivo, analisar o uso de indicadores de análise técnica, aliado à utilização de um modelo de rede neural da área de aprendizagem de máquina, no processo de predição do movimento do preço de ações.

Para atingir tal objetivo, foi realizado um experimento computacional, para o qual foi selecionada uma das maiores empresas de capital aberto do estado do Paraná, a Companhia Paranaense de Energia Elétrica - COPEL. Por meio da API Quandl e da linguagem de programação Python, foi possível a extração dos valores diários dos preços das ações da COPEL. No total foram coletados 134 dias de dados.

Com base nos dados extraídos, foi necessário o estudo e análise de indicadores de predição de valores de ações, dos quais foram selecionados seis: Média Móvel (Move Average - MA) para 5 e 10 dias anteriores; a Rate of Change (ROC) para 5 e 10 dias anteriores; e o Relative Strength Index (RSI) para 7 e 14 dias.

Foram utilizados 114 dias de dados para o cálculo dos indicadores referentes a 100 indicações de movimento, utilizando a linguagem Python. Com base nos indicadores, para o modelo de predição, foi treinada uma rede neural artificial Perceptron com backpropagation, implementada na linguagem de programação Java. Os resultados obtidos revelaram que a rede neural artificial pôde apresentar uma predição de forma eficiente para um período curto, no caso deste estudo, de 20

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

dias de teste, uma vez que os erros foram relativamente baixos.

Como possibilidade de estudos futuros tem-se as seguinte possibilidades: integração dos algoritmos implementados e/ou utilizados; implementação de uma interface gráfica, com geração automática de gráficos; utilizar algoritmos e técnicas para outras ações ou até mesmo para taxa cambial; comparar mais de uma empresa ao mesmo tempo; utilizar de outros indicadores técnicos para realizar a previsão.

Referências

ARANGO, A.; VELÁSQUEZ, J. D. *Forecasting the Colombian Exchange Market Index (IGBC) using Neural Networks*. IEEE Latin America Transactions, v. 12, n. 4, June, 2014.

BM&FBOVESPA. *Guia Online do Mercado de Ações. Página online*. São Paulo: BM&FBOVESPA S.A., 2017. Disponível em: <<http://www.bmfbovespa.com.br/Pdf/ConceitosFundamentais.pdf>>. Acesso em: 10 out. 2017.

BRIGHAM, E. F., & HOUSTON, J. F. *Fundamentals of financial management*. Cengage Learning, 2012.

CHEN, T., CHEN, F. *An intelligent pattern recognition model for supporting investment decisions in stock market*. Information Sciences, Volumes 346–347, 10 June, Pages 261-274, ISSN 0020-0255, 2016.

CHONG, E., HAN, C., PARK, F. C. *Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies*. Expert Systems with Applications, v. 83, n. 15 October, p. 187-205, ISSN 0957-4174, 2017.

ELDER, A. *Aprenda a Operar no Mercado de Ações*. 11. ed. Rio de Janeiro: Elsevier, 2006.

GROSSE, R. *The global financial crisis—Market misconduct and regulation from a behavioral view*. Research in International Business and Finance, v. 41, october, p. 387-398, ISSN 0275-5319, 2017.

KANG, M., WANG, W., EOM, C. *Corporate investment and stock liquidity: Evidence on the price impact of trade*. Review of Financial Economics, v. 33, april, p. 1-11, ISSN 1058-3300, 2017.

KIM, Y., AHN, W., OH, K. J., ENKE, D. *An intelligent hybrid trading system for discovering trading rules for the futures market using rough sets and genetic algorithms*. Applied Soft Computing, v. 55, june, p. 127-140, ISSN 1568-4946, 2017.

MARANGONI, P. H. *Redes Neurais Artificiais para Previsão de Séries Temporais no Mercado Acionário*. 80 f. Monografia (Especialização) - Curso de Ciências Econômicas, Universidade Federal de Santa Catarina – Ufsc, Florianópolis, 2010.

MURPHY, J. J. *Technical Analysis of the Financial Markets*, NYIF, 2003.

ODEKON, M. *Booms and Busts: An Encyclopedia of Economic History from the First Stock Market Crash of 1792 to the Current Global Economic Crisis*. Routledge, 2015.

QIU, M., SONG, Y., AKAGI, F. *Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market*. Chaos, Solitons & Fractals, v. 85, april, p. 1-7, ISSN 0960-0779, 2016.

QUANDL. *The world's most powerful data lives on Quandl*. Disponível em: <https://www.quandl.com>. Acesso em: 10 out. 2017.

RAUDYS, S. *Portfolio of Automated Trading Systems: Complexity and Learning Set Size Issues*. IEEE Transactions On Neural Networks And Learning Systems, v. 24, n. 3, march 2013.

RUSSELL, S., & NORVIG, P. *Inteligência artificial*, 3E., Elsevier, ISBN 978-85-352-3701-6, 2013.

SRINIVASAN, N.; LAKSHMI, C. *Stock prediction and analysis using intermittent training data with*

Ponta Grossa, Paraná, Brasil – 06 a 08 de junho de 2018

artificial neural networks. International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS), 2017.

SUJATHA, K. V. E SUNDARAM. S. M. *Stock index prediction using regression and neural network models under non normal conditions*. In: International Conference on Emerging Trends in Robotics and Communication Technologies, INTERACT-2010, p. 59-63, 2010.

TIWARI, A. K., ALBULESCU, C. T., YOON, S.-M. *A multifractal detrended fluctuation analysis of financial market efficiency: Comparison using Dow Jones sector ETF indices*. Physica A: Statistical Mechanics and its Applications, v. 483, n. 1 october, p. 182-192, ISSN 0378-4371, <https://doi.org/10.1016/j.physa.2017.05.007>, 2017.

VASHISTH, R. E CHANDRA, A. *Predicting stock returns in Nifty index: An application of artificial neural network, International*. Research Journal of Finance and Economics, v. 49, p. 15-24, 2010.

VERMA, R.; CHOURE, P.; SINGH, U. *Neural networks through stock market data prediction*. International conference of Electronics, Communication and Aerospace Technology (ICECA), Volume: 2, Pages: 514 - 519, 2017.

WEN, Q.; YANG, Z.; SONG, Y. and JIA. P. *Automatic stock decision support system based on box theory and SVM algorithm*. Expert Systems with Applications, v. 37, n. 2, p. 1015-1022, 2010.

YANG , C., ZHOU, L. *Individual stock crowded trades, individual stock investor sentiment and excess returns*. The North American Journal of Economics and Finance, v. 38, p. 39-53, ISSN 1062-9408, 2016.
