

## Sorte ou Técnica? Um Estudo sobre o Desempenho do Mercado de Ações à Luz de Diferentes Técnicas de Previsão

## Luck or Technique? A Study on the Performance of the Stock Market in the Light of Different Forecasting Techniques

Ahmed Sameer El Khatib

Fundação Escola de Comércio Álvares Penteado - FECAP - Brasil  
ahmed.khatib@fecap.br  
ORCID: 000-0002-0764-8622

Submetido em 01/12/2020; Aprovado em 31/03/2021.

### Resumo

**Objetivo:** Examinar o desempenho preditivo de modelos lineares, não lineares, de inteligência artificial, domínio de frequência e híbridos para encontrar um modelo apropriado de previsão do retorno das ações de mercados desenvolvidos, emergentes e de fronteira. **Metodologia:** Foram considerados os retornos diários do mercado de ações de índices selecionados de mercados desenvolvidos, emergentes e de fronteira, de 24 países, para o período de 2000–2019, para avaliar o desempenho preditivo de cinco modelos existentes. **Principais Resultados:** Os resultados indicaram que nenhum dos cinco modelos poderia ser aplicado uniformemente a todos os mercados. No entanto, os modelos lineares e não lineares tradicionais superaram a inteligência artificial e os modelos no domínio da frequência ao fornecer previsões mais precisas. **Contribuições acadêmicas e práticas:** Este estudo é útil principalmente para investidores internacionais e investidores institucionais estrangeiros que desejam minimizar riscos e diversificar suas carteiras, com o objetivo de maximizar lucros.

**Palavras-Chave:** Retorno das ações; Técnicas de Previsão; Mercados Financeiros.

### Abstract

**Purpose:** to examine the predictive performance of linear, non-linear, artificial intelligence, frequency domain and hybrid models to find an appropriate model for predicting the return on shares in developed, emerging and frontier markets. **Methodology:** the daily stock market returns of selected indices from developed, emerging and frontier markets in 24 countries for the period 2000–2019 were considered to assess the predictive performance of five existing models. **Main Findings:** the results indicated that none of the five models could be applied uniformly to all markets. However, traditional linear and non-linear models have outperformed artificial intelligence and models in the frequency domain by providing more accurate predictions. **Academic and practical contributions:** this study is particularly useful for international investors and foreign institutional investors who wish to minimize risks and diversify their portfolios, with the aim of maximizing profits.

**Keywords:** Stock Returns; Forecasting Techniques; Financial Markets.

### 1. Introdução

Estudos precedentes, teóricos e empíricos, evidenciaram que existe uma relação positiva entre os mercados financeiros e o crescimento econômico (e.g., Levine, 1997; Rajan & Zingales, 1998; Rousseau & Watchel, 2000; Beck & Levine, 2003; Guptha & Rao, 2018). Dada à importância dos mercados financeiros, a previsão de retornos das ações ocupa uma posição de destaque na tomada de decisão sobre investimentos. No entanto, os mercados de ações são caracterizados por alta volatilidade (causada por crises financeiras internacionais, locais ou Pandemias, como no recente caso da COVID-19), dinamismo e complexidade (Johnson, Jefferies & Hui, 2003; Cristelli, 2014; Wieland, 2015). Os movimentos nas bolsas de valores são influenciados por vários fatores, como fatores macroeconômicos, eventos internacionais e comportamento humano. Portanto, prever o retorno do preço das ações pode se tornar uma tarefa desafiadora. A lucratividade dos investimentos nas bolsas de valores depende muito da previsibilidade dos movimentos das ações. Caso um modelo ou técnica de previsão possa

prever com precisão a direção do mercado, o risco e a incerteza do investimento poderão ser minimizados por conta da ferramenta e não por um golpe de sorte. Melhorar os fluxos de investimento no mercado de ações também pode ser útil para formuladores de políticas e reguladores na tomada de decisões apropriadas, sejam elas preventivas ou corretivas.

Embora existam várias técnicas para prever retornos do mercado de ações, nenhum método único pode ser empregado uniformemente para os retornos de todos os mercados e pode-se afirmar que não existe previsibilidade com base do fator sorte. A literatura indica que não há consenso entre os pesquisadores sobre as técnicas de previsão de retorno do mercado de ações. O presente estudo, portanto, teve como objetivo avaliar diferentes técnicas de previsão, a saber: modelos ARIMA, SETAR, ANN, SSA e HM, representando inteligência linear, não linear, inteligência artificial (IA), domínio da frequência e métodos híbridos, respectivamente, aplicando-os a mercados de ações individuais. Este estudo também examinou a adequação de diferentes métodos de previsão para cada categoria dos mercados de ações mundiais – a saber, desenvolvidos, emergentes e de fronteira. Encontrar um método único que possa produzir previsões ideais para todos os mercados pode ajudar os investidores a economizar tempo e recursos e tomar melhores decisões. Este estudo é útil, principalmente, para investidores internacionais e investidores institucionais estrangeiros que desejam minimizar riscos e diversificar suas carteiras, com o objetivo de maximizar lucros. Dessa forma, os objetivos do presente estudo, que serão alcançados ao longo das próximas seções, são: **1** – prever retornos do mercado de ações usando inteligência linear, não linear, artificial, domínio da frequência e métodos híbridos; **2** – encontrar as técnicas de previsão mais apropriadas entre as cinco técnicas exploradas para mercados desenvolvidos, emergentes e de fronteira; e **3** – Verificar se uma única técnica pode ser aplicada a todos os mercados (desenvolvidos, emergentes e de fronteira) para obter previsões ideais.

Existem duas escolas de pensamento distintas para avaliação do mercado de ações: a análise fundamentalista e a análise técnica. Os fundamentalistas preveem os preços das ações com base em análises financeiras de empresas ou indústrias. Do outro lado da esteira, os analistas técnicos usam dados históricos de títulos e preveem preços futuros com base no pressuposto de que os preços das ações são determinados pelas forças do mercado e que a história tende a se repetir (Levy, 1967). Essas teorias coexistiram por várias décadas como estratégias para a tomada de decisões de investimento. Essas abordagens foram desafiadas na década de 1960 pela Teoria da Caminhada Aleatória, popularmente conhecida como Hipótese do Mercado Eficiente (Fama, 1970), que propõe que mudanças futuras nos preços das ações não podem ser previstas a partir de mudanças passadas nos preços. Alguns estudos empíricos mostraram a presença do chamado "passeio aleatório" nos preços das ações (p.e., Tong, Li & Benkato, 2014; Konak & Seker, 2014; Erdem & Ulucak, 2016). No entanto, a maioria dos estudos empíricos descobriu que os preços das ações são previsíveis (Darrat & Zhong, 2000; Lo & MacKinlay, 2002; Harrison & Moore, 2012; Owido, Onyuma & Owuor, 2013; Radikoko, 2014; Said, 2015; Almudhaf, 2018).

Várias técnicas de previsibilidade estão disponíveis para previsão de séries temporais. Os Modelos de Média Móvel Integrada Autorregressiva (ARIMA) foram propostos por Box e Jenkins (1970) para análise e previsão de séries temporais. Alguns estudos foram realizados empregando modelos ARIMA para prever retornos do mercado de ações (Al-Shaib, 2006; Ojo & Olatayo, 2009; Adebisi & Oluinka, 2014; Mondal, Shit & Goswami, 2014). Poucos trabalhos descobriram que os modelos ARIMA produziam previsões inferiores para dados de séries temporais financeiras (Zhang, 2003; Adebisi & Oluinka, 2014; Khandelwal & Adhikari, 2015). Para explicar as não linearidades resultantes de mudanças de regime nas economias, alguns pesquisadores usaram Modelos de Série Temporal com Mudança de Regime de Markov (*Markov Switching Models*) e Modelo Autorregressivo com Limiar (TAR), assumindo processos estacionários não lineares para prever os preços das ações (Hamilton, 1989; Tong, 1990).

Tasy (1989) propôs um procedimento de construção de modelo simples, mas amplamente aplicável, para Modelos Autorregressivos com Limiar, bem como um teste para não linearidade de limiar. Gooijer (1998) considerou a troca de regime em um modelo de Média Móvel (MA) e usou critérios de validação para a seleção do Modelo SETAR (*Self-Exciting Threshold AutoRegressive*). Alguns estudos empíricos comparando métodos diferentes com o SETAR descobriram que esse método produzia resultados superiores aos modelos lineares (e.g., Clements & Smith, 1999; Boero & Marrocu, 2002; Boero, 2003; Firat, 2017).

No final dos anos 80, uma classe de modelos de Inteligência Artificial (IA), como Rede *Feedfor-*

*ward*, *Backpropagation* e modelos de redes neurais recorrentes, foram introduzidos para fins de previsão no mercado de ações. As características distintivas das Redes Neurais Artificiais (RNA) são que elas são orientadas por dados não lineares e autoadaptáveis, além de possuírem poucas premissas a priori. Isso torna as RNA valiosas e atraentes para a previsão de séries temporais financeiras. Entre os modelos de RNA, a rede neural *Feedforward* com uma única camada oculta se tornou a mais popular para prever retornos do mercado de ações (Zhang, 2003). Muitos estudos mostraram que esses modelos produzem previsões mais precisas em comparação com modelos ingênuos e lineares (e.g., Ghiassi et al., 2005; Mostafa, 2010; Qosta et al., 2016; Aras & Kocakoc, 2016).

Além disso, existem diversos modelos de redes neurais para prever retornos do mercado de ações. Lu e Wu (2011) usaram o modelo de rede neural do Controlador de Articulação do Modelo Cerebelar (CAMC NN) para prever os índices de mercado de ações do Nikkei 225 e da Bolsa de Valores de Taiwan. Os resultados mostraram que o CAMC NN produziu previsões mais precisas do que os modelos de regressão vetorial e Rede Neural de Propagação Traseira (BPNN). Guresen, Kayakutlu e Daim (2011) observaram que os modelos clássicos de RNA e a percepção de multicamadas (MLP) superaram os modelos da classe GARCH para o índice NASDAQ. Lahmiri (2016) empregou Redes Neurais de Regressão Geral (GRNN) baseadas em Decomposição de Modo Variacional (VMD) para quatro conjuntos de dados econômicos e financeiros e descobriu que os modelos VMD-GRNN superaram o modelo ARIMA e outros modelos de redes neurais. A Rede Neural Polinomial Condensada baseada em algoritmo genético de Nayak e Misra (2018) (GA-CPNN) melhorou a precisão dos índices de previsão do preço de ações quando comparados aos modelos de Rede Neural de Função de Base Radial (RBFNN), *Perceptron* Multicamada e Algoritmo Genético (MLP-GA). Zhong e Enke (2019) observaram que técnicas como redes neurais profundas usando Análise de Componentes Principais ou *Principal Component Analysis* (PCA) 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 RNA, bem como os modelos de RNA combinados com modelos lineares, produzem previsões mais precisas do que outros modelos (p.e., Asadi, Tavakoli & Hejazi, 2010; Wang, Wang, Zhang & Guo, 2011; Khandelwal & Adhikari, 2015; Mallikarjuna, Guptha & Rao, 2017).

Recentemente, Modelos no Domínio da Frequência, como Análise Espectral, *Wavelets* e Transformadas de *Fourier*, foram propostos para melhorar a precisão da previsão de séries temporais financeiras. Uma técnica amplamente utilizada é a Análise de Espectro Singular ou *Singular Spectrum Analysis* (SSA), que é um método não paramétrico robusto, sem suposições prévias sobre os dados (Golyandina, Nekrutkin & Zhigljavsky, 2001; Hassani, Soofi & Zhigljavsky, 2013a). O SSA decompõe os dados da série temporal em seus componentes e depois reconstrói a série deixando o componente de ruído aleatório antes de usar a série reconstruída para prever os pontos futuros da série (Hassani, 2007; Ghodsi & Omer, 2014). Como a maioria dos conjuntos de dados de séries temporais financeiras não exhibe padrões puramente lineares nem puramente não lineares, a combinação de técnicas lineares e não lineares, isto é, técnicas híbridas para modelar estruturas de dados complexas para maior precisão, foi proposta (Asadi et al., 2010; Khashei & Bijari, 2010; Khashei & Bijari, 2012; Khandelwal & Adhikari, 2015; Ince & Trafalis, 2017). Khashei e Hajirahimi (2017) compararam modelos lineares e não lineares com Modelos Híbridos (HM) e concluíram que os modelos híbridos apresentam desempenho melhor que os modelos individuais.

Apenas alguns estudos têm procurado encontrar um método adequado para prever o retorno das ações de um grupo de mercados. Guidolin, Hyde, McMillan e Ono (2009) avaliaram o desempenho de modelos lineares e não lineares para prever o retorno de ativos financeiros dos países do G7. Eles descobriram que os modelos não lineares, como os TAR e STAR, tiveram um desempenho melhor que os modelos lineares no caso de retorno de ativos nos EUA e no Reino Unido. Enquanto isso, modelos lineares simples eram melhores para retornos de ativos nos mercados francês, alemão e italiano. Isso sugere que nenhum modelo é adequado para prever os retornos de todos os mercados de ações. Awan et al. (2018) compararam o desempenho de vários métodos de previsão aplicando-os a seis bolsas de valores e descobriram que o método empírico de decomposição do Método de *Holt-Winters* (EMD-HW) forneceu previsões mais precisas do que outros modelos.

## 2. Dados e metodologia

De acordo com os objetivos deste estudo, consideramos três tipos de mercados, baseados na classificação do *Morgan Stanley Capital International* (MSCI, 2018): desenvolvidos, emergentes e de

fronteira. Os índices de mercado adotados para a categoria desenvolvida são Austrália (ASX 200), Canadá (TSX Composite), França (CAC 40), Alemanha (DAX), Japão (NIKKEI 225), Coréia do Sul (KOSPI), Suíça (SMI), Reino Unido (FTSE 100) e Estados Unidos (S&P 500). Os mercados emergentes são Brasil (BOVE-SPA), China (SSEC), Egito (EGX 30), Índia (SENSEX), Indonésia (IDX), México (BMV IPC), Rússia (MOEX), África do Sul (JSE 40), Tailândia (SET) e Turquia (BIST 100). Por fim, os da categoria fronteira são Argentina (S&P Merval), Estônia (TSEG), Quênia (NSE 20), Sri Lanka (CSE AS) e Tunísia (TUNINDEX). Os preços diários de fechamento desses índices, para o período de 1º de janeiro de 2000 a 31 de dezembro de 2019, foram obtidos no site [www.investing.com](http://www.investing.com).

Os retornos dos ativos ( $R_t$ ) foram calculados a partir dos preços de fechamento de todos os índices, usando a fórmula apresentada na Equação 1 a seguir:

$$R_t = \frac{(P_t - P_{t-1})}{P_{t-1}} * 100 \quad (1)$$

Onde,  $P_t$  é o preço do ativo no período atual e  $P_{t-1}$  é o preço de um ativo no período anterior.

### 2.1. Média móvel integrada autorregressiva (ARIMA)

Propostos por George Box e Gwilym Jenkins em 1970, os modelos ARIMA estão entre os modelos lineares mais populares. Nos modelos ARIMA, o valor futuro de uma variável é obtido através de uma função linear de algumas observações anteriores da variável e de alguns erros aleatórios. O processo que gera a série temporal é apresentado na Equação 2 a seguir:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2)$$

Onde  $y_t$  é a variável que será explicada no tempo  $t$ ;  $c$  é a constante ou o intercepto;  $\phi_i$  ( $i = 1, 2, \dots, p$ ) e  $\theta_j$  ( $j = 1, 2, \dots, q$ ) são os parâmetros do modelo;  $p$  e  $q$  são números inteiros e são frequentemente referidos como ordens AR e MA do modelo, respectivamente; e  $\varepsilon_t$  é o termo do erro. O pressuposto relativo aos erros aleatórios  $\varepsilon_t$  é que eles são distribuídos de forma independente e idêntica com um zero médio e uma variação constante de  $\sigma^2$ . Esse modelo envolve um processo iterativo de três etapas de identificação, estimativa e verificação de diagnóstico.

A etapa de identificação envolve a especificação de um modelo experimental, decidindo a ordem dos termos de AR ( $p$ ) e MA ( $q$ ). Depois que um modelo experimental é especificado, os parâmetros do modelo devem ser estimados, de modo que a medida geral de erros seja minimizada, o que geralmente é feito com um procedimento de otimização não linear.

Após a estimativa dos parâmetros, deve-se verificar o diagnóstico da adequação do modelo, o que envolve testar se as suposições do modelo sobre os erros  $\varepsilon_t$  são atendidas. Se o modelo for adequado, pode-se proceder à previsão; caso contrário, um novo modelo experimental deve ser identificado após a estimativa do parâmetro e a verificação do modelo. Esse processo com três etapas deve ser repetido até que um modelo satisfatório seja selecionado para prever os dados.

### 2.2. Self-Exciting Threshold Autoregressive (SETAR)

O modelo SETAR, desenvolvido por Tong (1983), é um tipo de modelo autorregressivo que pode ser aplicado aos dados de séries temporais. Esse modelo tem mais flexibilidade nos parâmetros que apresentam comportamento de mudança de regime (Watier & Richardson, 1995). A alternância de regime nesse modelo é baseada na autodinâmica da variável dependente. Em outras palavras, o valor limite no modelo SETAR está relacionado à variável endógena, enquanto no Modelo TAR está relacionado a uma variável exógena. Esse modelo assume um processo autorregressivo diferente, de acordo com valores limite específicos. Os modelos SETAR têm a vantagem de capturar um fenômeno não linear comumente observado que não pode ser capturado por modelos lineares como suavização exponencial e modelos ARIMA. Um modelo de autorregressão de limite pode ser transformado em um modelo SETAR se a variável de limite for tomada como um valor atrasado da própria série temporal. O modelo SETAR com dois regimes está na Equação 3 a seguir:

$$y_t = \begin{cases} \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \varepsilon_t & \text{if } y_{t-d} \leq \tau \\ \beta_0 + \sum_{i=1}^p \beta_i y_{t-i} + \varepsilon_t & \text{if } y_{t-d} > \tau \end{cases} \quad (3)$$

Onde  $\alpha_i$  e  $\beta_i$  são coeficientes autorregressivos,  $p$  é a ordem do modelo SETAR,  $d$  é o parâmetro de atraso e  $y_{t-d}$  é a variável de limite,  $\varepsilon_t$  é uma série de variáveis aleatórias independentes e identicamente distribuídos com média 0 e variação  $\sigma^2\varepsilon$ .  $\tau$  é o valor do limiar e, se o valor de  $\tau$  for conhecido, as observações podem ser separadas com base em seu valor em comparação com o limiar, ou seja, se  $y_{t-d}$  está abaixo ou acima do limiar. Então, usando o método dos mínimos quadrados ordinários, o modelo de RA é estimado (Ismail & Isa, 2006). O valor limite deve ser determinado juntamente com outros parâmetros do modelo SETAR, pois o valor limite é desconhecido em geral.

### 2.3. Redes Neurais Artificiais (RNA)

As redes neurais artificiais são uma das estruturas de computação flexíveis que podem ser usadas para modelar uma ampla variedade de dados não lineares. As principais vantagens dos modelos de RNA são que eles são aproximadores orientados a dados e universais, que podem aproximar uma grande classe de funções com grande precisão. Esse processo de criação de modelo não exige nenhuma suposição anterior sobre o formato do modelo, pois as características dos dados determinam o modelo de rede. Uma rede neural *feedforward* com uma única camada oculta é um dos métodos mais amplamente utilizados para prever os dados de séries temporais (Zhang, 2003). A estrutura do modelo é definida por uma rede de três camadas de unidades de processamento simples conectadas por links acíclicos. A representação matemática da relação entre a saída  $y_t$  e as entradas  $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$  pode ser definida conforme a Equação 4 a seguir:

$$y_t = w_0 + \sum_{j=1}^q w_{j,g}(w_{o,j} + \sum_{i=1}^p w_{ij} \cdot y_{t-1}) + \varepsilon_t \quad (4)$$

Onde  $w_j$  ( $j = 0, 1, 2, \dots, q$ ) e  $w_{ij}$  ( $i = 0, 1, 2, \dots, p; j = 0, 1, 2, \dots, q$ ) são os pesos de conexão ou os parâmetros de modelo,  $p$  é o número de nós de entrada e  $q$  é o número de nós ocultos. A função de transferência da camada oculta é dada pela função logística apresentada na Equação 5 a seguir:

$$Sig(x) = \frac{1}{1 + \exp(-x)} \quad (5)$$

Portanto, o modelo de RNA na equação 4 executa o mapeamento funcional não linear de observações passadas  $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$  para o valor futuro  $y_t$ , isto é,

$$y_t = f(y_{t-1}, \dots, y_{t-p}, w) + \varepsilon_t \quad (6)$$

Onde  $f$  é uma função determinada pela estrutura da rede e pelos pesos de conexão, e  $w$  é um vetor de todos os parâmetros. Assim, esse modelo de rede neural é semelhante a um modelo autorregressivo com funcionalidade não linear. A escolha do valor de  $q$  depende dos dados, pois não existe um procedimento padrão para determinar esse parâmetro específico. Outra tarefa vital da modelagem de RNA é a escolha da dimensão do vetor de entrada e o número de observações atrasadas,  $p$ . Este talvez seja o parâmetro mais crucial a ser estimado em um modelo de rede neural artificial, pois a determinação da estrutura de autocorrelação não linear da série temporal depende desse parâmetro. No entanto, não existe uma regra geral que possa ser seguida para selecionar o valor de  $p$ .

Portanto, frequentemente são realizados ensaios para selecionar um valor ideal de  $p$  e  $q$ . Após especificar a estrutura da rede com os parâmetros  $p$  e  $q$ , está pronto para treinamento. Isso é feito com algoritmos de otimização não linear eficientes, como algoritmos de descida de gradiente e algoritmos de gradiente conjugado, além do algoritmo básico de treinamento de retropropagação (Hung & Adeli, 1993). Nas RNAs, as funções de ativação mais usadas são as funções sigmóides. Recentemente, no aprendizado profundo, várias outras funções foram sugeridas como alternativas à função sigmoide, como a função tangente hiperbólica (*tanh*), unidades lineares retificadas (*ReLU*), *softmax* e gaussiana. Essas funções são fornecidas abaixo. A função tangente hiperbólica (*tanh*) é uma das alternativas à função sigmoide. Pode ser definida como:

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (7)$$

Essa função é semelhante à função sigmoide, no entanto, compacta o número de valor real para um intervalo entre - 1 e 1; ou seja,  $\tanh(x) \in (-1, 1)$ . Unidades lineares retificadas (ReLU) são definidas como:

$$f(x) = \max(0, x) \quad (8)$$

Onde  $x$  é a entrada para um neurônio. Em outras palavras, a ativação é simplesmente configurada no limite de zero. O intervalo da *ReLU* está entre 0 e  $\infty$ . A função *softmax*, também chamada de função exponencial normalizada, é uma generalização da função logística que 'comprime' um vetor  $K$ -dimensional  $Z$  de valores reais aleatórios para um vetor  $K$ -dimensional  $\sigma(z)$  de valores reais no intervalo  $[0, 1]$ , que somam 1. A função é definida como:

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^k e^{z_k}}, j = 1, 2, \dots, k \quad (9)$$

As funções de ativação gaussianas são curvas em forma de sino que são contínuas. A saída do nó é interpretada dependendo da proximidade da entrada líquida de um valor médio escolhido, ou seja, é interpretada em termos de associação à classe (1 ou 0). A função é definida como:

$$f(x) = \frac{1}{r\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (10)$$

onde  $x$  é o centro (ponto médio) e  $r$  é o raio de abertura da função. Dentre as funções de ativação, a sigmoide, por ser uma função monotônica, limitada e ter uma derivada fácil de calcular, é mais amplamente utilizada em aplicações que envolvem o uso de RNAs.

## 2.4 Análise de Espectro Singular (SSA)

Alguns estudos empregaram o método SSA para prever séries temporais financeiras (Hassani, Soofi & Zhiglavsky, 2013b; Ghodsi & Omer, 2014). O método SSA compreende dois estágios: um é decomposição; o outro, de reconstrução. No primeiro estágio, a série temporal é decomposta para separar o sinal e o ruído; depois, no segundo estágio, a série com menos ruído é reconstruída e aplicada à previsão usando as seguintes algumas etapas (Hassani, 2007).

A primeira das etapas é a Incorporação. A incorporação pode ser considerada um mapeamento que transfere uma série temporal unidimensional  $Y_N = (y_1, \dots, y_N)$  para uma série multidimensional  $X_1, \dots, X_K$  com vetores  $X_i = (y_i, \dots, y_i + L - 1)^T \in R^L$ , onde  $L$  ( $2 \leq L \leq N - 1$ ) é o comprimento da janela e  $K = N - L + 1$ . O resultado dessa etapa é a matriz de trajetória.

$$X = [X_1, \dots, X_K] = (X_{ij})_{i,j=1}^{L,K} \quad (10)$$

Na etapa 2, temos a Decomposição do Valor Singular (SVD). Nessa etapa, o SVD de  $X$  é implementado. Denotado por  $\lambda_1, \dots, \lambda_L$  os autovalores de  $XX^T$  dispostos em ordem decrescente ( $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ ) e por  $U_1, \dots, U_L$  os vetores próprios correspondentes. O SVD de  $X$  pode ser escrito como  $X = X_1 + \dots + X_L$ , onde,  $X_i = \sqrt{\lambda_i} U_i V_i^T$ .

$\tilde{y}_i$  para  $i = 1, \dots, N$

$$y_t = \left\{ \sum_{j=1}^{L-1} \alpha_j y_{t-j}, \text{ para } i = N + 1, \dots, N + h' \right\} \quad (11)$$

Onde  $\tilde{y}_i$  ( $i = 1; \dots; N$ ) é a série reconstruída, e o vetor  $A = (\alpha_1, \dots, \alpha_{L-1})$  pode ser calculado por:

$$A = \frac{1}{1-v^2} \sum_{i=1}^r \pi_i u_i^v \quad (12)$$

Segundo Mahmoudvand et al. (2013), assume-se que o vetor  $U_i^v$  denota as primeiras  $L - 1$  componentes do autovetor  $U_j$  e que  $\pi_j$  é a última componente de  $U_i$  ( $i = 1, \dots, r$ ). O termo  $v^2 = \sum_{i=1}^r \pi_i^2$ .

## 2.5. Modelo Híbrido (HM)

Modelos puramente lineares ou puramente não lineares podem não ser adequados para prever retornos de ações, uma vez que os retornos são de natureza complexa. Até RNAs baseadas em dados produziram resultados mistos na previsão dos dados de séries temporais. Por exemplo, Denton (1995) usou dados simulados e descobriu que, quando há multicolinearidade ou outliers nos dados, as redes neurais podem prever os dados melhor do que os modelos de regressão linear. O tamanho da amostra e o nível de ruído desempenham um papel crucial na determinação do desempenho das RNAs para problemas de regressão linear (Markham & Rakes, 1998). Portanto, pode não ser útil aplicar RNAs para todos os tipos de dados.

Dadas as complexidades nos dados do mercado de ações, um método que pode lidar com os dados lineares e não lineares, ou seja, o modelo híbrido pode ser uma alternativa para a previsão. Aspectos lineares e não lineares dos padrões subjacentes nos dados podem ser capturados por meio da combinação de diferentes modelos. Pode ser útil considerar dados de séries temporais que consistem em estrutura de autocorrelação linear e um componente não linear. Isso é,

$$y_t = L_t + N_t \quad (13)$$

Onde  $L_t$  representa o componente linear e  $N_t$  denota o componente não linear. Inicialmente, devemos aplicar um modelo linear para os dados e, em seguida, os resíduos do modelo linear conterá apenas a relação não linear. Esses resíduos podem ser definidos como:

$$e_t = y_t - \hat{y}_t + \tilde{L}_t \quad (14)$$

Onde  $\tilde{L}_t$  é o valor previsto no tempo  $t$  da relação estimada da equação 13. Os resíduos são muito cruciais no diagnóstico da adequação dos modelos lineares, porque a presença de correlação linear nos resíduos indica a inadequação do modelo linear. Além disso, qualquer padrão não linear significativo nos resíduos também indica a limitação no modelo linear. Relações não lineares podem ser descobertas modelando resíduos usando RNAs. O modelo de RNA para resíduos com  $n$  nós de entrada será:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (15)$$

Onde  $f$  é uma função não linear determinada pela rede neural e  $\varepsilon_t$  é o erro aleatório. Denotando a previsão da equação 13 como  $\hat{N}_t$ , a previsão combinada será:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) \quad (16)$$

Onde  $\hat{Y}_t$  é o valor estimado do modelo híbrido, que é uma combinação de modelos lineares e não lineares. Utilizamos a razão erro inverso da média quadrada da previsão (MSFE) para determinar os pesos ótimos para os modelos híbridos, pois é um método amplamente utilizado com uma base teórica robusta (Bates & Granger, 1969). Para os modelos  $M$ , a previsão combinada do passo  $h$  à frente é:

$$\hat{Y}_{t+h} = \sum_{m=1}^M w_{m,h,t} \hat{Y}_{t+h,m} \quad (17)$$

$$w_{m,h,t} = \frac{\left(\frac{1}{msfe_{m,h,y}}\right)^k}{\sum_{j=1}^m \left(\frac{1}{msfe_{j,h,t}}\right)^k} \quad (18)$$

Onde  $\hat{Y}_{t+h,m}$  é o ponto previsto para  $h$  passos à frente no tempo  $t$  do modelo  $m$ . Em resumo, esse método híbrido contém duas etapas. O primeiro passo é empregar o ARIMA para modelar a parte linear dos dados. O segundo passo é aplicar a RNA para modelar os resíduos obtidos do ARIMA, visto que esses resíduos têm informações sobre a não linearidade nos dados. Os resultados do modelo ANN podem ser usados como previsões para os termos de erro do modelo ARIMA. Da maneira mencionada acima, o modelo híbrido abrange as características dos modelos ARIMA e ANN na modelagem de dados de séries temporais. Assim, pode ser benéfico empregar modelos híbridos para melhorar a precisão

das previsões.

## 2.6. Medidas de desempenho de previsão

A precisão das previsões indica quão bem um modelo de previsão prevê a variável escolhida. Diferentes medidas de precisão são usadas para validar a adequação de um modelo para um determinado conjunto de dados. Existem várias medidas de precisão na literatura, como erro médio (EM), erro absoluto médio (MAE), erro percentual absoluto médio (MAPE), erro quadrático médio (MSE) e erro quadrático médio da raiz (RMSE). Neste estudo, usamos o RMSE por ser um dos métodos mais adequados para medir a precisão da previsão de dados na mesma escala, e esse critério tem sido empregado em várias pesquisas anteriores (Lu & Wu, 2011; Wang et al., 2011; Hyndman & Athanasopoulos, 2015; Makridakis et al., 2015). Chai e Draxler (2014) também sugeriram que o RMSE é uma medida adequada para modelos com erros distribuídos normalmente. O erro quadrado médio (MSE) será dado por:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2, \quad (19)$$

O erro quadrático médio da raiz (RMSE) será dado por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (20)$$

## 3. Resultados empíricos

Os resultados empíricos, incluindo estatísticas descritivas e medidas de desempenho de vários métodos de previsão para retorno de ações em mercados desenvolvidos, emergentes e de fronteira, serão apresentados nesta seção.

### 3.1 Estatísticas descritivas dos retornos das ações

As Tabelas 1, 2 e 3 apresentam as estatísticas resumidas (por exemplo, média, desvio padrão, assimetria, curtose, estatística JB) para retornos do mercado de ações desenvolvidos, emergentes e de fronteira, respectivamente. A partir dessas tabelas, podemos ver que os retornos médios em todos os mercados são positivos, indicando retornos positivos gerais sobre os investimentos durante o período considerado para este estudo.

Tabela 1. Estatística Descritiva para Mercados Desenvolvidos

| País                  | Média    | Desvio Padrão | Skewness  | Kurtosis | Teste Jarque-Bera      | Teste Tsay |
|-----------------------|----------|---------------|-----------|----------|------------------------|------------|
| <b>Austrália</b>      | 0,016900 | 0,981318      | -0,366178 | 8,451780 | 5.732,678<br>(0,00000) | Não linear |
| <b>Canadá</b>         | 0,016719 | 1,043102      | -0,466783 | 13.58932 | 21.277,95<br>(0,00000) | Não linear |
| <b>França</b>         | 0,005790 | 1,429676      | 0,141474  | 8,712746 | 6.275,928<br>(0,00000) | Não linear |
| <b>Alemanha</b>       | 0,021703 | 1,475373      | 0,097060  | 8,111260 | 4.987,257<br>(0,00000) | Não linear |
| <b>Japão</b>          | 0,019562 | 1,501151      | -0,211389 | 9,413287 | 7.642,163<br>(0,00000) | Não linear |
| <b>Coreia do Sul</b>  | 0,040316 | 1,384506      | -0,350392 | 9,724636 | 8.473,831<br>(0,00000) | Não linear |
| <b>Suíça</b>          | 0,007731 | 1,174780      | -0,012284 | 10,18851 | 9.766,624<br>(0,00000) | Não linear |
| <b>Reino Unido</b>    | 0,009243 | 1,171826      | -0,004334 | 9,918071 | 9.061,453<br>(0,00000) | Não linear |
| <b>Estados Unidos</b> | 0,020694 | 1,147998      | -0,089045 | 12,10219 | 15.630,08<br>(0,00000) | Não linear |

Fonte: Estatísticas da Pesquisa (2020).

Os valores de curtose das séries de retorno de todos os mercados são superiores a 3, indicando que todas as séries são leptocúrticas – ou seja, possuem caudas grossas, o que é um fenômeno comum nos retornos das ações (Bouchauda & Potters, 2001; Humala, 2013; Mallikarjuna, Arti & Rao, 2018). O teste de *Jarque-Bera* mostrou que as séries não são normalmente distribuídas. Outra característica



importante, do teste de *Tsay* (1989), é que os retornos de todos os mercados são não lineares.

### 3.2. Resultados dos métodos de previsão

Para a obtenção de um bom resultado, devem ser feitas várias divisões diferentes no mesmo conjunto de dados em conjuntos de treinamento e de teste. Este método, chamado de *cross validation*, fornece uma estimativa mais realista do erro a ser cometido pelo método de classificação utilizado. Deve-se manter, nessa divisão, a mesma proporção entre as classes para os conjuntos de treinamento e validação (Martineli, 1999). Conforme recomenda Haykin (1999), o número de divisões diferentes no mesmo conjunto é 10, escolhendo-as de forma aleatória para a separação das amostras de treinamento e teste. Então, optou-se em utilizar o mesmo número de divisões proposto pelo autor em um único conjunto de dados. Em relação à divisão entre treinamento e teste, não existe nenhuma regra rígida estabelecida, e alguns autores preferem partições na proporção 60-40 ou 75-25 entre os grupos de treinamento e validação, respectivamente (Hair, Black, Babin & Anderson, 1998). Pesquisando trabalhos anteriores, observaram-se diversas divisões: Cunico (2005) optou em dividir os conjuntos na proporção 70-30; Lemos (2003), na proporção 90-10, ambos obtendo resultados satisfatórios. Neste trabalho, optou-se em separar os dados na proporção 80-20 para o conjunto de treinamento e teste, respectivamente, para observar se os resultados também seriam satisfatórios.

Para prever os retornos usando o modelo ARIMA ( $p, d, q$ ), foi necessário verificar a estacionariedade para obter inferências válidas. Para testar a estacionariedade das séries de retornos, empregamos os testes aumentados de Dickey-Fuller (1979) e Phillips-Perron (1988); os resultados mostraram que os retornos de todos os mercados eram estacionários. Determinamos o comprimento ótimo do atraso para a média autorregressiva ( $p$ ) e a média móvel ( $q$ ) componentes que utilizam o critério de informação de Akaike (AIC). Observamos diferentes ordens de AR e MA para séries diferentes e apresentamo-las juntamente com os valores RMSE nas Tabelas 4, 5 e 6. No modelo SETAR, a série exibiu tendências não lineares, e identificamos dois regimes pelos valores mínimos de AIC.

Tabela 2. Estatísticas Descritivas para Mercados Emergentes

| País          | Média    | Desvio Padrão | Skewness  | Kurtosis | Teste Jarque-Bera      | Teste Tsay |
|---------------|----------|---------------|-----------|----------|------------------------|------------|
| África do Sul | 0,047775 | 1,298747      | 0,036830  | 6,299922 | 2.044,612<br>(0,00000) | Não linear |
| Brasil        | 0,055547 | 1,769091      | 0,075096  | 7,347967 | 3.439,261<br>(0,00000) | Não linear |
| China         | 0,016499 | 1,585054      | -0,218775 | 7,684998 | 4.025,909<br>(0,00000) | Não linear |
| Egito         | 0,079649 | 1,658833      | -0,121416 | 13,15053 | 18.891,65<br>(0,00000) | Não linear |
| Índia         | 0,059777 | 1,414324      | 0,120611  | 12,83913 | 17.795,20<br>(0,00000) | Não linear |
| Indonésia     | 0,070676 | 1,326156      | -0,501572 | 9,570707 | 8.083,189<br>(0,00000) | Não linear |
| México        | 0,051820 | 1,213204      | 0,153714  | 9,356521 | 7.644,352<br>(0,00000) | Não linear |
| Rússia        | 0,082735 | 1,965327      | 0,370012  | 24,33804 | 85.492,66<br>(0,00000) | Não linear |
| Tailândia     | 0,047775 | 1,263998      | -0,520070 | 13,23751 | 2.044,612<br>(0,00000) | Não linear |
| Turquia       | 0,069655 | 1,973356      | -0,037463 | 9,689365 | 8.426,657<br>(0,00000) | Não linear |

Fonte: Estatísticas da Pesquisa (2020).

Em seguida, o modelo foi usado para prever os retornos dos mercados. Para prever retornos de ações usando o modelo ANN, empregamos redes neurais de *feedforward*, pois muitos estudos demonstraram que eles se encaixam bem com dados de retorno de ativos (Zhang, 2003; Qiu, Song & Akagi, 2016). Empregamos um modelo recorrente de análise de espectro único (RSSA) para prever os retornos após decompor e reconstruir a série de retornos originais, seguindo as quatro etapas envolvidas na previsão com SSA: incorporação, reconstrução, agrupamento e média diagonal. Para o modelo híbrido, que é uma combinação de ARIMA e ANN, ajustamos o modelo empregando a razão de erro médio de previsão quadrada inversa (MSFE), amplamente utilizada (Bates & Granger, 1969; Winkler & Makridakis, 1983) para atribuir melhor as ponderações para os modelos na previsão.

As Tabelas 4, 5 e 6 apresentam os valores RMSE dos conjuntos de testes da série de previsões

para todas as técnicas (ou seja, ARIMA, SETAR, SSA, ANN e HM) para mercados desenvolvidos, emergentes e de fronteira, respectivamente. O modelo com o menor RMSE foi escolhido como o modelo mais apropriado. Além disso, testamos a significância do RMSE usando o teste de *Diebold-Marino* (1995) e constatou-se que o RMSE de todos os modelos era significativo, exceto para o Japão, África do Sul e Sri Lanka.

Tabela 3. Estatísticas Descritivas para Mercados de Fronteira

| País             | Média    | Desvio Padrão | Skewness | Kurtosis | Teste Jarque-Bera       | Teste Tsay |
|------------------|----------|---------------|----------|----------|-------------------------|------------|
| <b>Argentina</b> | 0,120985 | 2,162861      | 0,018419 | 7,202958 | 3.230,70<br>(0,00000)   | Não linear |
| <b>Estônia</b>   | 0,052646 | 1,036820      | 0,316893 | 14,29612 | 24.406,12<br>(0,00000)  | Não linear |
| <b>Quênia</b>    | 0,012726 | 0,831383      | 0,555709 | 15,16038 | 28.057,55<br>(0,00000)  | Não linear |
| <b>Sri Lanka</b> | 0,066494 | 1,128874      | 0,993308 | 43,75095 | 300.319,20<br>(0,00000) | Não linear |
| <b>Tunísia</b>   | 0,035152 | 1,292467      | 0,603647 | 20,46153 | 59.408,84<br>(0,00000)  | Não linear |

Fonte: Estatísticas da Pesquisa (2020).

Nas Tabelas 4, 5 e 6, podemos observar que nenhum método isolado teve desempenho uniforme em todos os mercados. No entanto, o modelo não linear (ou seja, SETAR) teve um desempenho melhor que os outros modelos, produzindo previsões ideais para 10 mercados (ou seja, quatro mercados desenvolvidos, quatro emergentes e dois de fronteira). Esse resultado contrasta com Guidolin et al. (2009). No caso de mercados desenvolvidos, o modelo SETAR produziu previsões ótimas para quatro dos nove mercados (Austrália, França, Japão e Suíça).

Tabela 4. Valores RMSE dos modelos de previsão para mercados desenvolvidos

| País                  | ARIMA                      | SETAR     | ANN       | SSA       | HM        |
|-----------------------|----------------------------|-----------|-----------|-----------|-----------|
| <b>Alemanha</b>       | ARIMA (3,0,3)<br>1,137963  | 1,140388  | 1,156347  | 1,139859  | 1,138008  |
| <b>Austrália</b>      | ARIMA (1,0,0)<br>0,839708  | 0,8371075 | 0,839961  | 0,853739  | 0,8398178 |
| <b>Canadá</b>         | ARIMA (4,0,4)<br>0,7160948 | 0,7235669 | 0,7279448 | 0,721191  | 0,7178712 |
| <b>Coreia do Sul</b>  | ARIMA (1,0,2)<br>1,312612  | 0,7845301 | 0,7816591 | 0,7975102 | 0,7815836 |
| <b>Estados Unidos</b> | ARIMA (2,0,0)<br>0,8197795 | 0,8125207 | 0,8171281 | 0,8187795 | 0,8119642 |
| <b>França</b>         | ARIMA (2,0,3)<br>1,104531  | 1,1044509 | 1,121098  | 1,133334  | 1,107893  |
| <b>Japão</b>          | ARIMA (1,0,1)<br>1,312612  | 1,307090  | 1,312699  | 1,319925  | 1,312697  |
| <b>Reino Unido</b>    | ARIMA (3,0,2)<br>0,9002485 | 0,9003106 | 0,9093658 | 0,9194308 | 0,9057976 |
| <b>Suíça</b>          | ARIMA (3,0,3)<br>0,9262604 | 0,9252304 | 0,9262753 | 0,935211  | 0,9262085 |

Fonte: Autor (2020).

O modelo ARIMA foi ideal para o Canadá, Alemanha e Reino Unido; o modelo HM, para a Coreia do Sul e os EUA. Assim, podemos dizer que modelos não lineares são mais adequados para mercados desenvolvidos. Enquanto isso, os modelos ANN e SSA não são de todo úteis para mercados desenvolvidos, uma vez que não forneceram previsões ideais.

Tabela 5. Valores RMSE dos modelos de previsão para mercados emergentes

| País                 | ARIMA                     | SETAR    | ANN      | SSA      | HM       |
|----------------------|---------------------------|----------|----------|----------|----------|
| <b>África do Sul</b> | ARIMA (3,0,1)<br>1,062336 | 1,064449 | 1,063028 | 1,066819 | 1,061791 |
| <b>Brasil</b>        | ARIMA (2,0,1)<br>1,441972 | 1,442167 | 1,442900 | 1,470025 | 1,442262 |
| <b>China</b>         | ARIMA (3,0,3)<br>1,555623 | 1,570942 | 1,56378  | 1,555431 | 1,554521 |
| <b>Egito</b>         | ARIMA (0,0,1)<br>1,357198 | 1,324729 | 1,368285 | 1,385264 | 1,357206 |
| <b>Índia</b>         | ARIMA (3,0,1)<br>0,838730 | 0,844534 | 0,839839 | 0,851503 | 0,838335 |

|                  |               |          |          |          |          |
|------------------|---------------|----------|----------|----------|----------|
| <b>Indonésia</b> | ARIMA (1,0,0) | 0,926838 | 0,918685 | 0,921310 | 0,918988 |
|                  | 0,919355      |          |          |          |          |
| <b>México</b>    | ARIMA (2,0,1) | 0,848814 | 0,867506 | 0,851756 | 0,848878 |
|                  | 0,850496      |          |          |          |          |
| <b>Rússia</b>    | ARIMA (3,0,4) | 0,993842 | 1,008659 | 1,006565 | 1,000470 |
|                  | 0,996021      |          |          |          |          |
| <b>Tailândia</b> | ARIMA (2,0,2) | 0,754199 | 0,770766 | 0,775997 | 0,762275 |
|                  | 0,756856      |          |          |          |          |
| <b>Turquia</b>   | ARIMA (2,0,2) | 1,286060 | 1,292737 | 1,291581 | 1,283447 |
|                  | 1,280623      |          |          |          |          |

Fonte: Autor (2020).

Para mercados emergentes, o modelo SETAR foi considerado adequado para quatro mercados (Egito, México, Rússia e Tailândia). Os modelos HM foram apropriados para três mercados (China, Índia e África do Sul); os modelos ARIMA, para dois (Brasil e Turquia). O modelo de RNA era apropriado para apenas um mercado (Indonésia), enquanto o modelo de SSA não era adequado para nenhum mercado emergente. Embora nenhum modelo único fosse adequado para todos os mercados emergentes, os modelos SETAR e HM eram relativamente mais úteis. Em relação aos mercados fronteiriços, o SETAR foi adequado para Argentina e Quênia, ARIMA para Estônia e Sri Lanka e SSA para Tunísia. Os modelos ANN e HM não eram apropriados para nenhum mercado.

Tabela 6. Valores RMSE dos modelos de previsão para mercados de fronteira

| País             | ARIMA         | SETAR    | ANN      | SSA      | HM       |
|------------------|---------------|----------|----------|----------|----------|
| <b>Argentina</b> | ARIMA (1,0,0) | 2,046473 | 2,059416 | 2,067785 | 2,061399 |
|                  | 2,058513      |          |          |          |          |
| <b>Estônia</b>   | ARIMA (1,0,2) | 0,576389 | 0,593064 | 0,567850 | 0,574015 |
|                  | 0,554262      |          |          |          |          |
| <b>Quênia</b>    | ARIMA (2,0,2) | 0,656696 | 0,656707 | 0,680819 | 0,684070 |
|                  | 0,679084      |          |          |          |          |
| <b>Sri Lanka</b> | ARIMA (0,0,2) | 0,449314 | 0,444426 | 0,473222 | 0,445437 |
|                  | 0,443346      |          |          |          |          |
| <b>Tunísia</b>   | ARIMA (1,0,0) | 0,44934  | 0,618865 | 0,443756 | 0,464829 |
|                  | 0,460538      |          |          |          |          |

Fonte: Autor (2020).

Dos vinte e quatro índices do mercado de ações, o modelo SETAR produziu previsões ideais para dez; ARIMA para sete; modelos HM para cinco; e modelos ANN e SSA para um mercado cada. A partir desses resultados, podemos observar que modelos não lineares são mais úteis para mercados desenvolvidos, emergentes e de fronteira. Outra observação interessante é que os modelos de IA e domínio de frequência foram considerados adequados apenas para um mercado cada. Assim, podemos dizer que, mesmo com os avanços nos modelos de IA e no domínio da frequência, os modelos estatísticos tradicionais não se tornaram obsoletos: eles ainda são úteis e, de fato, são melhores que os modelos de IA e de domínio de frequência para prever dados financeiros de séries temporais.

#### 4. Considerações finais

Ao longo dos anos, as bolsas de valores tornaram-se caminhos alternativos para excedentes de fundos entre investidores individuais e institucionais, principalmente após a globalização e a integração dos mercados financeiros mundiais. Dado o risco inerente, a incerteza e a natureza dinâmica dos mercados de ações, prever com precisão o retorno das ações pode ajudar a minimizar os riscos dos investidores. Assim, as técnicas de previsão podem ajudar na melhor tomada de decisão de investimento.

Este estudo considerou dados diários dos retornos do mercado de ações, durante o período de 1º de janeiro de 2000 a 31 de dezembro de 2019, para comparar técnicas de previsão (ou seja, modelos ARIMA, SETAR, ANN, SSA e HM) representando lineares, não lineares, IA, domínio de frequência e híbridos métodos. Foram coletados os índices de ações de 24 bolsas de valores em três categorias de mercado (nove desenvolvidas, dez emergentes e cinco de fronteira) para encontrar técnicas de previsão adequadas para cada categoria.

Os resultados mostraram que nenhuma técnica de previsão única forneceu uma previsão ideal para todos os mercados. No entanto, o SETAR teve melhor desempenho em dez mercados; ARIMA em sete; HM em cinco; e ANN e SSA em um mercado cada. As técnicas SETAR e ARIMA podem, portanto,

ser consideradas as vencedoras na previsão de retornos do mercado de ações para mercados desenvolvidos, emergentes e de fronteira, pois esses dois métodos forneceram previsões ideais para dezesseis dos vinte e quatro mercados.

Para pesquisas futuras, recomenda-se o uso das técnicas de previsão estudadas neste artigo para captar sua eficiência apenas em momentos de crise financeira internacional (como na crise da dívida dos países da América Latina, em 1920; bolha imobiliária e de ações no Japão, em 1985; crise dos mercados emergentes, em 1994, ou crise mundial do *suprime*, em 2008) ou ainda destacando apenas períodos de volatilidade causados por Endemias ou Pandemias, como no caso recente da COVID-19, que tem afetado os mercados financeiros internacionais desde o ano de 2020.

## Referências

- Adebiyi, A.A., & Oluinka, A. (2014) Comparison of ARIMA and artificial neural network models for stock market prediction. *Journal of Applied Mathematics*, 14(1), 7-21.
- Almudhaf, F. (2018) Predictability, Price bubbles, and efficiency in the Indonesian stock-market. *Bulletin of Indonesian Economic Studies*, 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, I.D. (2016) A new model selection strategy in time series forecasting with artificial neural networks. *Neurocomputing Journal*, 174(1), 974-987.
- Asadi, S., Tavakoli, A., & Hejazi, S.R. (2010) A new hybrid for improvement of auto-regressive integrated moving average models applying particle swarm optimization. *Expert Systems with Applications*, 39, 5332-5337.
- Awajan, A.M., Ismail M.T., Wadi S.A. (2018) Improving forecasting accuracy for stock market data using EMD-HW bagging. *PLoS One*, 13(7):1-20.
- Bates, J.M., & Granger, C.W.J. (1969). The combination of forecasts. *Operational Research Society*, 20(4), 51-468.
- Beck, T., & Levine, R. (2003). Stock markets, banks and growth: panel evidence. *Journal of Banking and Finance*, 28, 423-442.
- Boero, G. (2003). The performance of SETAR models: a regime conditional evaluation of point, interval and density forecasts. *International Journal of Forecasting*, 20, 305-320.
- Boero, G., & Marrocu, E. (2002). The performance of non-linear exchange rate models: a forecasting comparison. *Journal of Forecasting* 21(7), 513-542
- Bouchauda, J.P., & Potters, M. (2001). More stylized facts of financial markets: leverage effect and downside correlations. *Physica Analytics*, 299, 60-70.
- Clements, M.P., & Smith, J. (1999). A Monte Carlo study of the forecasting performance of empirical SETAR models. *Journal of Applied Economics*, 14, 124-141.
- Cristelli, M. (2014). *Complexity in financial markets*. Springer International Publishing, Cham. Recuperado de <https://doi.org/10.1007/978-3-319-00723-6>.
- Cunico, L. H. B. (2005). *Técnicas em data mining aplicadas na predição de satisfação de funcionários de uma rede de lojas do comércio varejista*. Dissertação de Mestrado, Universidade Federal do Paraná, PR.
- Darrat, A.F., & Zhong, M. (2000). On testing the random walk hypothesis a model Comparison approach. *The Financial Review*, 35, 105-124.
- Denton, J.W. (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, F.X., & Marino, R.S. (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 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, E.F. (1970). Efficient capital markets: a review of theory and empirical work. *Journal of Finance*, 25(2), 383-417.
- Firat, E.H. (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., & Zimbras D.K. (2005). A dynamic artificial neural network model for forecasting series events. *International Journal of Forecasting*, 21, 341–362.
- Ghodsi, Z., & Omer, H.N. (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, D.J. (1998). On threshold moving-average models. *Journal of Time Series Analysis*, 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, S.K., & Rao, R.P. (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, T.U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38, 10389–10397.
- Hamilton, J.D. (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. *Journal of Forecasting*, 32(5), 395–408.
- Hassani, H., Soofi, A., & Zhiglavsky, A. (2013b) Predicting inflation dynamics with singular Spectrum analysis. *Journal of Royal Statistical Society*, 176(3), 743–760.
- Haykin, S. (1999). *Neural Networks: a comprehensive foundation*. New Jersey: Prentice-Hall.
- Humala, A. (2013). Some stylized facts of return in the foreign exchange and stock markets in Peru. *Studies in Economics and Finance*, 30(2), 139–158.
- Hung, S.L., & 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. Recuperado de <https://otexts.com/fpp3/>.
- Ince, H., & Trafalis, T.B. (2017). A hybrid forecasting model for stock market prediction. *Economic Computation and Economic Cybernetics Studies and Research*, 21, 263–280.
- Ismail, M.T., & Isa, Z. (2006). *Modelling exchange rate using regime switching models*. *Sains Malaysiana Journal*, 35(2), 55–62.
- Johnson, N.F., Jefferies P., Hui P.M. (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 Systems with Applications*, 37, 479–489.
- Khashei, M., & Bijari, M. (2012). A new class of hybrid models for time series forecasting. *Expert Systems with Applications*, 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. *Journal of Advanced Management Science*, 2(1), 29–32.
- Lahmiri, S. (2016). A variational mode decomposition approach for analysis and forecasting of economic and financial time series. *Expert Systems with Applications*, 55, 268–273.
- Lemos, E. P. (2003). *Análise de crédito bancário com o uso de data mining: redes neurais e árvores de decisão*. Dissertação de Mestrado, Universidade Federal do Paraná, PR.
- Levine, R. (1997). Financial development and economic growth: views and agenda. *Journal of Economic Literature*, 35, 688–726.

- Levy, R.A. (1967). The theory of random walks: a study of findings. *American Economy Review*, 11(2),34–48.
- Lo, A.W., & Mackinlay, A.C. (2002). *An non-random walk down Wall street*. Princeton University Press, Princeton.
- Lu, C.J., & Wu, J.Y. (2011). An efficient CMAC neural network for stock index forecasting. *Expert Systems with Applications*, 38, 15194–15201.
- Mahmoudvand, R.; Najari, N. and Zokaei, M. (2013). On the Parameters for Reconstruction and Forecasting in the Singular Spectrum Analysis. *Communication in Statistics: Simulations and Computations*, 42, 860–870.
- Makridakis, S., Wheelwright, S.C., & Hyndman, R.J. (2015). *Forecasting: methods and applications*. Wiley India, New Delhi.
- Mallikarjuna, M., Arti, G., & Rao R.P. (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, K.S., & Rao R.P. (2017). Modelling Sectoral volatility of Indian stock markets. *Wealth International Journal of Money Banking and Finance*, 6(2), 4–9.
- Markham, I.S., Rakes, T.R. (1998). The effect of sample size and variability of data on the comparative performance of artificial neural networks and regression. *Computers & Operations Research*, 25,251–263.
- Martineli, E. (1999). *Extração de conhecimento de redes neurais artificiais*. Dissertação de Mestrado, Universidade de São Paulo – USP, SP.
- 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, M.M. (2010). Forecasting stock exchange movements using neural networks: empirical evidence from Kuwait. *Expert Systems with Applications*, 37, 6302–6309.
- MSCI. (2018). *MSCI Announces the Results of Its Annual Market Classification Review*. Recuperado de <https://www.msci.com/market-classification>.
- Nayak, S.C., & Misra, B.B. (2018). Estimating stock closing indices using a GA-weighted condensed polynomial neural network. *Financial Innovation*, 4(21), 1–22.
- Ojo, J.F., & Olatayo, T.O. (2009). ON the estimation and performance of subset of autoregressive integrated moving average models. *European Journal of Scientific Research*, 28, 287–293.
- Owido, P.K., Onyuma, S.O., & 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, P.C.B., & 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. *Journal of Applied Business Research*, 30(3), 647–658.
- Rajan, R., & Zingales, L. (1998). Financial dependence and growth. *American Economic Review*, 88, 559–586.
- Rousseau, P.L., & Watchel, P. (2000). Equity markets and growth: cross-country evidence on timing and outcomes, 1980-1995. *Journal of Banking and Finance*, 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, T., Li, B., & Benkato, O. (2014). Revisiting the weak form efficiency of the Australian stock market. *Corporate Ownership and Control*, 11(2), 21–28.
- Tsay, R. (1989). Testing and modeling threshold autoregressive processes. *Journal of American Statistical Association*, 84, 231–240.
- Wang, J.Z., Wang, J.J., Zhang, Z.G., & Guo, S.P. (2011). Forecasting stock indices with backpropagation neural network. *Expert Systems with Applications*, 38(1), 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, O.L. (2015). Modern financial markets and the complexity of financial innovation. *Universal Journal of Accounting and Finance*, 3(3), 117–125.

- Winkler, R.L., & Makridakis, S. (1983). The combination of forecasts. *Journal of Royal Statistical Society*, 146(2), 150–157.
- Zhang, G.P. (2003) Time series forecasting using a hybrid ARIMA and neural network model. *Neuro-computing*, 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.