

Previsão do Índice S&P 500 da Bolsa de Valores Através de Redes Neurais Artificiais Multicamadas

Rodrigo de Moraes¹, Daniel Gomes Soares¹

¹Instituto Federal Catarinense – Campus Rio do Sul
R. Abraham Lincoln, 210 - Jardim América, Rio do Sul - SC, 89160-202

moraesrodrigo6gmail.com, daniel.soares@ifc.edu.br

Abstract. *The prediction of stock market indices or stock quotes is a great challenge even for experts with years of experience in investment techniques. Forecasting the future, and especially the time-series behavior, is considered a major challenge for both statistics and computing. In this context, this work presents a predictive model, based on Artificial Neural Networks (ANNs) of the Multilayer Perceptron type, for the prediction of the S&P 500 index of the New York stock exchange. The performance of the modeled ANNs is analyzed through statistical and graphical indexes. The results show that it is possible to forecast the stock market indexes with acceptable error and advance.*

Resumo. *A predição de índices da bolsa de valores e/ou cotações das ações, é um grande desafio até mesmo para especialistas com anos de experiência em técnicas de investimento. Prever o futuro, e em especial o comportamento de séries temporais é considerado um grande desafio, tanto para a estatística como para a computação. Dentro deste contexto, este trabalho apresenta um modelo predictor, baseado em Redes Neurais Artificiais (RNAs) do tipo Multilayer Perceptron, para a predição do índice S&P 500 da bolsa de valores de Nova Iorque. O desempenho das RNAs modeladas é analisado por meio de índices estatísticos e gráficos. Os resultados demonstram que é possível realizar a previsão de índices da bolsa de valores com erro e antecedência aceitáveis.*

1. Introdução

Investir no mercado de ações é tido como um desafio para muitos, visto que os resultados para este tipo de investimento podem ser de certa maneira, muito difíceis de prever. De acordo com Wang et al (2011), “os dados históricos sobre os preços das ações são uma das informações mais importantes para investidores na bolsa de valores, porém, infelizmente, estes dados são dinâmicos, não lineares, não parametrizados e caóticos por natureza. Isso implica que os investidores têm que lidar com séries cronológicas não estacionárias e com frequentes quebras estruturais, dificultando a previsibilidade dos dados futuros.”

Ainda para Wang et al (2011), os preços das ações são afetados por diversos fatores macroeconômicos diferentes, dentre estes fatores se destacam, eventos políticos, taxas bancárias, expectativas dos investidores, condições financeiras em geral e até

mesmo fatores psicológicos dos investidores. Prever a variação desses preços com precisão pode ser bastante desafiador, porém, de certa maneira, é de grande interesse para os investidores.

Existem vários estudos relativos a modelos de predição de índices da bolsa, tais como, o IBOVESPA da bolsa de valores brasileira como pode ser visto nos trabalhos de Rêgo e Mussa (2008) e Roque (2009), e o índice S&P500 da bolsa americana, conforme pode ser observado em Tsaih et al (1998) e Yudong e Lenan (2009). Naturalmente a predição dos índices através destes modelos se dá por indicadores de análise técnica, visto que este tipo de análise baseia-se na observação de gráficos e índices em busca de prever o comportamento futuro desses valores em função de uma série histórica de cotações.

Uma técnica que vem obtendo sucesso na predição de preços das ações ou índices da bolsa de valores, são as Redes Neurais Artificiais (RNAs), como é o caso do trabalho de Krieger (2012). Em geral, as RNAs possuem atributos de aprendizagem, generalização, processamento paralelo e resistência a erros (WANG et al, 2011). Outro aspecto importante, é o que mencionam Yudong e Lenan (2009), afirmando que a maioria dos modelos baseados em RNAs usam os dados históricos e atuais do índice de ações para prever os preços futuros, além disto, as RNAs têm ganhado popularidade devido às suas capacidades inerentes para aproximar qualquer função não linear com um alto grau de precisão.

Dentro deste contexto, pelo fato das RNAs terem a capacidade de identificação de padrões, realizar previsões e de terem sido utilizadas com sucesso nesse tipo de problema, o objetivo deste trabalho será utilizar a técnica de Redes Neurais Artificiais para, a partir da série histórica do índice de ações S&P500, prever o valor de fechamento deste índice com um dia de antecedência.

2. Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais) (SILVA; SPATTI; FLAUZINO, 2010).

Segundo Braga, Carvalho e Ludermir (2011), as RNAs tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento funcional e sua dinâmica.

Silva, Spatti e Flauzino (2010) complementam que as RNAs possuem características de mapear sistemas não-lineares, aprendendo seus comportamentos a partir de amostras, medidas ou até mesmo padrões.

2.1 Redes Multilayer Perceptron

Segundo Silva, Spatti e Flauzio (2010) as Redes Multilayer Perceptron (MLP) pertencem à arquitetura neural conhecida como *feedforward* de múltiplas camadas, possuindo em sua estrutura pelo menos uma camada oculta (intermediária) de neurônios, situada entre a camada de entrada e a de saída. Desta forma as redes MLP possuem no mínimo duas camadas de neurônios, que estão distribuídas entre as camadas intermediárias e a camada de saída.

A camada de entrada da RNA é a responsável por receber os sinais externos. As camadas intermediárias extraem a maioria das informações referentes ao seu comportamento e as codificam através dos pesos sinápticos e limiares de seus neurônios nas camadas adjacentes.

Segundo Braga, Carvalho e Ludermir (2011) o algoritmo de treinamento mais comumente utilizado em uma rede MLP é o *backpropagation*, ou algoritmo de retropropagação, que é um método supervisionado de treinamento que utiliza pares de entrada e saída para ajustar os pesos da rede por meio de um mecanismo de correção de erros. Silva, Spatti e Flauzio (2010) reforçam que o treinamento ocorre através de aplicações sucessivas de duas fases, uma delas é a fase de propagação adiante (ou *forward*) e a outra é a fase de propagação reversiva (ou *backward*).

De acordo com Soares e Teive (2015), a utilização do algoritmo *backpropagation* convencional na prática tende a convergir de forma demasiadamente lenta, exigindo-se, assim, um elevado esforço computacional. Algumas das alternativas para tornar o processo de convergência da rede mais eficiente são: a inserção do termo de *momentum*, ou a utilização de variantes do *backpropagation* como o algoritmo de *Levenberg-Marquardt* e a Regularização Bayesiana.

3. Índices de Ações

Segundo a BM&FBovespa (2016), o Mercado de Capitais “tem como objetivo principal canalizar recursos dos agentes econômicos para a capitalização das empresas de capital aberto, por meio de operações com títulos e valores mobiliários em mercado de bolsa ou balcão. A compra e a venda de títulos e valores mobiliários pelos diversos agentes econômicos (indivíduos, empresas, fundos e instituições financeiras, por exemplo) é o que define a liquidez e o valor de mercado de tais ativos e, portanto, da empresa emissora.”

Sendo assim, uma das principais funções do mercado de capitais, é possibilitar que empresas, com intuito de viabilizar projetos de investimento, captem recursos diretamente do público investidor em condições mais vantajosas do que as oferecidas pelos empréstimos e financiamentos bancários (BM&FBovespa, 2016).

Dentro do Mercado de Capitais, além das ações negociadas, há o termo de índice de mercado, ou índices de ações, que segundo Lagioia (2007), é um composto estatístico que registra mudanças nas cotações das ações e mede as altas e baixas das

ações numa determinada bolsa de valores.

Outra definição é a dada por BM&FBovespa (2016), apontando que os índices acionários resume a evolução dos preços de um conjunto de ações em um único indicador. São números absolutos utilizados para representar o valor de mercado de uma carteira teórica de ações e para observar sua evolução temporal.

Um dos índices mais relevantes do mercado financeiro mundial é o S&P 500, estudado nesta pesquisa, da bolsa de valores de Nova Iorque. De acordo com Siegel (2015), o S&P 500 é composto por quinhentas ações selecionadas de acordo com o seu tamanho de mercado, liquidez e sua representação de grupo industrial. Os ativos deste índice estão presentes para negociação nas bolsas dos Estados Unidos, NYSE (New York Stock Exchange) e NASDAQ.

4. Metodologia

4.1 Dados Disponíveis

Os dados utilizados para treinamento, validação e testes das RNAs foram retirados do site oficial do índice S&P 500 contendo informações dos valores do índice desde 20/04/2011 até 21/10/2016, onde as informações entre as datas 20/04/2011 até 19/04/2016 foram utilizadas para o treinamento e validação das redes, e os dados contidos entre 20/04/2016 e 21/10/2016 foram utilizados para testar a melhor RNA dentre as configurações utilizadas. A Figura 1 mostra a disposição dos dados da forma como foram obtidos e tais informações englobam amostras com os seguintes dados referentes ao índice: data, valor de abertura, máximo, mínimo, fechamento, variação, volume e índice de interesse de abertura.

	A	B	C	D	E	F	G	H	I
1	Date	Open	High	Low	Last	Change	Settle	Volume	Open Interest
2	2016-10-21	2136	2138,5	2123,25	2136	2,25	2134,75	1404835	2944425
3	2016-10-20	2137,5	2144,5	2126,75	2136,75	1	2137	1602595	2944305
4	2016-10-19	2131,5	2142,5	2126,5	2138	6	2138	930618	2928096
5	2016-10-18	2122,5	2139,75	2120,25	2132	9	2132	1129535	2925829
6	2016-10-17	2126,25	2130	2116,75	2121,75	4	2123	1246192	2920332
7	2016-10-14	2126,25	2143,25	2122,25	2126,25	0,75	2127	1834488	2928712
8	2016-10-13	2127,75	2132,25	2107,75	2126	5,25	2126,25	2175906	2929169
9	2016-10-12	2133	2140,75	2126,25	2128	3	2131,5	1465871	2927494
10	2016-10-11	2159,5	2160,75	2121,75	2133,5	24,5	2134,5	2231047	2942901

Figura 1: Amostra de dados disponíveis

Para a utilização dos dados nos treinamentos e testes das RNAs, faz-se necessário a realização de um pré-processamento dos dados, denominado de normalização. De acordo com Silva, Spatti e Flauzino (2010), este processo objetiva escalonar as amostras de dados para uma faixa de valores dinâmica das funções de ativação das camadas escondidas, a fim de evitar o ruído dos dados externos à rede.

Além disto, foi utilizada neste trabalho, uma técnica denominada validação cruzada por amostragem aleatória, onde 70% do conjunto total de dados disponíveis foram escolhidos de forma aleatória para o subconjunto de treinamento e os 30% restantes compuseram o subconjunto de teste e validação.

4.2 RNA Proposta

As RNAs construídas neste trabalho são do tipo MLP e possuem cinco entradas, uma camada oculta com n neurônios e um neurônio na camada de saída (ver Figura 2).

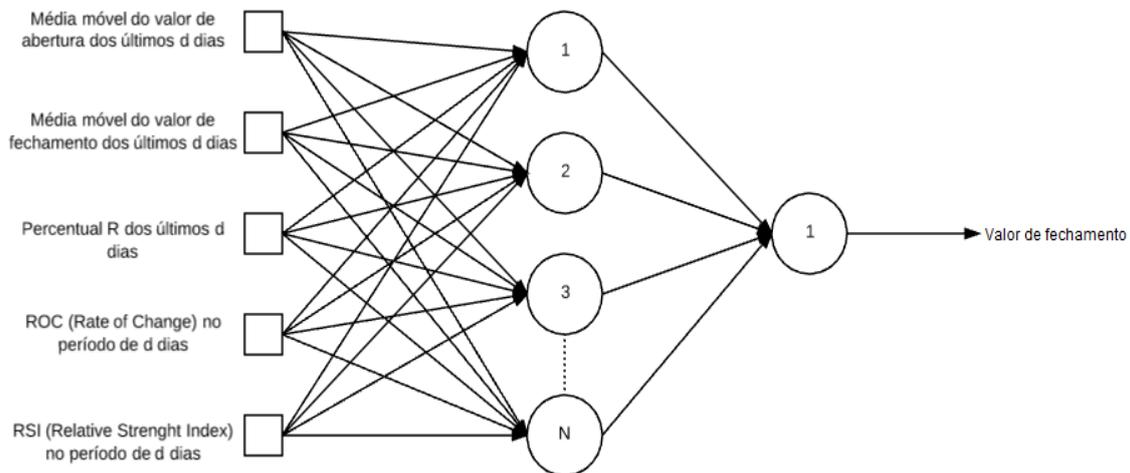


Figura 2: Modelo de RNA para previsão do índice S&P500

Conforme observado na Figura 2, os parâmetros de entrada do modelo de RNA apresentado, contém além de médias móveis de d dias do valor de abertura e fechamento do índice, 3 indicadores técnicos, sendo eles: Percentual R, *Rate of Change* (ROC) e *Relative Strength Index* (RSI), onde suas definições podem ser acompanhadas através do trabalho de Krieger (2012).

A escolha de tais parâmetros de entrada, se deu através da análise de trabalhos correlatos, como em Krieger (2012) e Roque (2009), identificando os melhores dados de entrada dos mesmos e montando um modelo com a mescla destes parâmetros.

As RNAs utilizadas nesta pesquisa foram construídas, treinadas e testadas utilizando-se a *toolbox* de Redes Neurais do software Matlab. As funções de ativação utilizadas na camada escondida das redes foram a TANSIG (sigmoide tangente hiperbólica) e LOGSIG (sigmoide logística). Na camada de saída foi utilizada a função purelin (linear). Os algoritmos de treinamento utilizados foram o TrainLM (Levenberg-Marquardt) e TrainBR (Regularização Bayesiana).

4.3 Índices para análise da qualidade de previsão

Os índices para avaliação da qualidade da previsão adotados neste trabalho foram o MAPE (Erro Médio Percentual Absoluto) e o RMSE (Raiz do Erro Quadrático Médio). Suas equações são representadas a seguir:

O MAPE pode ser calculado através da seguinte expressão:

$$MAPE = \frac{1}{n} \cdot \sum_{k=1}^n \frac{|t_k - o_k|}{(t_k + o_k)/2} \cdot 100 \quad (1)$$

Por sua vez, o RMSE é definido por:

$$RMSE = \sqrt{\frac{\sum_{k=1}^n (t_k - o_k)^2}{n}} \quad (2)$$

Onde, de acordo com Zafari, Kianmehr e Abdolazadeh (2013), para ambos os casos, t_k é a saída esperada na amostra k (valor alvo ou observado), o_k é a saída da rede (valor previsto) para a amostra k e n é o número total de amostras.

5. Resultados e Discussão

Durante a realização dos treinamentos, foram modeladas 48 configurações de RNAs, variando o algoritmo de treinamento entre o TrainLM e TrainBR, a quantidade de neurônios da camada oculta entre 3 e 15 (isto porque percebeu-se via testes, que acima de 13 neurônios havia perda de desempenho) e função de ativação (entre LOGSIG e TANSIG). Cada configuração de RNA foi treinada 30 vezes, e dentre estes treinamentos, foi escolhida a rede com menor RMSE, como sendo a melhor rede daquela configuração.

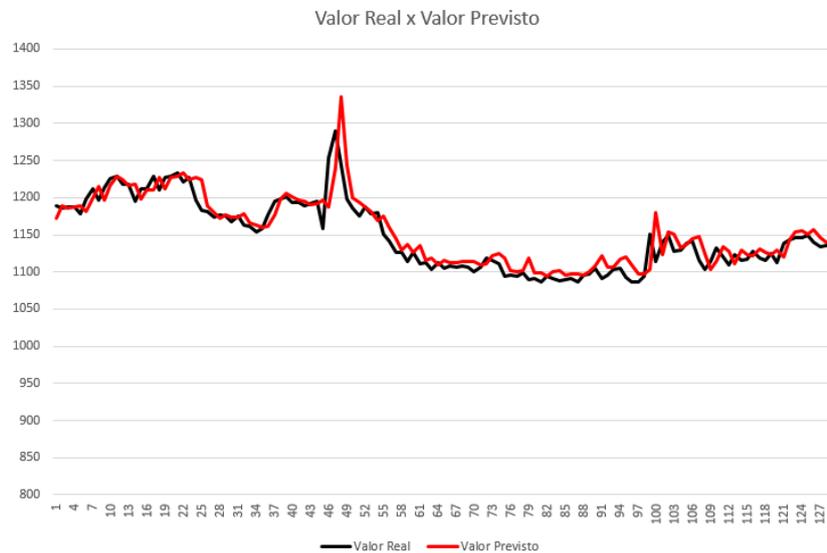
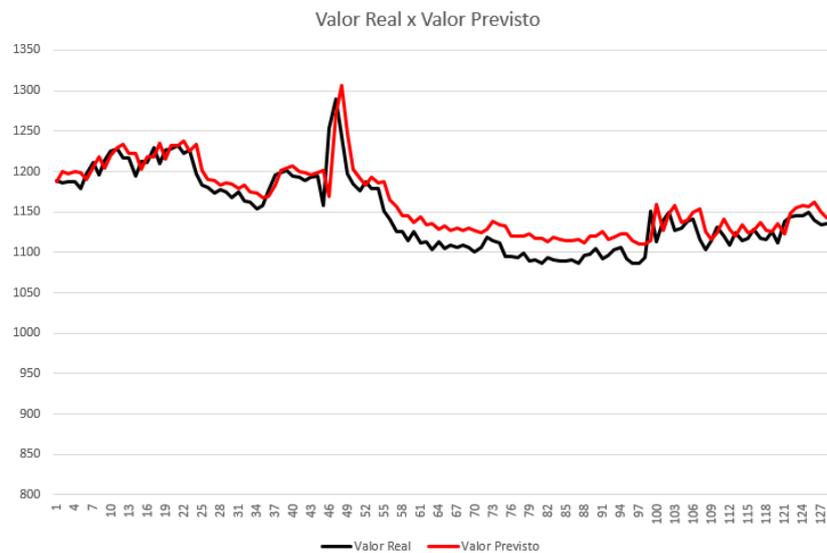
A seguir, as melhores topologias foram comparadas entre si, objetivando identificar as 2 melhores RNAs, ou seja, a rede com melhor MAPE e a rede com melhor RMSE. A rede com menor RMSE utilizou 50 dias uteis para as médias móveis, algoritmo de treinamento TrainLM com função de ativação LOGSIG e 11 neurônios na camada oculta. Já a RNA com menor MAPE, utilizou 5 dias para as médias móveis, algoritmo de treinamento TrainBR, com função de ativação LOGSIG e 9 neurônios na camada oculta.

Os resultados produzidos por estas duas RNAs são apresentados na Tabela 1, onde as colunas RMSE Trei. e MAPE Trei. são dados dos índices de qualidades obtidos no período de treinamento entre 20/04/2011 e 21/10/2016, e as colunas RMSE Tes. e MAPE Tes. representam os dados de testes compreendidos entre 20/04/2011 até 19/04/2016

Rede	RMSE Trei.	MAPE Trei.	RMSE Tes.	MAPE Tes.
Melhor RMSE Trei.	0.01132	2.2694	0.000299	1.25339
Melhor MAPE Trei.	0.01245	2.1746	0.000400	1.71788

Tabela 1: Desempenho das melhores configurações

Na Figura 3 são apresentados graficamente os valores reais do índice e os previstos pela rede com melhor RMSE, e por sua vez, a Figura 4 apresenta a comparação entre os valores reais e previstos para a rede com melhor MAPE.

**Figura 3: Comparação entre valor real do índice e previsão da rede com melhor RMSE****Figura 4: Comparação entre valor real do índice e previsão da rede com melhor MAPE.**

Os resultados apresentados por ambas as redes demonstram a possibilidade de realizar a previsão do valor de fechamento do índice S&P 500 com o período de um dia de antecedência, apresentando um erro médio percentual absoluto (MAPE) abaixo de 2,5%. Vale ressaltar que, como toda modelagem matemática, a generalização dos resultados obtidos através desta pesquisa, não pode ser utilizada diretamente para outros casos (outros índices ou ações da bolsa), visto que para cada caso, necessita-se de um estudo objetivando encontrar a melhor configuração para aquele caso.

6. Conclusões

Este trabalho descreve a modelagem de Redes Neurais Artificiais para realizar a predição do valor de fechamento do índice S&P 500 da bolsa de valores de Nova Iorque. O tipo de Rede Neural utilizada neste trabalho foi a Multilayer Perceptron, onde foram criadas configurações variando o algoritmo de treinamento entre o TrainLM e TrainBR, a função de ativação dos neurônios da camada oculta entre LOGSIG e TANSIG e a quantidade de neurônios na camada oculta, que ficou entre 3 e 15. Ainda assim, cada configuração de rede foi treinada 30 vezes para tentar diminuir os efeitos causados pela aleatoriedade dos valores iniciais.

Para avaliar o desempenho das redes modeladas, foram utilizadas as métricas de erro RMSE e MAPE. Onde a partir desses índices de avaliação de qualidade, foram selecionadas as duas melhores configurações, sendo estas, a rede com melhor RMSE e a com melhor MAPE. A rede com melhor RMSE, apresentou no período de testes, os valores 0.000299 e 1.25339 para o RMSE e o MAPE, respectivamente. Enquanto a rede com melhor MAPE apresentou RMSE e MAPE de 0.0004 e 1.71788 respectivamente.

Os resultados apresentados pelas redes demonstram que é possível fazer a previsão do índice S&P 500 com um dia de antecedência, utilizando como entrada das RNAs dados históricos do índice e indicadores de análise técnica. No estudo de caso realizado obteve-se um MAPE abaixo de 5%, ou seja, houve um percentual de acerto acima de 95%.

A partir do presente trabalho vislumbra-se algumas possibilidades de continuidade. Uma possibilidade de continuidade é a comparação com outros modelos baseados em Redes Neurais, tais como, as RNAs de arquitetura recorrentes ou a rede RBF, que pode ser usada nos mesmos tipos de problemas que a MLP. A realização de comparações entre o modelo de previsão baseado em Redes Neurais Artificiais com outros modelos de predição de índices da bolsa de valores, como, por exemplo, modelos estatísticos ou outros modelos que trabalhem com séries temporais também é uma possibilidade.

Referências

- BM&FBOVESPA. Programa de Qualificação Operacional: Apresentação da Certificação Profissional do PQO, 2016.
- Krieger eduardo, Paulo. Uso de Redes Neurais Artificiais para Predição da Bolsa de Valores. 2012. 91 folhas. Trabalho Técnico-científico de Conclusão de Curso (Graduação em Ciência da Computação) – Centro de Ciências Tecnológicas da Terra e do Mar, Universidade do Vale do Itajaí, Itajaí, 2012.
- Lagioia, U. C. T. Fundamentos do Mercado de Capitais. Editora Atlas, 2007
- Rêgo, R. H. T; Mussa, A. Anomalias do mercado acionário: A verificação do efeito feriado no IBOVESPA e IBX-100 no período de 2002 a 2007. Congresso USP de

- Controladoria e Contabilidade, n. 8, 2008. São Paulo.
- Roque, R. C. Estudo sobre a empregabilidade da previsão do índice BOVESPA usando Redes Neurais Artificiais. 2009. 101 f. Escola Politécnica, Departamento de Eletrônica e de Computação, Universidade do Rio de Janeiro, Rio de Janeiro. 2009.
- Siegel, J. J. Investindo em ações no longo Prazo: O guia indispensável do investidor no mercado financeiro. 5. Ed. Editora Bookman, 2015.
- Silva, I. N. DA; Spatti, D. H.; Flauzino, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas. São Paulo: Artliber, 2010.
- Soares, D. G; Teive, R. C. G. Previsão de Cheias do Rio Itajaí-Açu Utilizando Redes Neurais Artificiais. Computer on the beach, 2015.
- Tsaih, R. Hsu, Y. Lai, C. C. Forecasting S&P 500 stock index futures with a hybrid AI system. Decision Support Systems 23 1998 161–174 (1998) 163
- WANG, J-Z, WANG, J-J, ZHANG, Z-G, GUO, S-P. Forecasting stock indices with back propagation neural network. Expert System with Applications, 38 (2011) 14346–14355
- Yudong, Z. Lenan, W. Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network. Expert Systems with Applications 36 (2009) 8849–8854
- Zafari, A.; Kianmehr, M. H.; Abdolazadeh, R. Modeling the effect of extrusion parameters on density of biomass pellet using artificial neural network. International Journal Of Recycling of Organic Waste in Agriculture, v. 2, n. 1, p. 9, 2013.