

Influential Article Review - Assessment Of Estimation Strategies in the Stock Market

Jayden Sampson

Sol Kenny

Laiba Vinson

This paper examines the financial market. We present insights from a highly influential paper. Here are the highlights from this paper: Forecasting stock market returns is one of the most effective tools for risk management and portfolio diversification. There are several forecasting techniques in the literature for obtaining accurate forecasts for investment decision making. Numerous empirical studies have employed such methods to investigate the returns of different individual stock indices. However, there have been very few studies of groups of stock markets or indices. The findings of previous studies indicate that there is no single method that can be applied uniformly to all markets. In this context, this study aimed to examine the predictive performance of linear, nonlinear, artificial intelligence, frequency domain, and hybrid models to find an appropriate model to forecast the stock returns of developed, emerging, and frontier markets. We considered the daily stock market returns of selected indices from developed, emerging, and frontier markets for the period 2000–2018 to evaluate the predictive performance of the above models. The results showed that no single model out of the five models could be applied uniformly to all markets. However, traditional linear and nonlinear models outperformed artificial intelligence and frequency domain models in providing accurate forecasts. For our overseas readers, we then present the insights from this paper in Spanish, French, Portuguese, and German.

Keywords: Financial markets, Stock returns, Linear and nonlinear, Forecasting techniques, Root mean square error

SUMMARY

- Here, we present the empirical results, comprising descriptive statistics and the performance measures of various forecasting methods for stock returns in developed, emerging, and frontier markets.
- Tables 1, 2, and 3 present the summary statistics for developed, emerging, and frontier stock market returns, respectively. From these tables, we can see that the mean returns in all markets are positive, indicating overall positive returns on investments during the period considered for this study. The kurtosis values of the return series of all the markets are observed to be greater than 3, indicating that all of the series are leptokurtic—i.e., they have thick tails, which is a common phenomenon in

stock returns . The Jarque–Bera test showed that the series are non-normally distributed. Another key feature, from the Tsay test, is that the returns of all the markets are nonlinear.

- Before applying the forecasting methods, we divided the data into the training set and the test set; we used 80% of the data for training the models and the remaining 20% for testing the models. To forecast the returns using the ARIMA model, it was necessary to check stationarity to have valid inferences. To test the stationarity of the returns series, we employed the augmented Dickey–Fuller and Phillips–Perron tests; the results showed that the returns of all of the markets were stationary. We determined the optimal lag length for the autoregressive and moving average components using the Akaike information criterion . We observed different orders of AR and MA for different series and present them along with RMSE values in Tables 4, 5, and 6. In the SETAR model, the series exhibited nonlinear trends, and we identified two regimes by the minimum AIC values. Then, the model was used to forecast the returns of the markets. To forecast stock returns using the ANN model, we employed feedforward neural networks since many studies have shown that they fit well with asset return data . We employed a recurrent singular spectrum analysis model to forecast the returns after decomposing and reconstructing the original returns series by following the four steps involved in forecasting with SSA: embedding, reconstructing, grouping, and diagonal averaging. For the hybrid model, which is a combination of ARIMA and ANN, we fit the model by employing the widely used inverse mean square forecast error ratio for assigning the optimal weights for the models in forecasting. Tables 4, 5, and 6 present the RMSE values of the test sets of the forecast series for all techniques for developed, emerging, and frontier markets, respectively. The model with the lowest RMSE was chosen as the most appropriate model. In addition, we tested RMSE significance using the Diebold–Marino test and found that the RMSE of all of the models was significant, except for Japan, South Africa, and Sri Lanka.

HIGHLY INFLUENTIAL ARTICLE

We used the following article as a basis of our evaluation:

Mallikarjuna, M., & Rao, R. P. (2019). Evaluation of forecasting methods from selected stock market returns. *Financial Innovation*, 5(1), 1–16.

This is the link to the publisher's website:

<https://jfin-swufe.springeropen.com/articles/10.1186/s40854-019-0157-x>

INTRODUCTION

Theoretical and empirical studies have shown that a positive relationship exists between financial markets and economic growth (e.g., Levine, 1997; Rajan and Zingales, 1998; Rousseau and Watchel, 2000; Beck et al., 2003; Guptha and Rao, 2018). Given the significance of financial markets, forecasting financial returns occupies a paramount position in investment decision making. However, stock markets are characterized by high volatility, dynamism, and complexity (Johnson et al., 2003; Cristelli, 2014; Wieland, 2015). Movements in stock markets are influenced by several factors, such as macro-economic factors, international events, and human behavior. Hence, forecasting stock returns can become a challenging task. The profitability of investments in stock markets highly depends on the predictability of stock movements. If a forecasting model or technique can precisely predict the direction of the market, investment risk and uncertainty can be minimized. It would enhance investment flows into stock markets and also be useful for policymakers and regulators in making appropriate decisions and taking corrective measures.

There are two distinct schools of thought—namely, fundamental analysis and technical analysis—for predicting stock price movements. Fundamentalists forecast stock prices on the basis of financial analyses of companies or industries. Technical analysts, meanwhile, use historical securities data and predict future prices on the assumption that stock prices are determined by market forces and that history tends to repeat

itself (Levy, 1967). These theories coexisted for several decades as strategies for investment decision making. These approaches were challenged in the 1960s by random walk theory, popularly known as the efficient market hypothesis (Fama, 1970), which proposes that future changes in stock prices cannot be predicted from past price changes. Some empirical studies have shown the presence of ‘random walk’ in stock prices (e.g., Tong et al., 2014; Konak and Seker, 2014; Erdem and Ulucak, 2016). However, most empirical studies have found that stock prices are predictable (Darrat and Zhong, 2000; Lo and MacKinlay, 2002; Harrison and Moore, 2012; Owido et al., 2013; Radikoko, 2014; Said, 2015; Almudhaf, 2018).

Various forecasting techniques are available for time series forecasting. Autoregressive integrated moving average (ARIMA) models were proposed by Box and Jenkins (1970) for time series analysis and forecasting. Some studies have been conducted by employing ARIMA models to forecast stock market returns (Al-Shaib, 2006; Ojo and Olatayo, 2009; Adebiyi and Oluinka, 2014; Mondal et al., 2014). Quite a few studies found that ARIMA models produced inferior forecasts for financial time series data (Zhang, 2003; Adebiyi and Oluinka, 2014; Khandelwal et al., 2015). To account for nonlinearities resulting from regime changes in economies, some researchers have used Markov regime-switching models and threshold autoregressive (TAR) models assuming nonlinear stationary processes to predict stock prices (Hamilton, 1989; Tong, 1990). Tasy (1989) proposed a simple yet widely applicable model-building procedure for threshold autoregressive models as well as a test for threshold nonlinearity. Gooijer (1998) considered regime switching in a moving average (MA) model and used validation criteria for self-exciting threshold autoregressive (SETAR) model selection. Some empirical studies comparing different methods with SETAR found that this method produced superior results to linear models (e.g., Clements and Smith, 1999; Boero and Marroc, 2002; Boero, 2003; Firat, 2017).

In the late 1980s, a class of artificial intelligence (AI) models—such as feedforward, backpropagation, and recurrent neural network models—were introduced for forecasting purposes. The distinguishing features of artificial neural networks (ANN) are that they are data-driven, nonlinear, and self-adaptive, and they have very few *a priori* assumptions. This makes ANNs valuable and attractive for forecasting financial time series. Among ANN models, the feed-forward neural network with a single hidden layer has become the most popular for forecasting stock market returns (Zhang, 2003). Many studies have shown that these models yield more accurate forecasts compared to naïve and linear models (e.g., Ghiasi et al., 2005; Mostafa, 2010; Qiu et al., 2016; Aras and Kocakoc, 2016).

In addition, there are various neural network models for forecasting stock returns. Lu and Wu (2011) used the cerebellar model articulation controller neural network (CAMC NN) model to forecast the stock market indices of the Nikkei 225 and the Taiwan Stock Exchange. The results showed that CAMC NN made more accurate forecasts than support vector regression and back-propagation neural network (BPNN) models. Guresen et al. (2011) observed that classical ANN models and multilayer perceptron (MLP) outperformed GARCH-class models for the NASDAQ index. Lahmiri (2016) employed variational mode decomposition (VMD) based general regression neural networks (GRNN) for four economic and financial data sets and found that VMD-GRNN models outperformed the ARIMA model and other neural network models. Nayak and Misra’s (2018) genetic algorithm-based condensed polynomial neural network (GA-CPNN) improved the accuracy of forecasting stock indices compared to radial basis function neural network (RBFNN) and multilayer perceptron and genetic algorithm (MLP-GA) models. Zhong and Enke (2019) observed that techniques such as deep neural networks using principal component analysis (PCA) and artificial neural networks performed better than traditional models. However, most studies have found that traditional ANN models, as well as ANN models combined with linear models, produce more accurate forecasts than other models (e.g., Asadi et al., 2010; Wang et al., 2011; Khandelwal et al., 2015; Mallikarjuna et al., 2018).

Recently, frequency-domain models, such as spectral analysis, wavelets, and Fourier transformations, have been proposed to improve the forecasting accuracy of financial time series. One widely used technique is singular spectrum analysis (SSA), which is a robust nonparametric method with no prior assumptions about the data (Golyandina et al., 2001; Hassani et al., 2013a). SSA decomposes a time series data into its components and then reconstructs the series by leaving the random noise component before using the reconstructed series to forecast the future points in the series (Hassani, 2007; Ghodsi and Omer, 2014).

Since most financial time series data sets exhibit neither purely linear nor purely nonlinear patterns, the combination of linear and nonlinear, i.e., hybrid techniques to model complex data structures for improved accuracy has been proposed (Asadi et al., 2010; Khashei and Bijari, 2010; Khashei and Bijari, 2012; Khandelwal et al., 2015; Ince and Trafalis, 2017). Khashei and Hajirahimi (2017) compared linear and nonlinear models with hybrid models (HM) and concluded that hybrid models perform better than individual models.

Only a few studies have aimed to find a suitable method for forecasting the stock returns of a group of markets. Guidolin et al. (2009) evaluated the performance of linear and nonlinear models for forecasting the financial asset returns of G7 countries. They found that nonlinear models, such as threshold autoregressive (TAR) and smooth transition autoregressive (STAR) models, performed better than linear models in the case of US and UK asset returns. Meanwhile, simple linear models such as random walk and autoregressive models were better for French, German, and Italian asset returns. This suggests that no single model is suitable for forecasting the returns of all stock markets. Awajan et al. (2018) compared the performance of several forecasting methods by applying them to six stock markets and found that the empirical mode decomposition Holt–Winters method (EMD-HW) provided more accurate forecasts than other models.

Though there are various techniques for forecasting stock market returns, no single method can be employed uniformly for the returns of all stock markets. The literature indicates that there is no consensus among researchers regarding the techniques for forecasting stock market returns. The present study, therefore, aimed to evaluate different forecasting techniques—namely, ARIMA, SETAR, ANN, SSA, and HM models, representing linear, nonlinear, artificial intelligence (AI), frequency domain, and hybrid methods, respectively—as applied to individual stock markets. This study also examined the suitability of different forecasting methods for each category of the world stock markets—namely, developed, emerging, and frontier. Finding a single method that can produce optimal forecasts for all markets could help investors save time and resources and make better decisions. This study is mainly useful for international investors and foreign institutional investors who wish to minimize risks and diversify their portfolios, with the aim of maximizing profits. The objectives of the present study are outlined below.

Objectives

1. To forecast stock market returns using linear, nonlinear, artificial intelligence, frequency domain, and hybrid methods.
2. To find the most appropriate forecasting techniques among the five above-mentioned techniques for developed, emerging, and frontier markets.
3. To check whether any single technique can be applied to all markets to obtain optimal forecasts.

The rest of this paper is organized as follows. Section 2 describes the data and methods employed in the study. Section 3 presents the empirical results. Finally, the conclusions are given in section 4.

CONCLUSION

Over the years, stock markets have become alternative avenues for surplus funds among individual and institutional investors, especially following globalization and the integration of world financial markets. Given the inherent risk, uncertainty, and dynamic nature of stock markets, accurately forecasting stock returns can help to minimize investors' risks. Thus, forecasting techniques can help with better investment decision making.

This study considered daily data for stock market returns during the period 1 January 2000 to 30 December 2018 to compare forecasting techniques (i.e., ARIMA, SETAR, ANN, SSA, and HM models) representing linear, nonlinear, AI, frequency domain, and hybrid methods. We took the stock indices of 24 stock markets in three market categories (nine developed, ten emerging, and five frontier) to find suitable forecasting techniques for each category. The results showed that no single forecasting technique provided uniformly optimal forecasting for all markets. However, SETAR performed better for ten markets, ARIMA for seven, HM for five, and ANN and SSA for one market each. SETAR and ARIMA techniques can thus

be considered the clear winners in forecasting stock market returns for developed, emerging, and frontier markets, as these two methods provided optimal forecasts for seventeen of the twenty-four markets.

APPENDIX

TABLE 1
DESCRIPTIVE STATISTICS FOR DEVELOPED MARKETS

Country	Mean	Standard Deviation	Skewness	Kurtosis	Jarque-Bera Statistic	Tsay Test
Australia	0.016900	0.981318	-0.366178	8.451780	5732.678 (0.00000)	Nonlinear
Canada	0.016719	1.043102	-0.466783	13.58932	21,277.95 (0.00000)	Nonlinear
France	0.005790	1.429676	0.141474	8.712746	6275.928 (0.00000)	Nonlinear
Germany	0.021703	1.475373	0.097060	8.111260	4987.257 (0.00000)	Nonlinear
Japan	0.019562	1.501151	-0.211389	9.413287	7642.163 (0.00000)	Nonlinear
Korea	0.040316	1.384506	-0.350392	9.724636	8473.831 (0.00000)	Nonlinear
Switzerland	0.007731	1.174780	-0.012284	10.18851	9766.624 (0.00000)	Nonlinear
UK	0.009243	1.171826	-0.004334	9.918071	9061.453 (0.00000)	Nonlinear
US	0.020694	1.147998	-0.089045	12.10219	15,630.08 (0.00000)	Nonlinear

TABLE 2
DESCRIPTIVE STATISTICS FOR EMERGING MARKETS

Country	Mean	Standard Deviation	Skewness	Kurtosis	Jarque-Bera Statistic	Tsay Test
Brazil	0.055547	1.769091	0.075096	7.347967	3439.261 (0.00000)	Nonlinear
China	0.016499	1.585054	-0.218775	7.684998	4025.909 (0.00000)	Nonlinear
Egypt	0.079649	1.656833	-0.121416	13.15053	18,891.65 (0.00000)	Nonlinear
India	0.059777	1.414324	0.120611	12.83913	17,795.20 (0.00000)	Nonlinear
Indonesia	0.070676	1.326156	-0.501572	9.570707	8083.189 (0.00000)	Nonlinear
Mexico	0.051820	1.213204	0.153714	9.356521	7644.352 (0.00000)	Nonlinear
Russia	0.082735	1.965327	0.370012	24.33804	85,492.66 (0.00000)	Nonlinear
South Africa	0.047609	1.298747	0.036830	6.299922	2044.612 (0.00000)	Nonlinear
Thailand	0.047775	1.263998	-0.520070	13.23751	19,417.31 (0.00000)	Nonlinear
Turkey	0.069655	1.973356	-0.037463	9.689365	8426.657 (0.00000)	Nonlinear

TABLE 3
DESCRIPTIVE STATISTICS FOR FRONTIER MARKETS

Country	Mean	Standard Deviation	Skewness	Kurtosis	Jarque-Bera Statistic	Tsay Test
Argentina	0.120985	2.162861	0.018419	7.202958	3230.709 (0.00000)	Nonlinear
Estonia	0.052646	1.036820	0.316893	14.29612	24,406.12 (0.00000)	Nonlinear
Kenya	0.012726	0.831383	0.555709	15.16038	28,057.55 (0.00000)	Nonlinear
Tunisia	0.035152	1.292467	0.603647	20.46153	59,408.84 (0.00000)	Nonlinear
Sri Lanka	0.066494	1.128874	0.993308	43.75095	300,319.2 (0.00000)	Nonlinear

TABLE 4
RMSE VALUES OF THE FORECASTING MODELS FOR DEVELOPED MARKETS

Country	ARIMA	SETAR	ANN	SSA	HM
Australia	ARIMA (1,0,0) 0.839708	0.8371075	0.839961	0.853739	0.8398178
Canada	ARIMA (4,0,4) 0.7160948	0.7235669	0.7279448	0.721191	0.7178712
France	ARIMA (2,0,3) 1.104531	1.104509	1.121098	1.13334	1.107893
Germany	ARIMA (3,0,3) 1.137963	1.140388	1.156347	1.139859	1.138008
Japan	ARIMA (1,0,1) 1.312612	1.307090	1.312699	1.319925	1.312697
South Korea	ARIMA (1,0,2) 0.7815902	0.7845301	0.7816591	0.7975102	0.7815836
Switzerland	ARIMA (3,0,3) 0.9262604	0.9252304	0.9262753	0.935211	0.9262085
UK	ARIMA (3,0,2) 0.9002485	0.9003106	0.9093658	0.9194308	0.9057976
US	ARIMA (2,0,0) 0.8197795	0.8125207	0.8171281	0.8187795	0.8119642

TABLE 5
RMSE VALUES OF THE FORECASTING MODELS FOR EMERGING MARKETS

Country	ARIMA	SETAR	ANN	SSA	HM
Brazil	ARIMA (2,0,1) 1.441972	1.442167	1.442900	1.470025	1.442262
China	ARIMA (3,0,3) 1.555623	1.570942	1.56378	1.555431	1.554521
Egypt	ARIMA (0,0,1) 1.357198	1.324729	1.368285	1.385264	1.357206
India	ARIMA (3,0,1) 0.838730	0.844534	0.839839	0.851503	0.838335
Indonesia	ARIMA (1,0,0) 0.919355	0.926838	0.918685	0.921310	0.918988
Mexico	ARIMA (2,0,1) 0.850496	0.848814	0.867506	0.851756	0.848878
Russia	ARIMA (3,0,4) 0.996021	0.993842	1.008659	1.006565	1.000470
South Africa	ARIMA (3,0,1) 1.062336	1.064449	1.063028	1.066819	1.061791
Thailand	ARIMA (2,0,2) 0.756856	0.754199	0.770766	0.775997	0.762275
Turkey	ARIMA (2,0,2) 1.280623	1.28606	1.292737	1.291581	1.283447

TABLE 6
RMSE VALUES OF THE FORECASTING MODELS FOR FRONTIER MARKETS

Country	ARIMA	SETAR	ANN	SSA	HM
Argentina	ARIMA (1,0,0) 2.058513	2.046473	2.059416	2.067785	2.061399
Estonia	ARIMA (1, 0, 2) 0.554262	0.576389	0.593064	0.567850	0.574015
Kenya	ARIMA (2,0,2) 0.679084	0.656696	0.656707	0.680819	0.684070
Sri Lanka	ARIMA (0,0,2) 0.443346	0.449314	0.444426	0.473222	0.445437
Tunisia	ARIMA (1,0,0) 0.460538	0.44934	0.618865	0.443756	0.464829

REFERENCES

- Adebiyi AA, Oluinka A (2014) Comparision of ARIMA and artificial neural network models for stock market prediction. *Journal of Applied Mathematics*. <https://doi.org/10.1155/2014/614342>
- Almudhaf F (2018) Predictability, Price bubbles, and efficiency in the Indonesian stock-market. *Bull Indones Econ Stud* 54(1):113–124
- Al-Shaib M (2006) The predictability of the Amman stock exchange using Univariate autoregressive integrated moving average (ARIMA) model. *Journal of Economic and Administrative Sciences* 22(2):17–35
- Aras S, Kocakoc ID (2016) A new model selection strategy in time series forecasting with artificial neural networks. *IHTS Neurocomputing* 174:974–987
- Asadi S, Tavakoli A, Hejazi SR (2010) A new hybrid for improvement of auto-regressive integrated moving average models applying particle swarm optimization. *Expert Syst Appl* 39:5332–5337
- Awajan AM, Ismail MT, Wadi SA (2018) Improving forecasting accuracy for stock market data using EMD-HW bagging. *PLoS One* 13(7):1–20
- Bates JM, Granger CWJ (1969) The combination of forecasts. *Operational Research Society* 20(4):451–468
- Beck T, Levine R (2003) Stock markets, banks and growth: panel evidence. *J Bank Financ* 28:423–442
- Boero G (2003) The performance of SETAR models: a regime conditional evaluation of point, interval and density forecasts. *Int J Forecast* 20:305–320
- Boero G, Marrocu E (2002) The performance of non-linear exchange rate models: a forecasting comparison. *J Forecast* 21(7):513–542
- Bouchaud JP, Potters M (2001) More stylized facts of financial markets: leverage effect and downside correlations. *Physica A* 299:60–70
- Box GEP, Jenkins GM (1970) Time series analysis: forecasting and control. Holden-Day, San Francisco
- Chai T, Draxler RR (2014) Root mean square error (RMSE) or mean absolute error (MAE)? – arguments against avoiding RMSE in the literature. *Geo Scientific Model Development* 7:1247–1250
- Clements MP, Smith J (1999) A Monte Carlo study of the forecasting performance of empirical SETAR models. *J Appl Econ* 14:124–141
- Cristelli M (2014) Complexity in financial markets. Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-319-00723-6>
- Darrat AF, Zhong M (2000) On testing the random walk hypothesis a model Comparision approach. *The Financial Review* 35:105–124
- Denton JW (1995) How good are neural networks for causal forecasting? *The Journal of Business Forecasting Methods and Systems* 14(2):17–23
- Dickey D, Fuller W (1979) Distribution of the estimators for autoregressive time series with a unit root. *Journal of American Statistical Association* 74(366):427–431
- Diebold FX, Marino RS (1995) Comparing predictive accuracy. *J Bus Econ Stat* 13(3):134–144
- Erdem E, Ulucak R (2016) Efficiency of stock exchange markets in G7 countries: bootstrap causality approach. *Economics World* 4(1):17–24
- Fama EF (1970) Efficient capital markets:a review of theory and empirical work. *J Financ* 25(2):383–417

- Firat EH (2017) SETAR (self-exciting threshold autoregressive) non-linear currency Modelling in EUR/USD, EUR/TRY and USD/TRY parities. *Mathematics and Statistics* 5(1):33–55
- Ghiassi M, Saidane H, Zimbra DK (2005) A dynamic artificial neural network model for forecasting series events. *Int J Forecast* 21:341–362
- Ghodsi Z, Omer HN (2014) Forecasting energy data using singular Spectrum analysis in the presence of outlier(s). *International Journal of Energy and Statistics* 2(2):125–136
- Golyandina N, Nekrutkin V, Zhigljavsky A (2001) Analysis of time series structure SSA and related techniques. Chapman and Hall/CRC, Newyork
- Gooijer DJ (1998) On threshold moving-average models. *J Time Ser Anal* 19(1):1–18
- Guidolin M, Hyde S, McMillan D, Ono S (2009). Non-linear predictability in stock and bond returns: when and where is it exploitable. Federal Reserve Bank of St. Louis: working paper series no 2008-010B
- Guptha SK, Rao RP (2018) The causal relationship between financial development and economic growth experience with BRICS economies. *Journal of Social and Economic Development* 20(2):308–326
- Guresen E, Kayakutlu G, Daim TU (2011) Using artificial neural network models in stock market index prediction. *Expert Syst Appl* 38:10389–10397
- Hamilton JD (1989) A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica* 57:357–384
- Harrison B, Moore M (2012) Stock market efficiency, non-linearity, thin trading and asymmetric information in MENA stock markets. *Economic Issues* 17(1):77–93
- Hassani H (2007) Singular spectrum analysis: methodology and comparison. *Journal of Data Science* 5(2):239–257
- Hassani H, Soofi A, Zhiglavsky A (2013a) Forecasting UK industrial production with multivariate singular Spectrum analysis. *J Forecast* 32(5):395–408
- Hassani H, Soofi A, Zhiglavsky A (2013b) Predicting inflation dynamics with singular Spectrum analysis. *J R Stat Soc* 176(3):743–760
- Humala A (2013) Some stylized facts of return in the foreign exchange and stock markets in Peru. *Stud Econ Financ* 30(2):139–158
- Hung SL, Adeli H (1993) Parallel backpropagation algorithms on CRAY Y-MP8/864 supercomputer. *Neurocomputing* 5(6):287–302
- Hyndman R, Athanasopoulos G (2015) Forecasting principles and practice. Otexts, Melbourne. Available at: <https://otexts.com/fpp3/>. Accessed 20 Mar 2019.
- Ince H, Trafalidis TB (2017) A hybrid forecasting model for stock market prediction. *Economic Computation and Economic Cybernetics Studies and Research* 21:263–280
- Ismail MT, Isa Z (2006) Modelling exchange rate using regime switching models. *Sains Malaysiana* 35(2):55–62
- Johnson NF, Jefferies P, Hui PM (2003) Financial market complexity. Oxford University Press, Oxford
- Khandelwal I, Adhikari R (2015) Time series forecasting using hybrid ARIMA and ANN models based on DWT decomposition. *Procedia Computer Science* 48:173–179
- Khashei M, Bijari M (2010) An artificial neural network model for time series forecasting. *Expert Syst Appl* 37:479–489
- Khashei M, Bijari M (2012) A new class of hybrid models for time series forecasting. *Expert Syst Appl* 39:4344–4357
- Khashei M, Hajirahimi Z (2017) Performance evaluation of series and parallel strategies for financial time series forecasting. *Financial Innovation* 3(24):1–24
- Konak F, Seker Y (2014) The efficiency of developed markets: empirical evidence from FTSE 100. *J Adv Manag Sci* 2(1):29–32
- Lahmiri S (2016) A variational mode decomposition approach for analysis and forecasting of economic and financial time series. *Expert Syst Appl* 55:268–273
- Levine R (1997) Financial development and economic growth: views and agenda. *J Econ Lit* 35:688–726
- Levy RA (1967) The theory of random walks: a study of findings. *Am Econ* 11(2):34–48

- Lo AW, Mackinlay AC (2002) An non-random walk down Wall street. Princeton University Press, Princeton
- Lu CJ, Wu JY (2011) An efficient CMAC neural network for stock index forecasting. *Expert Syst Appl* 38:15194–15201
- Makridakis S, Wheelwright SC, Hyndman RJ (2015) Forecasting: methods and applications. Wiley India, New Delhi
- Mallikarjuna M, Arti G, Rao RP (2018) Forecasting stock returns of selected sectors of Indian capital market. *SS International Journal of Economics and Management* 8(6):111–126
- Mallikarjuna M, Guptha KS, Rao RP (2017) Modelling Sectoral volatility of Indian stock markets. *Wealth International Journal of Money Banking and Finance* 6(2):4–9
- Markham IS, Rakes TR (1998) The effect of sample size and variability of data on the comparative performance of artificial neural networks and regression. *Comput Oper Res* 25:251–263
- Mondal P, Shit L, Goswami S (2014) Study of effectiveness of time series Modelling (ARIMA) in forecasting stock prices. *International Journal of Computer Science, Engineering and Applications* 4(2):13–29
- Mostafa MM (2010) Forecasting stock exchange movements using neural networks: empirical evidence from Kuwait. *Expert Syst Appl* 37:6302–6309
- MSCI (2018) MSCI Announces the Results of Its Annual Market Classification Review. Available at: <https://www.msci.com/market-classification>. Accessed 25 Mar 2019
- Nayak SC, Misra BB (2018) Estimating stock closing indices using a GA-weighted condensed polynomial neural network. *Financial Innovation* 4(21):1–22
- Ojo JF, Olatayo TO (2009) ON the estimation and performance of subset of autoregressive integrated moving average models. *Eur J Sci Res* 28:287–293
- Owido PK, Onyuma SO, Owuor G (2013) A GARCH approach to measuring efficiency: a case study of Nairobi securities exchange. *Research Journal of Finance and Accounting* 4(4):1–16
- Phillips PCB, Perron P (1988) Testing for unit roots in time series regression. *Biometrika* 75:335–346
- Qiu M, Song Y, Akagi F (2016) Application of artificial neural network for the prediction of stock market returns the case of the Japanese stock market. *Chaos, Solitons and Fractals* 85:1–7
- Radikoko I (2014) Testing weak-form market efficiency on the TSX. *J Appl Bus Res* 30(3):647–658
- Rajan R, Zingales L (1998) Financial dependence and growth. *Am Econ Rev* 88:559–586
- Rousseau PL, Watchel P (2000) Equity markets and growth: cross-country evidence on timing and outcomes, 1980–1995. *J Bank Financ* 24(12):1933–1957
- Said A (2015) The efficiency of the Russian stock market: a revisit of the random walk hypothesis. *Academy of Accounting and Financial Studies Journal* 19(1):42–48
- Tong H (1983) Threshold models in non-linear time series analysis. Springer, Berlin. <https://doi.org/10.1007/978-1-4684-7888-4>
- Tong H (1990) Non-Linear Time Series: A Dynamical System Approach. Oxford University Press, Oxford
- Tong T, Li B, Benkato O (2014) Revisiting the weak form efficiency of the Australian stock market. *Corp Ownersh Control* 11(2):21–28
- Tsay R (1989) Testing and modeling threshold autoregressive processes. *Journal of American Statistical Association* 84:231–240
- Wang JZ, Wang JJ, Zhang ZG, Guo SP (2011) Forecasting stock indices with backpropagation neural network. *Expert Syst Appl* 38:14346–14355
- Watier L, Richardson S (1995) Modelling of an epidemiological time series by a threshold autoregressive model. *Journal of Royal Statistical Society* 44(3):353–364
- Wieland OL (2015) Modern financial markets and the complexity of financial innovation. *Universal Journal of Accounting and Finance* 3(3):117–125
- Winkler RL, Makridakis S (1983) The combination of forecasts. *J R Stat Soc* 146(2):150–157
- Zhang GP (2003) Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing* 50:159–175

Zhong X, Enke D (2019) Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation* 5(4):1–20

TRANSLATED VERSION: SPANISH

Below is a rough translation of the insights presented above. This was done to give a general understanding of the ideas presented in the paper. Please excuse any grammatical mistakes and do not hold the original authors responsible for these mistakes.

VERSIÓN TRADUCIDA: ESPAÑOL

A continuación se muestra una traducción aproximada de las ideas presentadas anteriormente. Esto se hizo para dar una comprensión general de las ideas presentadas en el documento. Por favor, disculpe cualquier error gramatical y no responsabilite a los autores originales de estos errores.

INTRODUCCIÓN

Estudios teóricos y empíricos han demostrado que existe una relación positiva entre los mercados financieros y el crecimiento económico (por ejemplo, Levine, 1997; Rajan y Zingales, 1998; Rousseau y Watchel, 2000; Beck et al., 2003; Guptha y Rao, 2018). Dada la importancia de los mercados financieros, la previsión de rendimientos financieros ocupa una posición primordial en la toma de decisiones de inversión. Sin embargo, los mercados bursátiles se caracterizan por una alta volatilidad, dinamismo y complejidad (Johnson et al., 2003; Cristelli, 2014; Wieland, 2015). Los movimientos en los mercados bursátiles están influenciados por varios factores, como factores macroeconómicas, eventos internacionales y comportamiento humano. Por lo tanto, la previsión de rendimientos de acciones puede convertirse en una tarea difícil. La rentabilidad de las inversiones en los mercados bursátiles depende en gran medida de la previsibilidad de los movimientos de acciones. Si un modelo o técnica de previsión puede predecir con precisión la dirección del mercado, el riesgo de inversión y la incertidumbre se pueden minimizar. Mejoraría los flujos de inversión hacia los mercados bursátiles y también sería útil para los responsables de la formulación de políticas y los reguladores a la disposición de decisiones adecuadas y a la adopción de medidas correctivas.

Hay dos escuelas de pensamiento distintas, a saber, el análisis fundamental y el análisis técnico, para predecir los movimientos de los precios de las acciones. Los fundamentalistas pronostican los precios de las acciones sobre la base de análisis financieros de empresas o industrias. Los analistas técnicos, por su parte, utilizan datos históricos de valores y predicen los precios futuros en el supuesto de que los precios de las acciones están determinados por las fuerzas del mercado y que la historia tiende a repetirse (Levy, 1967). Estas teorías coexistieron durante varias décadas como estrategias para la toma de decisiones de inversión. Estos enfoques fueron desafiados en la década de 1960 por la teoría del paseo aleatorio, conocida popularmente como la hipótesis de mercado eficiente (Fama, 1970), que propone que los cambios futuros en los precios de las acciones no se pueden predecir a partir de cambios de precios pasados. Algunos estudios empíricos han demostrado la presencia de "caminar al azar" en los precios de las acciones (por ejemplo, Tong et al., 2014; Konak y Seker, 2014; Erdem y Ulucak, 2016). Sin embargo, la mayoría de los estudios empíricos han encontrado que los precios de las acciones son predecibles (Darrat y Zhong, 2000; Lo y mackinlay, 2002; Harrison y Moore, 2012; Owido et al., 2013; Radikoko, 2014; Dijo, 2015; Almudhaf, 2018).

Hay varias técnicas de previsión disponibles para la previsión de series temporales. Los modelos de media móvil integrada autoregresiva (ARIMA) fueron propuestos por Box y Jenkins (1970) para el análisis y la previsión de series temporales. Algunos estudios se han realizado empleando modelos ARIMA para pronosticar los rendimientos del mercado de valores (Al-Shaib, 2006; Ojo y Olatayo, 2009; Adebiyi y Oluinka, 2014; Mondal et al., 2014). En algunos estudios se encontró que los modelos ARIMA producían previsiones inferiores para los datos de series temporales financieras (Zhang, 2003; Adebiyi y Oluinka,

2014; Khandelwal et al., 2015). Para tener en cuenta las no linealidades resultantes de los cambios de régimen en las economías, algunos investigadores han utilizado modelos de cambio de régimen de Markov y modelos autoregresivos de umbrales (TAR) asumiendo procesos estacionarios no lineales para predecir los precios de las acciones (Hamilton, 1989; Tong, 1990). Tasy (1989) propuso un procedimiento de creación de modelos simple pero ampliamente aplicable para los modelos autoregresivos de umbral, así como una prueba de no linealidad de umbral. Gooijer (1998) consideró la conmutación de régimen en un modelo de media móvil (MA) y utilizó criterios de validación para la selección de modelos auto-emocionantes de umbral autoregresivo (SETAR). Algunos estudios empíricos que comparan diferentes métodos con SETAR encontraron que este método produjo resultados superiores a modelos lineales (por ejemplo, Clements y Smith, 1999; Boero y Marrocu, 2002; Boero, 2003; Firat, 2017).

A finales de la década de 1980, se introdujeron una clase de modelos de inteligencia artificial (IA), como feedforward, backpropagation y modelos de redes neuronales recurrentes, con fines de previsión. Las características distintivas de las redes neuronales artificiales (ANN) son que son basadas en datos, no lineales y autoadaptables, y tienen muy pocas suposiciones apriori. Esto hace que los ANN sean valiosos y atractivos para pronosticar series temporales financieras. Entre los modelos ANN, la red neuronal de avance con una sola capa oculta se ha convertido en la más popular para pronosticar los rendimientos del mercado de valores (Zhang, 2003). Muchos estudios han demostrado que estos modelos producen previsiones más precisas en comparación con los modelos ingenuos y lineales (por ejemplo, Ghiassi et al., 2005; Mostafa, 2010; Qiu et al., 2016; Aras y Kocakoc, 2016).

Además, hay varios modelos de redes neuronales para pronosticar los rendimientos de las acciones. Lu y Wu (2011) utilizaron el modelo de red neuronal del controlador de articulación del modelo cerebeloso (CAMC NN) para pronosticar los índices bursátiles del Nikkei 225 y la Bolsa de Taiwán. Los resultados mostraron que CAMC NN hizo pronósticos más precisos que los modelos de regresión vectorial de soporte y red neuronal de retropropagación (BPNN). (2011) observaron que los modelos ANN clásicos y el perceptrón multicapa (MLP) superaron a los modelos de la clase GARCH para el índice NASDAQ. Lahmiri (2016) empleó redes neuronales de regresión general (GRNN) basadas en el modo de variación (VMD) para cuatro conjuntos de datos económicos y financieros y encontró que los modelos VMD-GRNN superaron al modelo ARIMA y a otros modelos de redes neuronales. La red neuronal polinómica condensada basada en algoritmos genéticos (GA-CPNN) de Nayak y Misra (2018) mejoró la precisión de la previsión de índices bursátiles en comparación con los modelos de red neuronal de función de base radial (RBFNN) y perceptrón y algoritmo genético multicapa (MLP-GA). Zhong y Enke (2019) observaron que técnicas como las redes neuronales profundas que utilizan el análisis de componentes principales (PCA) y las redes neuronales artificiales funcionaban mejor que los modelos tradicionales. Sin embargo, la mayoría de los estudios han encontrado que los modelos ANN tradicionales, así como los modelos ANN combinados con modelos lineales, producen pronósticos más precisos que otros modelos (por ejemplo, Asadi et al., 2010; Wang et al., 2011; Khandelwal et al., 2015; Mallikarjuna et al., 2018).

Recientemente, se han propuesto modelos de dominio de frecuencia, como el análisis espectral, las ondas y las transformaciones de Fourier, para mejorar la precisión de la previsión de series temporales financieras. Una técnica ampliamente utilizada es el análisis de espectro singular (SSA), que es un método no paramétrico robusto sin suposiciones previas sobre los datos (Golyandina et al., 2001; Hassani et al., 2013a). SSA descompone los datos de series temporales en sus componentes y luego reconstruye la serie dejando el componente de ruido aleatorio antes de utilizar la serie reconstruida para pronosticar los puntos futuros de la serie (Hassani, 2007; Ghodsi y Omer, 2014). Dado que la mayoría de los conjuntos de datos de series temporales financieras no presentan patrones puramente lineales ni puramente no lineales, se ha propuesto la combinación de técnicas lineales y no lineales, es decir, técnicas híbridas para modelar estructuras de datos complejas para mejorar la precisión (Asadi et al., 2010; Khashei y Bijari, 2010; Khashei y Bijari, 2012; Khandelwal et al., 2015; Ince y Trafalis, 2017). Khashei y Hajirahimi (2017) compararon modelos lineales y no lineales con modelos híbridos (HM) y concluyeron que los modelos híbridos funcionan mejor que los modelos individuales.

Sólo unos pocos estudios han tenido como objetivo encontrar un método adecuado para pronosticar los rendimientos de las acciones de un grupo de mercados. (2009) evaluaron el rendimiento de los modelos

lineales y no lineales para la previsión de los rendimientos de los activos financieros de los países del G7. Encontraron que los modelos no lineales, como los modelos autoregresivos de umbral (TAR) y autoregresivos de transición suave (STAR), tuvieron un mejor rendimiento que los modelos lineales en el caso de los rendimientos de activos de EE. UU. Y Reino Unido. Mientras tanto, los modelos lineales simples, como los modelos de marcha aleatoria y autoregresivo, eran mejores para los rendimientos de activos franceses, alemanes e italianos. Esto sugiere que ningún modelo único es adecuado para pronosticar los rendimientos de todos los mercados de valores. (2018) comparó el rendimiento de varios métodos de predicción aplicándolos a seis mercados bursátiles y encontró que el método de descomposición en modo empírico Holt-Winters (EMD-HW) proporcionaba pronósticos más precisos que otros modelos.

Aunque existen varias técnicas para pronosticar los rendimientos del mercado de valores, no se puede emplear un solo método uniformemente para los rendimientos de todos los mercados bursátiles. La literatura indica que no hay consenso entre los investigadores sobre las técnicas para pronosticar los rendimientos del mercado de valores. El presente estudio, por lo tanto, tenía como objetivo evaluar diferentes técnicas de predicción , a saber, ARIMA, SETAR, ANN, SSA y HM, que representan lineales, no lineales, inteligencia artificial (IA), dominio de frecuencia y métodos híbridos, respectivamente, aplicados a los mercados bursátiles individuales. Este estudio también examinó la idoneidad de diferentes métodos de predicción para cada categoría de los mercados bursátiles mundiales, a saber, desarrollados, emergentes y fronterizos. Encontrar un único método que pueda producir previsiones óptimas para todos los mercados podría ayudar a los inversores a ahorrar tiempo y recursos y tomar mejores decisiones. Este estudio es principalmente útil para inversores internacionales e inversores institucionales extranjeros que desean minimizar los riesgos y diversificar sus carteras, con el objetivo de maximizar los beneficios. Los objetivos del presente estudio se describen a continuación.

Objetivos

1. Para pronosticar los rendimientos del mercado de valores utilizando métodos lineales, no lineales, de inteligencia artificial, de dominio de frecuencia e híbridos.
2. Encontrar las técnicas de predicción más adecuadas entre las cinco técnicas antes mencionadas para los mercados desarrollados, emergentes y fronterizos.
3. Para comprobar si se puede aplicar una técnica única a todos los mercados para obtener previsiones óptimas.

El resto de este documento se organiza de la siguiente manera. La Sección 2 describe los datos y métodos empleados en el estudio. La Sección 3 presenta los resultados empíricos. Por último, las conclusiones figuran en la sección 4.

CONCLUSIÓN

A lo largo de los años, los mercados bursátiles se han convertido en vías alternativas para obtener fondos excedentarios entre los inversores individuales e institucionales, especialmente después de la globalización y la integración de los mercados financieros mundiales. Dado el riesgo inherente, la incertidumbre y la naturaleza dinámica de los mercados de valores, la previsión precisa de los rendimientos de las acciones puede ayudar a minimizar los riesgos de los inversores. Por lo tanto, las técnicas de previsión pueden ayudar a una mejor toma de decisiones de inversión.

Este estudio examinó los datos diarios de los rendimientos del mercado de valores durante el período comprendido entre el 1 de enero de 2000 y el 30 de diciembre de 2018 para comparar técnicas de previsión (es decir, arima, SETAR, ANN, SSA y HM) que representan métodos lineales, no lineales, de IA, de frecuencia y híbridos. Tomamos los índices bursátiles de 24 mercados bursátiles en tres categorías de mercados (nueve desarrollados, diez emergentes y cinco fronterizos) para encontrar técnicas de previsión adecuadas para cada categoría. Los resultados mostraron que ninguna técnica de previsión única proporcionaba una previsión uniformemente óptima para todos los mercados. Sin embargo, SETAR tuvo un mejor desempeño para diez mercados, ARIMA para siete, HM para cinco, y ANN y SSA para un mercado cada uno. De este modo, las técnicas SETAR y ARIMA pueden considerarse los claros ganadores

en la previsión de rendimientos bursátiles para los mercados desarrollados, emergentes y fronterizos, ya que estos dos métodos proporcionaron previsiones óptimas para diecisiete de los veinticuatro mercados.

TRANSLATED VERSION: FRENCH

Below is a rough translation of the insights presented above. This was done to give a general understanding of the ideas presented in the paper. Please excuse any grammatical mistakes and do not hold the original authors responsible for these mistakes.

VERSION TRADUITE: FRANÇAIS

Voici une traduction approximative des idées présentées ci-dessus. Cela a été fait pour donner une compréhension générale des idées présentées dans le document. Veuillez excuser toutes les erreurs grammaticales et ne pas tenir les auteurs originaux responsables de ces erreurs.

INTRODUCTION

Des études théoriques et empiriques ont montré qu'il existe une relation positive entre les marchés financiers et la croissance économique (p. Ex., Levine, 1997; Rajan et Zingales, 1998; Rousseau et Watchel, 2000; Beck et coll., 2003; Guptha et Rao, 2018). Compte tenu de l'importance des marchés financiers, la prévision des rendements financiers occupe une place primordiale dans la prise de décisions d'investissement. Toutefois, les marchés boursiers se caractérisent par une forte volatilité, dynamisme et complexité (Johnson et coll., 2003; Cristelli, 2014; Wieland, 2015). Les mouvements sur les marchés boursiers sont influencés par plusieurs facteurs, tels que les facteurs macro-économiques, les événements internationaux et le comportement humain. Par conséquent, la prévision des rendements des stocks peut devenir une tâche difficile. La rentabilité des investissements sur les marchés boursiers dépend fortement de la prévisibilité des mouvements d'actions. Si un modèle ou une technique de prévision peut prédire avec précision l'orientation du marché, le risque d'investissement et l'incertitude peuvent être réduits au minimum. Il améliorerait les flux d'investissement sur les marchés boursiers et serait également utile pour les décideurs et les organismes de réglementation dans la prise de décisions appropriées et la prise de mesures correctives.

Il existe deux écoles de pensée distinctes , à savoir l'analyse fondamentale et l'analyse technique , pour prédire les mouvements du cours des actions. Les fundamentalistes prévoient le cours des actions sur la base d'analyses financières d'entreprises ou d'industries. Les analystes techniques, quant à eux, utilisent des données historiques sur les valeurs mobilières et prédissent les prix futurs en supposant que les cours des actions sont déterminés par les forces du marché et que l'histoire tend à se répéter (Levy, 1967). Ces théories ont coexisté pendant plusieurs décennies en tant que stratégies de prise de décision en matière d'investissement. Ces approches ont été contestées dans les années 1960 par la théorie de la marche aléatoire, populairement connue sous le nom d'hypothèse efficace du marché (Fama, 1970), qui propose que les changements futurs du cours des actions ne puissent pas être prédits à partir des variations de prix passées. Certaines études empiriques ont montré la présence d'une « marche aléatoire » dans le cours des actions (p. Ex., Tong et coll., 2014; Konak et Seker, 2014; Erdem et Ulucak, 2016). Toutefois, la plupart des études empiriques ont révélé que le cours des actions est prévisible (Darrat et Zhong, 2000; Lo et mackinlay, 2002; Harrison et Moore, 2012; Owido et coll., 2013; Radikoko, 2014; Said, 2015; Almudhaf, 2018).

Diverses techniques de prévision sont disponibles pour la prévision des séries de temps. Les modèles de moyenne mobile intégrée autorégressive (ARIMA) ont été proposés par Box et Jenkins (1970) pour l'analyse et la prévision des séries météorologiques. Certaines études ont été menées en utilisant des modèles ARIMA pour prévoir les rendements boursiers (Al-Shaib, 2006; Ojo et Olatayo, 2009; Adebiyi et Oluinka, 2014; Mondal et coll., 2014). Pas mal d'études ont révélé que les modèles ARIMA produisaient des prévisions inférieures pour les données des séries de temps financier (Zhang, 2003; Adebiyi et Oluinka,

2014; Khandelwal et coll., 2015). Pour tenir compte des non-lignes résultant des changements de régime dans les économies, certains chercheurs ont utilisé des modèles de commutation du régime Markov et des modèles autorégressifs de seuil (TAR) en assumant des processus stationnaires non ligneux pour prédire le cours des actions (Hamilton, 1989; Tong, 1990). Tasy (1989) a proposé une procédure simple mais largement applicable de construction de modèles pour les modèles autorégressifs de seuil ainsi qu'un test pour la non-ligne de seuil. Gooijer (1998) a considéré le changement de régime dans un modèle de moyenne mobile (MA) et a utilisé des critères de validation pour la sélection autorégressive du modèle autorégressif (SETAR). Certaines études empiriques comparant différentes méthodes à SETAR ont révélé que cette méthode a donné des résultats supérieurs à des modèles linéaires (p. Ex., Clements et Smith, 1999; Boero et Marrocu, 2002; Boero, 2003; Firat, 2017).

À la fin des années 1980, une classe de modèles d'intelligence artificielle (IA), tels que les modèles de feedforward, de backpropagation et de réseau neuronal récurrent, ont été introduits à des fins de prévision. Les caractéristiques distinctives des réseaux neuronaux artificiels (ANN) sont qu'ils sont axés sur les données, non ligneux et auto-adaptatifs, et ils ont très peu d'hypothèses apriori. Cela rend anns précieux et attrayant pour la prévision des séries de temps financier. Parmi les modèles ANN, le réseau neuronal feed-forward avec une seule couche cachée est devenu le plus populaire pour prévoir les rendements boursiers (Zhang, 2003). De nombreuses études ont montré que ces modèles donnent des prévisions plus précises par rapport aux modèles naïfs et linéaires (p. Ex., Ghiassi et coll., 2005; Mostafa, 2010; Qiu et coll., 2016; Aras et Kocakoc, 2016).

En outre, il existe différents modèles de réseau neuronal pour prévoir les rendements des stocks. Lu et Wu (2011) ont utilisé le modèle cerebellar model articulation controller neural network (CAMC NN) pour prévoir les indices boursiers du Nikkei 225 et de la Bourse de Taiwan. Les résultats ont montré que CAMC NN a fait des prévisions plus précises que les modèles de régression vectorielle de soutien et de réseau neuronal de propagation arrière (BPNN). Guresen et coll. (2011) ont observé que les modèles ANN classiques et le perceptron multicouche (MLP) surpassaient les modèles de classe GARCH pour l'indice NASDAQ. Lahmiri (2016) a utilisé des réseaux neuronaux de régression générale basés sur la décomposition du mode de variation (VMD) pour quatre ensembles de données économiques et financières et a constaté que les modèles VMD-GRNN surpassaient le modèle ARIMA et d'autres modèles de réseaux neuronaux. Le réseau neuronal condensé (GA-CPNN) de Nayak et Misra (2018) a amélioré la précision des indices boursiers prévisionnels par rapport aux modèles de réseau neuronal de fonction de base radiale (RBFNN) et de perceptron multicouche et d'algorithme génétique (MLP-GA). Zhong et Enke (2019) ont observé que des techniques telles que les réseaux neuronaux profonds utilisant l'analyse des composants principaux (PCA) et les réseaux neuronaux artificiels ont obtenu de meilleurs résultats que les modèles traditionnels. Toutefois, la plupart des études ont révélé que les modèles ANN traditionnels, ainsi que les modèles ANN combinés à des modèles linéaires, produisent des prévisions plus précises que les autres modèles (p. Ex., Asadi et coll., 2010; Wang et coll., 2011; Khandelwal et coll., 2015; Mallikarjuna et coll., 2018).

Récemment, des modèles de domaine de fréquence, tels que l'analyse spectrale, les ondes et les transformations fourier, ont été proposés pour améliorer l'exactitude des prévisions des séries de temps financier. Une technique largement utilisée est l'analyse singulière du spectre (ASS), qui est une méthode non paramétrique robuste sans hypothèses préalables sur les données (Golyandina et coll., 2001; Hassani et coll., 2013a). SSA décompose les données d'une série de temps dans ses composants, puis reconstruit la série en laissant le composant de bruit aléatoire avant d'utiliser la série reconstruite pour prévoir les points futurs de la série (Hassani, 2007; Ghodsi et Omer, 2014). Étant donné que la plupart des ensembles de données sur les séries de temps financiers ne présentent ni modèles purement linéaires ni modèles purement non linéaires, la combinaison de techniques linéaires et non linéaires, c'est-à-dire hybrides, pour modéliser des structures de données complexes pour une meilleure précision a été proposée (Asadi et coll., 2010; Khashei et Bijari, 2010; Khashei et Bijari, 2012; Khandelwal et coll., 2015; Ince et Trafalis, 2017). Khashei et Hajirahimi (2017) ont comparé les modèles linéaires et non linéaires aux modèles hybrides (HM) et ont conclu que les modèles hybrides sont plus performants que les modèles individuels.

Seules quelques études ont cherché à trouver une méthode appropriée pour prévoir les rendements boursiers d'un groupe de marchés. Guidolin et coll. (2009) ont évalué la performance des modèles linéaires et non linéaires de prévision des rendements des actifs financiers des pays du G7. Ils ont constaté que les modèles non linéaires, tels que les modèles autorégressifs de seuil (TAR) et les modèles autorégressifs de transition en douceur (STAR), ont obtenu de meilleurs résultats que les modèles linéaires dans le cas des rendements des actifs aux États-Unis et au Royaume-Uni. Pendant ce temps, les modèles linéaires simples tels que la marche aléatoire et les modèles autorégressifs étaient meilleurs pour les Français d'actifs allemands, allemands et italiens. Cela donne à penser qu'aucun modèle ne convient pour prévoir les rendements de tous les marchés boursiers. Awajan et coll. (2018) ont comparé la performance de plusieurs méthodes de prévision en les appliquant à six marchés boursiers et ont constaté que la méthode de décomposition empirique du mode Holt-Winters (EMD-HW) fournissait des prévisions plus précises que les autres modèles.

Bien qu'il existe diverses techniques pour prévoir les rendements boursiers, aucune méthode unique ne peut être utilisée uniformément pour les rendements de tous les marchés boursiers. La littérature indique qu'il n'y a pas de consensus parmi les chercheurs sur les techniques de prévision des rendements boursiers. La présente étude visait donc à évaluer différentes techniques de prévision , à savoir les modèles ARIMA, SETAR, ANN, SSA et HM, représentant respectivement des méthodes linéaires, non linéaires, d'intelligence artificielle (IA), de domaine des fréquences et d'hybrides, telles qu'appliquées aux marchés boursiers individuels. Cette étude a également examiné l'adéquation des différentes méthodes de prévision pour chaque catégorie des marchés boursiers mondiaux, à savoir les marchés boursiers développés, émergents et frontaliers. Trouver une méthode unique qui peut produire des prévisions optimales pour tous les marchés pourrait aider les investisseurs à économiser du temps et des ressources et à prendre de meilleures décisions. Cette étude est principalement utile pour les investisseurs internationaux et les investisseurs institutionnels étrangers qui souhaitent minimiser les risques et diversifier leurs portefeuilles, dans le but de maximiser les bénéfices. Les objectifs de la présente étude sont décrits ci-dessous.

Objectifs

1. Prévoir les rendements boursiers à l'aide de méthodes linéaires, non linéaires, d'intelligence artificielle, de domaine des fréquences et d'hybrides.
2. Trouver les techniques de prévision les plus appropriées parmi les cinq techniques mentionnées ci-dessus pour les marchés développés, émergents et frontaliers.
3. Vérifier si une seule technique peut être appliquée à tous les marchés pour obtenir des prévisions optimales.

Le reste de ce document est organisé comme suit. La section 2 décrit les données et les méthodes utilisées dans l'étude. La section 3 présente les résultats empiriques. Enfin, les conclusions sont tirées à l'article 4.

CONCLUSION

Au fil des ans, les marchés boursiers sont devenus d'autres voies pour les fonds excédentaires parmi les investisseurs individuels et institutionnels, en particulier à la suite de la mondialisation et de l'intégration des marchés financiers mondiaux. Compte tenu du risque inhérent, de l'incertitude et de la nature dynamique des marchés boursiers, la prévision précise des rendements des actions peut aider à minimiser les risques pour les investisseurs. Ainsi, les techniques de prévision peuvent aider à une meilleure prise de décision en matière d'investissement.

Cette étude a examiné les données quotidiennes sur les rendements boursiers au cours de la période du 1er janvier 2000 au 30 décembre 2018 afin de comparer les techniques de prévision (c.-à-d. Les modèles ARIMA, SETAR, ANN, SSA et HM) représentant les méthodes linéaires, non linéaires, ia, de fréquence et hybrides. Nous avons pris les indices boursiers de 24 marchés boursiers dans trois catégories de marché (neuf développés, dix émergents et cinq frontières) pour trouver des techniques de prévision appropriées pour chaque catégorie. Les résultats ont montré qu'aucune technique de prévision unique n'offrait des prévisions uniformément optimales pour tous les marchés. Toutefois, SETAR a obtenu de meilleurs résultats pour dix marchés, ARIMA pour sept, HM pour cinq, et ANN et SSA pour un marché chacun. Les

techniques SETAR et ARIMA peuvent ainsi être considérées comme les gagnants évidents dans la prévision des rendements boursiers pour les marchés développés, émergents et frontaliers, car ces deux méthodes ont fourni des prévisions optimales pour dix-sept des vingt-quatre marchés.

TRANSLATED VERSION: GERMAN

Below is a rough translation of the insights presented above. This was done to give a general understanding of the ideas presented in the paper. Please excuse any grammatical mistakes and do not hold the original authors responsible for these mistakes.

ÜBERSETZTE VERSION: DEUTSCH

Hier ist eine ungefähre Übersetzung der oben vorgestellten Ideen. Dies wurde getan, um ein allgemeines Verständnis der in dem Dokument vorgestellten Ideen zu vermitteln. Bitte entschuldigen Sie alle grammatischen Fehler und machen Sie die ursprünglichen Autoren nicht für diese Fehler verantwortlich.

EINLEITUNG

Theoretische und empirische Studien haben gezeigt, daß eine positive Beziehung zwischen Finanzmärkten und Wirtschaftswachstum besteht (z. B. Levine, 1997; Rajan und Zingales, 1998; Rousseau and Watchel, 2000; Beck et al., 2003; Guptha und Rao, 2018). Angesichts der Bedeutung der Finanzmärkte nimmt die Prognose der Finanzrenditen eine herausragende Stellung bei der Entscheidungsfindung bei Investitionen ein. Die Aktienmärkte zeichnen sich jedoch durch hohe Volatilität, Dynamik und Komplexität aus (Johnson et al., 2003; Cristelli, 2014; Wieland, 2015). Die Bewegungen an den Aktienmärkten werden von mehreren Faktoren beeinflusst, wie makroökonomische Faktoren, internationale Ereignisse und menschliches Verhalten. Daher kann die Prognose von Aktienrenditen zu einer herausfordernden Aufgabe werden. Die Rentabilität von Investitionen an den Aktienmärkten hängt stark von der Vorhersehbarkeit von Aktienbewegungen ab. Wenn ein Prognosemodell oder eine Prognosemethode die Richtung des Marktes genau vorhersagen kann, können Investitionsrisiken und Unsicherheiten minimiert werden. Sie würde die Investitionsströme in die Aktienmärkte ansteigen und auch für politische Entscheidungsträger und Regulierungsbehörden nützlich sein, wenn es darum geht, geeignete Entscheidungen zu treffen und Korrekturmaßnahmen zu ergreifen.

Es gibt zwei unterschiedliche Denkschulen – nämlich fundamentale Analysen und technische Analysen – zur Vorhersage von Aktienkursbewegungen. Fundamentalisten prognostizieren Aktienkurse auf der Grundlage von Finanzanalysen von Unternehmen oder Branchen. Technische Analysten verwenden derweil historische Wertpapierdaten und prognostizieren zukünftige Kurse unter der Annahme, dass die Aktienkurse von den Marktkräften bestimmt werden und dass sich die Geschichte tendenziell wiederholt (Levy, 1967). Diese Theorien existierten mehrere Jahrzehnte als Strategien für die Entscheidungsfindung bei Investitionen. Diese Ansätze wurden in den 1960er Jahren durch die zufällige Walk-Theorie in Frage gestellt, die im Volksmund als effiziente Markthypothese bekannt ist (Fama, 1970), die vorschlägt, dass zukünftige Veränderungen der Aktienkurse nicht von früheren Preisänderungen vorhergesagt werden können. Einige empirische Studien haben gezeigt, dass es bei den Aktienkursen einen "zufälligen Spaziergang" gibt (z. B. Tong et al., 2014; Konak und Seker, 2014; Erdem und Ulucak, 2016). Die meisten empirischen Studien haben jedoch ergeben, dass die Aktienkurse vorhersehbar sind (Darrat und Zhong, 2000; Lo und Mackinlay, 2002; Harrison und Moore, 2012; Owido et al., 2013; Radikoko, 2014; Said, 2015; Almudhaf, 2018).

Für die Zeitreihenvorhersage stehen verschiedene Prognosetechniken zur Verfügung. Autoregressive Integrated Moving Average (ARIMA) Modelle wurden von Box und Jenkins (1970) für die Analyse und Prognose von Zeitreihen vorgeschlagen. Einige Studien wurden unter Verwendung von ARIMA-Modellen durchgeführt, um Börsenrenditen vorherzusagen (Al-Shaib, 2006; Ojo und Olatayo, 2009; Adebiyi und

Oluinka, 2014; Mondal et al., 2014). Nicht wenige Studien fanden heraus, dass ARIMA-Modelle schlechtere Prognosen für Finanzzeitreihendaten erstellten (Zhang, 2003; Adebiyi und Oluinka, 2014; Khandelwal et al., 2015). Um die Nichtlinearitäten infolge von Regimewechseln in Volkswirtschaften zu berücksichtigen, haben einige Forscher Markov-Regime-Switching-Modelle und Threshold-Autoregressive (TAR)-Modelle verwendet, bei der nichtlineare stationäre Prozesse zur Vorhersage von Aktienkursen angingen (Hamilton, 1989; Tong, 1990). Tasy (1989) schlug ein einfaches, aber weit verbreitetes Modellbauverfahren für schwellenautoregressive Modelle sowie einen Test für die Nichtlinearität der Schwelle vor. Gooijer (1998) erwog die Regimewechsel in einem gleitenden Durchschnittsmodell (MA) und verwendete Validierungskriterien für die selbstspannende Schwellenautoregressive (SETAR)-Modellauswahl. Einige empirische Studien, die verschiedene Methoden mit SETAR verglichen, ergaben, dass diese Methode zu überlegenen Ergebnissen als lineare Modelle führte (z. B. Clements und Smith, 1999; Boero und Marrocu, 2002; Boero, 2003; Firat, 2017).

In den späten 1980er Jahren wurde eine Klasse von Modellen für künstliche Intelligenz (KI) eingeführt – wie Feedforward, Backpropagation und wiederkehrende neuronale Netzwerkmodelle – zu Prognosezwecken. Die Unterscheidungsmerkmale künstlicher neuronaler Netzwerke (ANN) sind, dass sie datengesteuert, nichtlinear und selbstadaptiv sind und nur sehr wenige apriori Annahmen haben. Dies macht anns wertvoll und attraktiv für die Vorhersage von Finanzzeitreihen. Unter den ANN-Modellen ist das neuronale Feed-Forward-Netzwerk mit einer einzigen versteckten Schicht das beliebteste für die Vorhersage von Börsenrenditen geworden (Zhang, 2003). Viele Studien haben gezeigt, dass diese Modelle genauere Prognosen liefern als naive und lineare Modelle (z. B. Ghiasi et al., 2005; Mostafa, 2010; Qiu et al., 2016; Aras und Kocakoc, 2016).

Darüber hinaus gibt es verschiedene neuronale Netzwerkmodelle für die Vorhersage von Aktienrenditen. Lu und Wu (2011) nutzten das Modell des Kleinhirnmodells Artikulationssteuerungs-Neuralnetzwerk (CAMC NN), um die Börsenindizes des Nikkei 225 und der Taiwan Stock Exchange vorherzusagen. Die Ergebnisse zeigten, dass CAMC NN genauere Prognosen erstellte als Unterstützungsvektorregressions- und BPNN-Modelle (Back-Propagation Neural Network). Guresen et al. (2011) beobachteten, dass klassische ANN-Modelle und Mehrschichtperceptron (MLP) die Modelle der GARCH-Klasse für den NASDAQ-Index übertrafen. Lahmiri (2016) verwendete die Variationsmoduszersetzung (VMD) basierend auf allgemeinen regressionsneuronen Netzwerken (GRNN) für vier wirtschaftliche und finanzielle Datensätze und stellte fest, dass VMD-GRNN-Modelle das ARIMA-Modell und andere neuronale Netzwerkmodelle übertrafen. Nayak und Misras (2018) genetischealgorithmusbasierte simiertes polynomiale neuronales Netzwerk (GA-CPNN) verbesserte die Genauigkeit der Vorhersage von Aktienindizes im Vergleich zu radialen Basisfunktions-Neuralnetzwerkmodellen (RBFNN) und Multilayer-Perzeptron- und genetischen Algorithmusmodellen (MLP-GA). Zhong und Enke (2019) beobachteten, dass Techniken wie tiefe neuronale Netzwerke mit Hauptkomponentenanalyse (PCA) und künstliche neuronale Netzwerke besser abgeschnitten haben als herkömmliche Modelle. Die meisten Studien haben jedoch ergeben, dass herkömmliche ANN-Modelle sowie ANN-Modelle in Kombination mit linearen Modellen genauere Vorhersagen liefern als andere Modelle (z. B. Asadi et al., 2010; Wang et al., 2011; Khandelwal et al., 2015; Mallikarjuna et al., 2018).

Kürzlich wurden Frequenzbereichsmodelle wie Spektralanalyse, Wavelets und Fourier-Transformationen vorgeschlagen, um die Prognosegenauigkeit von Finanzzeitreihen zu verbessern. Eine weit verbreitete Technik ist die Singular Spectrum Analysis (SSA), eine robuste nichtparametrische Methode ohne vorherige Annahmen über die Daten (Golyandina et al., 2001; Hassani et al., 2013a). SSA zerlegt eine Zeitreihendaten in ihre Komponenten und rekonstruiert dann die Reihe, indem sie die zufällige Rauschkomponente verlässt, bevor sie die rekonstruierte Reihe verwendet, um die zukünftigen Punkte in der Reihe vorherzusagen (Hassani, 2007; Ghodsi und Omer, 2014). Da die meisten Datensätze von Finanzzeitreihen weder rein lineare noch rein nichtlineare Muster aufweisen, wurde die Kombination von linearen und nichtlinearen, d. H. Hybriden Techniken zur Modellierung komplexer Datenstrukturen für eine verbesserte Genauigkeit vorgeschlagen (Asadi et al., 2010; Khashei und Bijari, 2010; Khashei und Bijari, 2012; Khandelwal et al., 2015; Ince und Trafalis, 2017). Khashei und Hajirahimi (2017) verglichen lineare

und nichtlineare Modelle mit Hybridmodellen (HM) und kamen zu dem Schluss, dass Hybridmodelle besser abschneiden als einzelne Modelle.

Nur wenige Studien haben darauf abzielen, eine geeignete Methode zur Prognose der Aktienrenditen einer Gruppe von Märkten zu finden. Guidolin et al. (2009) bewerteten die Leistung linearer und nichtlinearer Modelle zur Prognose der finanziellen Vermögensrenditen der G7-Länder. Sie stellten fest, dass nichtlineare Modelle wie Threshold autoregressive (TAR) und Smooth Transition autoregressive (STAR)-Modelle bei US- und britischen Asset-Returns besser abgeschnitten haben als lineare Modelle. In der Zwischenzeit waren einfache lineare Modelle wie zufällige Walk- und autoregressive Modelle besser für französische, deutsche und italienische Asset-Returns. Dies deutet darauf hin, dass kein einziges Modell geeignet ist, die Renditen aller Aktienmärkte vorherzusagen. Awajan et al. (2018) verglichen die Leistung mehrerer Prognosemethoden, indem sie sie auf sechs Aktienmärkte anwendeten, und stellte fest, dass die empirische Moduszerlegung Holt-Winters-Methode (EMD-HW) genauere Prognosen lieferte als andere Modelle.

Obwohl es verschiedene Techniken zur Prognose von Börsenrenditen gibt, kann keine einzige Methode einheitlich für die Renditen aller Aktienmärkte verwendet werden. Die Literatur zeigt, dass es keinen Konsens unter den Forschern über die Techniken zur Vorhersage von Börsenrenditen gibt. Die vorliegende Studie zielte daher darauf ab, verschiedene Prognosetechniken – nämlich ARIMA-, SETAR-, ANN-, SSA- und HM-Modelle – zu bewerten, die lineare, nichtlineare, künstliche Intelligenz (AI), Frequenzdomäne und hybride Methoden darstellen, wie sie auf einzelne Aktienmärkte angewendet werden. Diese Studie untersuchte auch die Eignung verschiedener Prognosemethoden für jede Kategorie der Weltbörsen – nämlich entwickelt, neu entstehend und grenzüberschreitend. Die Suche nach einer einzigen Methode, die optimale Prognosen für alle Märkte erstellen kann, könnte Investoren helfen, Zeit und Ressourcen zu sparen und bessere Entscheidungen zu treffen. Diese Studie ist vor allem für internationale Investoren und ausländische institutionelle Investoren nützlich, die Risiken minimieren und ihre Portfolios diversifizieren möchten, mit dem Ziel, Gewinne zu maximieren. Die Ziele der vorliegenden Studie sind nachstehend aufgeführt.

Ziele

1. Prognose von Börsenrenditen mit linearen, nichtlinearen, künstlichen Intelligenz-, Frequenzdomänen- und Hybridmethoden.
2. Die am besten geeigneten Prognosetechniken unter den fünf oben genannten Techniken für Industrie-, Schwellen- und Grenzmärkte zu finden.
3. Um zu überprüfen, ob eine einzelne Technik auf alle Märkte angewendet werden kann, um optimale Prognosen zu erhalten.

Der Rest dieses Papiers ist wie folgt organisiert. Abschnitt 2 beschreibt die in der Studie verwendeten Daten und Methoden. Abschnitt 3 stellt die empirischen Ergebnisse vor. Schließlich werden die Schlussfolgerungen in Abschnitt 4 dargelegt.

SCHLUSSFOLGERUNG

Im Laufe der Jahre sind die Aktienmärkte zu alternativen Wegen für überschüssige Fonds unter einzelnen und institutionellen Anlegern geworden, insbesondere nach der Globalisierung und der Integration der Weltfinanzmärkte. Angesichts des inhärenten Risikos, der Unsicherheit und der Dynamik der Aktienmärkte kann eine genaue Prognose von Aktienrenditen dazu beitragen, die Risiken der Anleger zu minimieren. Daher können Prognosetechniken bei einer besseren Investitionsentscheidung helfen.

In dieser Studie wurden die täglichen Daten für Börsenrenditen im Zeitraum vom 1. Januar 2000 bis zum 30. Dezember 2018 berücksichtigt, um Prognosetechniken (d. H. ARIMA-, SETAR-, ANN-, SSA- und HM-Modelle) zu vergleichen, die lineare, nichtlineare, KI-, Frequenzdomänen- und Hybridmethoden darstellen. Wir haben die Aktienindizes von 24 Aktienmärkten in drei Marktategorien (neun entwickelte,

zehn aufstrebende und fünf Grenzgänger) aufgenommen, um für jede Kategorie geeignete Prognosetechniken zu finden. Die Ergebnisse zeigten, dass keine einzige Prognosetechnik für alle Märkte eine einheitlich optimale Prognose lieferte. SETAR schnitt jedoch für zehn Märkte besser ab, ARIMA für sieben, HM für fünf und ANN und SSA für jeweils einen Markt. SETAR- und ARIMA-Techniken können daher als die klaren Gewinner bei der Prognose der Börsenrenditen für Industrie-, Schwellen- und Grenzmärkte angesehen werden, da diese beiden Methoden optimale Prognosen für siebzehn der 24 Märkte lieferten.

TRANSLATED VERSION: PORTUGUESE

Below is a rough translation of the insights presented above. This was done to give a general understanding of the ideas presented in the paper. Please excuse any grammatical mistakes and do not hold the original authors responsible for these mistakes.

VERSÃO TRADUZIDA: PORTUGUÊS

Aqui está uma tradução aproximada das ideias acima apresentadas. Isto foi feito para dar uma compreensão geral das ideias apresentadas no documento. Por favor, desculpe todos os erros gramaticais e não responsabilize os autores originais responsáveis por estes erros.

INTRODUÇÃO

Estudos teóricos e empíricos demonstraram que existe uma relação positiva entre os mercados financeiros e o crescimento económico (por exemplo, Levine, 1997; Rajan e Zingales, 1998; Rousseau e Watchel, 2000; Beck et al., 2003; Guptha e Rao, 2018). Dada a importância dos mercados financeiros, a previsão dos retornos financeiros ocupa uma posição primordial na tomada de decisões de investimento. No entanto, os mercados bolsistas caracterizam-se pela elevada volatilidade, dinamismo e complexidade (Johnson et al., 2003; Cristelli, 2014; Wieland, 2015). Os movimentos nos mercados bolsistas são influenciados por vários fatores, tais como fatores macroeconómicos, eventos internacionais e comportamento humano. Assim, a previsão de retornos de stock pode tornar-se uma tarefa desafiadora. A rentabilidade dos investimentos nos mercados bolsistas depende muito da previsibilidade dos movimentos das ações. Se um modelo ou técnica de previsão puder prever com precisão a direção do mercado, o risco de investimento e a incerteza podem ser minimizados. Reforçaria os fluxos de investimento nos mercados bolsistas e seria igualmente útil para os decisores políticos e reguladores na tomada de decisões adequadas e na tomada de medidas corretivas.

Existem duas escolas distintas de pensamento - nomeadamente, análise fundamental e análise técnica - para prever o movimento dos preços das ações. Os fundamentalistas prevêem os preços das ações com base em análises financeiras de empresas ou indústrias. Os analistas técnicos, entretanto, utilizam dados históricos de títulos e prevêem preços futuros no pressuposto de que os preços das ações são determinados pelas forças do mercado e que a história tende a repetir-se (Levy, 1967). Estas teorias coexistiram durante várias décadas como estratégias para a tomada de decisões de investimento. Estas abordagens foram contestadas na década de 1960 pela teoria da caminhada aleatória, popularmente conhecida como a hipótese de mercado eficiente (Fama, 1970), que propõe que as futuras alterações nos preços das ações não possam ser previstas a partir de alterações de preços passadas. Alguns estudos empíricos mostraram a presença de "caminhada aleatória" nos preços das ações (por exemplo, Tong et al., 2014; Konak e Seker, 2014; Erdem e Ulucak, 2016). No entanto, a maioria dos estudos empíricos descobriu que os preços das ações são previsíveis (Darrat e Zhong, 2000; Lo e Mackinlay, 2002; Harrison e Moore, 2012; Owido et al., 2013; Radikoko, 2014; Said, 2015; Almudhaf, 2018).

Várias técnicas de previsão estão disponíveis para a previsão de séries de tempo. Os modelos autoregressivos integrados da média móvel (ARIMA) foram propostos pela Box e pela Jenkins (1970) para análise e previsão de séries de tempo. Alguns estudos foram realizados utilizando modelos ARIMA

para prever a rentabilidade do mercado de ações (Al-Shaib, 2006; Ojo e Olatayo, 2009; Adebiyi e Oluinka, 2014; Mondal et al., 2014). Alguns estudos constataram que os modelos ARIMA produziram previsões inferiores para dados de séries de tempo financeiros (Zhang, 2003; Adebiyi e Oluinka, 2014; Khandelwal et al., 2015). Para responder às não-linearidades resultantes de alterações de regime nas economias, alguns investigadores utilizaram modelos de comutação de regime markov e modelos autoregressivos de limiar (TAR) assumindo processos estacionários não lineares para prever os preços das ações (Hamilton, 1989; Tong, 1990). A Tasy (1989) propôs um procedimento simples, mas amplamente aplicável, de construção de modelos para modelos autoregressivos limiares, bem como um teste para a não-linearidade dos limiares. Gooijer (1998) considerou a mudança de regime num modelo médio móvel (MA) e utilizou critérios de validação para a seleção autoregressiva autoregressiva autoregressiva (SETAR) autoregressiva. Alguns estudos empíricos que compararam diferentes métodos com o SETAR constataram que este método produziu resultados superiores a modelos lineares (por exemplo, Clements e Smith, 1999; Boero e Marrocó, 2002; Boero, 2003; Firat, 2017).

No final da década de 1980, uma classe de modelos de inteligência artificial (IA) - tais como feedforward, backpropagation e modelos de rede neural recorrente - foram introduzidos para fins de previsão. As características distintivas das redes neurais artificiais (ANN) são que são orientadas por dados, não lineares e auto-adaptáveis, e têm muito poucas suposições apriori. Isto torna as anns valiosas e atraentes para a previsão de séries de tempo financeiro. Entre os modelos ANN, a rede neural de feed-forward com uma única camada escondida tornou-se a mais popular para a previsão de retornos do mercado de ações (Zhang, 2003). Muitos estudos demonstraram que estes modelos produzem previsões mais precisas em comparação com modelos ingênuos e lineares (por exemplo, Ghiassi et al., 2005; Mostafa, 2010; Qiu et al., 2016; Aras e Kocakoc, 2016).

Além disso, existem vários modelos de rede neural para a previsão de retornos de stock. Lu e Wu (2011) usaram o modelo cerebelar da rede neural do controlador de articulação (CAMC NN) para prever os índices da bolsa de valores do Nikkei 225 e da Bolsa de Valores de Taiwan. Os resultados mostraram que o CAMC NN fez previsões mais precisas do que os modelos de regressão vetorial de suporte e rede neural de propagação de back-propagação (BPNN). Guresen et al. (2011) observou que os modelos clássicos de ANN e perceptron multicamadas (MLP) superaram os modelos da classe GARCH para o índice NASDAQ. Lahmiri (2016) utilizou redes neurais de regressão geral (VMD) baseadas em variações para quatro conjuntos de dados económicos e financeiros e descobriu que os modelos VMD-GRNN superaram o modelo ARIMA e outros modelos de rede neural. A rede neural polinomial condensada (GA-CPNN) de Nayak e Misra (2018) melhorou a precisão dos índices de prospeção em comparação com a rede neural da função de base radial (RBFNN) e os modelos de pertron e algoritmo genético multicamadas (MLP-GA). Zhong e Enke (2019) observaram que técnicas como redes neuronais profundas usando a análise principal de componentes (APC) e redes neurais artificiais tiveram um desempenho melhor do que os modelos tradicionais. No entanto, a maioria dos estudos descobriu que os modelos tradicionais de ANN, bem como os modelos ANN combinados com modelos lineares, produzem previsões mais precisas do que outros modelos (por exemplo, Asadi et al., 2010; Wang et al., 2011; Khandelwal et al., 2015; Mallikarjuna et al., 2018).

Recentemente, foram propostos modelos de domínio de frequência, como a análise espectral, as ondas e as transformações de Fourier, para melhorar a precisão das previsões das séries temporais financeiras. Uma técnica amplamente utilizada é a análise do espectro singular (SSA), que é um método robusto não paramétrico sem pressupostos prévios sobre os dados (Golyandina et al., 2001; Hassani et al., 2013a). A SSA decompõe os dados da série de tempo nos seus componentes e, em seguida, reconstrói a série deixando o componente de ruído aleatório antes de utilizar a série reconstruída para prever os pontos futuros da série (Hassani, 2007; Ghodsi e Omer, 2014). Uma vez que a maioria dos conjuntos de dados de séries de tempo financeiro não apresentam padrões puramente lineares nem puramente não lineares, a combinação de técnicas lineares e não lineares, ou seja, técnicas híbridas para modelar estruturas de dados complexas para uma maior precisão foi proposta (Asadi et al., 2010; Khashei e Bijari, 2010; Khashei e Bijari, 2012; Khandelwal et al., 2015; Ince e Trafalis, 2017). Khashei e

Hajirahimi (2017) compararam os modelos lineares e não lineares com os modelos híbridos (HM) e concluíram que os modelos híbridos têm um desempenho melhor do que os modelos individuais.

Apenas alguns estudos visaram encontrar um método adequado para a previsão da rentabilidade das ações de um grupo de mercados. Guidolin et al. (2009) avaliou o desempenho de modelos lineares e não lineares para a previsão dos retornos de ativos financeiros dos países do G7. Descobriram que os modelos não lineares, tais como os modelos autoregressivos de limiar (TAR) e os modelos autoregressivos de transição suave (STAR), apresentaram melhores resultados do que os modelos lineares no caso dos retornos de ativos dos EUA e do Reino Unido. Enquanto isso, modelos lineares simples, como caminhada aleatória e modelos autoregressivos eram melhores para retornos de ativos franceses, alemães e italianos. Isto sugere que nenhum modelo único é adequado para prever os retornos de todos os mercados bolsistas. Awajan et al. (2018) comparou o desempenho de vários métodos de previsão aplicando-os a seis bolsas de valores e descobriu que o método de decomposição empírica Holt-Winters (EMD-HW) forneceu previsões mais precisas do que outros modelos.

Embora existam várias técnicas para prever a rentabilidade das bolsas, nenhum método único pode ser utilizado uniformemente para os retornos de todos os mercados bolsistas. A literatura indica que não há consenso entre os investigadores sobre as técnicas de previsão dos retornos do mercado bolsista. O presente estudo visou, portanto, avaliar diferentes técnicas de previsão - nomeadamente, ARIMA, SETAR, ANN, SSA e HM, representando modelos lineares, não lineares, de inteligência artificial (IA), domínio de frequência e métodos híbridos, respectivamente , aplicados aos mercados bolsistas individuais. Este estudo analisou igualmente a adequação de diferentes métodos de previsão para cada categoria dos mercados bolsistas mundiais , nomeadamente, desenvolvidos, emergentes e fronteiriços. Encontrar um único método que possa produzir previsões ótimas para todos os mercados poderia ajudar os investidores a poupar tempo e recursos e a tomar melhores decisões. Este estudo é principalmente útil para investidores internacionais e investidores institucionais estrangeiros que desejam minimizar riscos e diversificar as suas carteiras, com o objetivo de maximizar os lucros. Os objetivos do presente estudo são descritos abaixo.

Objetivos

1. Para prever retornos do mercado de ações usando métodos lineares, não lineares, de inteligência artificial, de frequência e híbridos.
2. Encontrar as técnicas de previsão mais adequadas entre as cinco técnicas acima mencionadas para os mercados desenvolvidos, emergentes e fronteiriços.
3. Para verificar se uma única técnica pode ser aplicada a todos os mercados para obter previsões ótimas.

O resto deste trabalho é organizado da seguinte forma. A secção 2 descreve os dados e métodos utilizados no estudo. A secção 3 apresenta os resultados empíricos. Por último, as conclusões são dadas na secção 4.

CONCLUSÃO

Ao longo dos anos, os mercados bolsistas tornaram-se caminhos alternativos para os fundos excedentários entre investidores individuais e institucionais, especialmente após a globalização e a integração dos mercados financeiros mundiais. Dado o risco inerente, a incerteza e a natureza dinâmica dos mercados bolsistas, a previsão precisa da rentabilidade das ações pode ajudar a minimizar os riscos dos investidores. Assim, as técnicas de previsão podem ajudar a uma melhor tomada de decisão de investimento.

Este estudo considerou dados diários para retornos do mercado de ações durante o período de 1 de janeiro de 2000 a 30 de dezembro de 2018 para comparar técnicas de previsão (isto é, ARIMA, SETAR, ANN, SSA e HM) representando métodos lineares, naronline, IA, domínio de frequência e métodos

híbridos. Tocámos os índices de ações de 24 bolsas em três categorias de mercado (nove desenvolvidas, dez emergentes e cinco fronteiras) para encontrar técnicas de previsão adequadas para cada categoria. Os resultados revelaram que nenhuma técnica de previsão única forneceu uma previsão uniformemente ótima para todos os mercados. No entanto, a SETAR teve um melhor desempenho em dez mercados, ARIMA para sete, HM para cinco, e ANN e SSA para um mercado cada. As técnicas SETAR e ARIMA podem, assim, ser consideradas os claros vencedores na previsão dos retornos do mercado bolsista para os mercados desenvolvidos, emergentes e fronteiriços, uma vez que estes dois métodos forneceram previsões ótimas para dezassete dos vinte e quatro mercados.