Elivelto Ebermam

Desenvolvimento de um Método Híbrido para Negociações de Ações na Bolsa de Valores Brasileira

Vitória, ES

2018

Elivelto Ebermam

Desenvolvimento de um Método Híbrido para Negociações de Ações na Bolsa de Valores Brasileira

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Informática.

Universidade Federal do Espírito Santo – UFES

Centro Tecnológico

Programa de Pós-Graduação em Informática

Orientador: Prof. Dr. Renato A. Krohling

Coorientador: MSc. Helder Knidel

Vitória, ES

2018

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Tecnológica,
Universidade Federal do Espírito Santo, ES, Brasil)

Ebermam, Elivelto, 1993-

E16d Desenvolvimento de um método híbrido para negociações de ações na bolsa de valores brasileira / Elivelto Ebermam. – 2018.

78 f. : il.

Orientador: Renato Antônio Krohling.

Coorientador: Helder Knidel.

Dissertação (Mestrado em Informática) – Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Ações (Finanças) – Negociação. 2. Bolsa de valores. 3. Análise técnica (Análise de investimentos). 4. Decomposição de modo empírico (EMD). 5. TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution). 6. Máquinas de aprendizado extremo (ELM). I. Krohling, Renato Antônio. II. Knidel, Helder. III. Universidade Federal do Espírito Santo. Centro Tecnológico. IV. Título.

CDU: 004

Elaborada por Sandra Mara Borges Campos – CRB-6 ES-000593/O

Elivelto Ebermam

Desenvolvimento de um Método Híbrido para Negociações de Ações na Bolsa de Valores Brasileira

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Informática.

Trabalho aprovado. Vitória, ES, 03 de agosto de 2018:

Prof. Dr. Renato A. Krohling
Orientador

MSc. Helder Knidel
Coorientador

Prof^{a}. Dr^{a}. Claudine Santos Badue Gonçalves
Membro interno

Dr. Rodolfo Lourenzutti Torres de Oliveira
Membro externo

Vitória, ES
2018

Dedico essa dissertação a minha esposa Sheila e aos meus pais Avelino e Evani

DECLARAÇÃO DE AUTORIA

Eu, Elivelto Ebermam, declaro que este trabalho foi escrito e desenvolvido por mim. Toda e qualquer ajuda recebida durante todo o processo de desenvolvimento foi devidamente reconhecida. Além disso, certifico que todas as fontes de informação e literatura utilizadas são indicadas na dissertação.

Vitória, ES

2018

Agradecimentos

Agradeço a primeiramente a Deus, por ter me guiado neste e em todos os momentos da minha vida.

Aos meus pais Avelino e Evani e aos meus avós por todo auxílio e incentivo ao estudo. A minha irmã Elciele e a todos os familiares que me auxiliaram desde os tempos de graduação, em especial, meu tio Arlindo. Aos meus tios-avós Martins e Zélia, pelo acolhimento em sua casa e por todo auxílio prestado na cidade de Vitória.

À minha esposa Sheila, por toda compreensão, incentivo e auxílio. Aos familiares da minha esposa pelo apoio.

Ao meu professor orientador Renato Krohling, por toda sua dedicação e compreensão, e pelo seu ensinamento e incentivo à busca pelo conhecimento. Ao meu coorientador Helder Knidel, por todo auxílio prestado, principalmente em relação ao mercado de ações.

Aos membros da banca, Claudine Santos Badue Gonçalves e Rodolfo Lourenzutti Torres de Oliveira por aceitarem o convite.

Aos amigos do Labcin, pelo auxílio e por todas conversas e debates, que sempre foram proveitosos.

Ao CNPq pela bolsa de mestrado.

"A verdadeira força se esconde na fraqueza"
(autor desconhecido)

Resumo

O mercado de ações brasileiro tem atraído muitos investidores e movimenta bilhões de reais diariamente. No entanto, decidir quando comprar ou vender uma ação não é uma tarefa fácil, pois o mercado é difícil de prever, sendo influenciado por fatores políticos e econômicos. Dessa forma, metodologias baseadas em inteligência computacional tem sido aplicadas para essa tarefa. Entretanto, a maioria dos trabalhos seleciona uma ação ou índice a priori para aplicação de determinado método. A seleção da ação em si já é um problema importante, pois cada mercado possui várias ações. Assim, um método de tomada de decisão multicritério como a técnica para preferência de ordem por similaridade à solução ideal (TOPSIS) pode ser aplicado. Nesse trabalho, a cada dia as ações são ranqueadas pelo TOPSIS utilizando critérios da análise técnica, e a mais apta é selecionada para compra. Mesmo assim, pode ocorrer que o mercado não esteja favorável para compra em determinados dias, ou mesmo, o TOPSIS fazer uma seleção incorreta. Para aumentar a confiabilidade da seleção, outro método deve ser utilizado. Assim é utilizado um modelo híbrido composto por decomposição de modo empírico (EMD) e máquina de aprendizado extremo (ELM). O EMD decompõe a série em várias sub-séries, e com isso a componente principal, ou seja, de tendência é extraída. Essa componente é processada pela ELM, a qual realiza a predição do próximo elemento da mesma. Se o valor predito pela ELM for superior ao último valor, então a compra da ação é confirmada. Uma segunda confirmação da compra pode ser realizada por meio de regras de negociação baseadas em indicadores técnicos. Foram testados indicadores individualmente e combinações entre dois indicadores. O método foi aplicado em um universo de 50 ações do mercado brasileiro. A seleção feita pelo TOPSIS mostrou resultados promissores, quando comparado com a seleção aleatória e ao retorno gerado pelo índice Bovespa. A confirmação com o modelo híbrido EMD-ELM conseguiu aumentar o percentual de negociações com lucro.

Palavras-chaves: Negociação de ações. Análise técnica. Técnica para preferência de ordem por similaridade à solução ideal (TOPSIS). Decomposição em modos empíricos (EMD). Máquina de aprendizado extremo (ELM).

Abstract

The Brazilian stock market has attracted many investors and moves billions of Real daily. However, deciding when to buy or sell a stock is not an easy task because the market is hard to predict, being influenced by political and economic factors. Thus, methodologies based on computational intelligence have been applied to this task. However, most papers select an a priori stock or index to the application of a given method. The stock selection itself is already a challenging problem, since each market has several stocks. Thus, a multicriteria decision-making method such as the technique for order preference by similarity to ideal solution (TOPSIS) can be applied. In this work, every day the stocks are ranked by TOPSIS using technical analysis criteria, and the most suitable stock is selected for purchase. Even so, it may occur that the market is not favorable to purchase on certain days, or even, the TOPSIS make an incorrect selection.To increase the reliability of the selection, another method should be used. Thus, a hybrid model composed of empirical mode decomposition (EMD) and extreme learning machine (ELM) is used. The EMD decomposes the series into several sub-series, and thus the main (trend) component is extracted. This component is processed by the ELM, which performs the prediction of the next element of component. If the value predicted by the ELM is greater than the last value, then the purchase of the stock is confirmed. A second confirmation of the purchase can be made by negotiation rules of technical indicators. Individual indicators and combinations between two indicators were tested. The method was applied to 50 stocks in the Brazilian market. The selection made by TOPSIS showed promising results when compared to the random selection and the return generated by the Bovespa index. Confirmation with the EMD-ELM hybrid model was able to increase the percentage of profit tradings.

Keywords: Stock trading. Technical analysis. Technique for order preference by similarity to ideal solution (TOPSIS). Empirical mode decomposition (EMD). Extreme learning machine (ELM).

Lista de ilustrações

Figura 1 – Indicador Bandas de Bollinger aplicado sobre a ação da empresa Petrobras (PETR4) durante o ano 2016 34
Figura 2 – Decomposição de série temporal feita pelo EMD 41
Figura 3 – Neurônio artificial 41
Figura 4 – Exemplo de arquitetura de uma rede neural 42
Figura 5 – Metodologia baseada no TOPSIS usando indicadores da análise técnica 48
Figura 6 – Método combinando TOPSIS e EMD-ELM 51
Figura 7 – Método híbrido combinando TOPSIS, EMD-ELM e regras de negociação de indicadores de análise técnica 54
Figura 8 – Histogramas dos indicadores 61
Figura 9 – Histograma do coeficiente de proximidade relativa 62
Figura 10 – Retorno percentual dos métodos ao longo do ano de 2017 69

Lista de tabelas

Tabela 1 – Regra RSI 32
Tabela 2 – Regra K 32
Tabela 3 – Regra D 33
Tabela 4 – Regra KD 33
Tabela 5 – Regra CCI 34
Tabela 6 – Regra BB 35
Tabela 7 – Exemplo de formação da matriz de decisão para aplicação do TOPSIS para seleção de ações 49
Tabela 8 – Exemplo da aplicação do TOPSIS para seleção de ações 49
Tabela 9 – Modelagem de série temporal 50
Tabela 10 – Serie temporal de uma ação selecionada pelo TOPSIS 52
Tabela 11 – Aplicação do EMD sobre a série normalizada 52
Tabela 12 – Série modelada como entrada para rede neural 53
Tabela 13 – Códigos e nomes das ações consideradas nesse trabalho 57
Tabela 14 – Comparação entre retorno cumulativo e simulação com investimento inicial determinado 59
Tabela 15 – Resultados da aplicação do TOPSIS para o ano de 2016 60
Tabela 16 – Resultados do TOPSIS (K-D-CCI) + EMD-ELM para o ano de 2016 . 64
Tabela 17 – Resultados do TOPSIS (D-CCI) + EMD-ELM para o ano de 2016 . . 65
Tabela 18 – Resultados do TOPSIS (RSI-K-D-CCI) + EMD-ELM para o ano de 2016 66
Tabela 19 – TOPSIS (RSI-K-D-CCI) + EMD-ELM + regras 67
Tabela 20 – TOPSIS (RSI-K-D-CCI) + EMD-ELM + regras 68
Tabela 21 – Resultados do TOPSIS para o ano de 2017 68
Tabela 22 – Resultados TOPSIS+EMD-ELM para o ano de 2017 69
Tabela 23 – Resultados TOPSIS+EMD-ELM+regras para o ano de 2017 69

Lista de abreviaturas e siglas

BB	Bandas de Bollinger
CCI	Índice de Canal de Commodities
D	Linha D do indicador estocástico
ELM	Máquina de Aprendizado Extremo
EMD	Decomposição de Modo Empírico
HME	Hipótese do Mercado Eficiente
IMF	Função de Modo Intrínseca
K	Linha K do indicador estocástico
KD	Cruzamento das linhas K e D do indicador estocástico
RSI	Índice de Força Relativa
TOPSIS	Técnica para Ordem de Preferência por Similaridade à Solução Ideal

Sumário

1 INTRODUÇÃO . . . 25
1.1 Definição do problema . . . 25
1.2 Motivação . . . 27
1.3 Objetivos . . . 28
1.4 Estrutura do trabalho . . . 28
1.5 Lista de publicações . . . 28

2 ANÁLISE TÉCNICA . . . 31
2.1 Índice de Força Relativa (RSI) . . . 31
2.1.1 Definição . . . 31
2.1.2 Regra de negociação . . . 31
2.2 Oscilador estocástico . . . 32
2.2.1 Definição . . . 32
2.2.2 Regra de negociação . . . 32
2.3 Índice de Canal de Commodities (CCI) . . . 33
2.3.1 Definição . . . 33
2.3.2 Regra de negociação . . . 33
2.4 Bandas de Bollinger (BB) . . . 34
2.4.1 Definição . . . 34
2.4.2 Regra de negociação . . . 35

3 ALGORITMOS UTILIZADOS . . . 37
3.1 Técnica para preferência de ordem por similaridade à solução ideal (TOPSIS) . . . 37
3.2 Decomposição de Modo Empírico (EMD) . . . 39
3.3 Máquina de aprendizado extremo (ELM) . . . 40

4 MÉTODO HÍBRIDO PARA NEGOCIAÇÃO DE AÇÕES . . . 47
4.1 Introdução . . . 47
4.2 Seleção de ação para compra através do TOPSIS . . . 47
4.3 Classificação de tendência com EMD-ELM . . . 49
4.4 Confirmação de compra por meio de regras de negociação de indicadores técnicos . . . 52
4.5 Seleção de parâmetros . . . 53
4.6 Efeito do viés de olhar à frente . . . 54

5 RESULTADOS EXPERIMENTAIS 57
5.1 Base de dados 57
5.2 Métricas de avaliação 58
5.3 Resultados usando TOPSIS 59
5.3.1 Estratégias usadas para comparação 59
5.3.2 Aplicação para o ano de 2016 59
5.3.3 Análise dos critérios utilizados para o TOPSIS 60
5.4 Resultados usando TOPSIS + EMD-ELM 62
5.5 Regras de negociação da análise técnica 63
5.5.1 Regras utilizando apenas um indicador 64
5.5.2 Regras utilizando dois indicadores 66
5.6 Resultados para o ano de 2017 67
5.7 Análise dos resultados 70

6 CONCLUSÃO 73

REFERÊNCIAS 75

1 Introdução

1.1 Definição do problema

Os mercados acionários movimentam uma grande quantia de dinheiro em muitos países diariamente (dias úteis). No entanto, mercados financeiros são essencialmente dinâmicos, não-lineares, complicados e caóticos por natureza (TAN; QUEK; NG, 2007). Prever o preço ou o movimento das ações, assim como o melhor momento para comprá-las e vendê-las, é uma tarefa difícil e ainda não solucionada. Essa dificuldade se deve ao fato do comportamento do mercado ser volátil e influenciado por vários fatores macroeconômicos como: eventos políticos, políticas de empresas, condição geral da economia, expectativa dos investidores, escolhas de investidores institucionais, movimentos de outros mercados, psicologia dos investidores, entre outros (VARGAS; LIMA; EVSUKOFF, 2017; TAN; QUEK; NG, 2007).

A previsibilidade ou não-previsibilidade do mercado financeiro tem sido motivo de discussão entre pesquisadores e também de investidores profissionais durante décadas. Um dos pontos centrais dessa discussão é a validade da hipótese do mercado eficiente (HME), criado por Fama na década de 1960. Essa hipótese diz que o preço sempre incorpora todas as informações disponíveis (FAMA, 1970). Assim, se as informações forem refletidas imediatamente nos preços das ações, então a alteração de preço de amanhã é independente das alterações de preço atuais, dependendo apenas das notícias de amanhã (MALKIEL, 2003). Notícias, no entanto, são por definição imprevisíveis, tornando as mudanças de preços também imprevisíveis e aleatórias (MALKIEL, 2003). Isso significa que, por essa hipótese, os preços no mercado seguem um movimento aleatório (do inglês: *random walk*), sendo impossível utilizar comportamentos passados para realizar predição sobre o preço dos ativos (PAPACOSTANTIS, 2009).

Entretanto, muitos economistas e estatísticos acreditam que o preço das ações é, pelo menos, parcialmente previsível (MALKIEL, 2003). Com base nisso, surgiram vários trabalhos na tentativa de prever o mercado de ações e questionar a HME. Nas últimas décadas, métodos baseados em inteligência computacional tais como redes neurais, algoritmos evolutivos, lógica *fuzzy*, entre outros, têm sido aplicados para esse problema.

Redes neurais artificiais tem tido um relativo sucesso na previsão de preços e movimentos no mercado de ações. Martinez et al. (2009) utilizaram uma rede neural tradicional para previsão dos preços de mínimo e máximo diários para duas ações do mercado acionário brasileiro. Já Oliveira et al. (2011) realizam a predição do preço de fechamento da ação Petrobras (PETR4). Kara, Boyacioglu e Baykan (2011) utilizaram

redes neurais e máquina de vetor de suporte para prever o movimento do índice do mercado acionário de Istambul (ISE). Nelson, Pereira e Oliveira (2017) utilizaram rede neural de memória de longo prazo (do inglês: *long short-term memory*, abreviado por LSTM) para predição de tendência de preço de cinco ações do mercado brasileiro. Vargas, Lima e Evsukoff (2017) combinaram rede neural convolucional e rede neural recorrente (no caso uma LSTM) para predição do movimento do índice S&P500, tendo como entradas títulos de notícias e indicadores técnicos. Nascimento et al. (2017) usaram redes neurais sem peso VG-RAM para avaliar oportunidades de investimento no mercado futuro brasileiro na escala de dezenas de segundos.

A lógica *fuzzy* também tem sido aplicada em problemas do mercado financeiro, principalmente por sua capacidade de tratar incertezas. Sistemas de suporte a decisão, combinando indicadores técnicos e lógica *fuzzy*, são utilizados em Dourra e Siy (2002), Cheung e Kaymak (2007) e Ijegwa et al. (2014). Naranjo, Arroyo e Santos (2018) desenvolveram um sistema de negociação de ações baseado em padrões gráficos de *candles* usando lógica *fuzzy*.

Algoritmos evolutivos têm sido utilizados principalmente para otimizar parâmetros de indicadores técnicos, como visto em Fernández-Blanco et al. (2008), Bodas-Sagi et al. (2009), Fayek, El-Boghdadi e Omran (2013) e Almeida, Reynoso-Meza e Steiner (2016). Brasileiro et al. (2013) desenvolveram um sistema de negociação utilizando k-vizinhos mais próximos (kNN), um indicador de análise técnica e otimização por colônia de abelhas artificiais. Grande parte dos trabalhos seleciona uma ação ou índice a priori para aplicação de determinado método. No entanto, selecionar a ação a ser negociada já é um problema em si, visto que cada mercado possui várias ações e escolher entre elas não é uma tarefa trivial. Para tal, métodos de tomada de decisão multicritérios podem ser utilizados. Eles têm sido aplicados com êxito para seleção de alternativas em diversos tipos de aplicações, tais como: avaliação de preços de imóveis (KROHLING; SOUZA, 2011), seleção de fornecedores (JADIDI; FIROUZI; BAGLIERY, 2010; DESWAL; GARG, 2015), planejamento energético (LØKEN, 2007), entre outros. Uma técnica muito utilizada é o TOPSIS (do inglês: *Technique for Order Preference by Similarity to Ideal Solution*), o qual avalia o desempenho das alternativas com base na similaridade com a solução ideal (HWANG; YOON, 1981).

Métodos de tomada de decisão multicritérios necessitam, como o próprio nome já diz, de critérios, ou seja, de algumas medidas de avaliação das alternativas. Para seleção de ações no mercado acionário, a maioria dos trabalhos utiliza critérios fundamentalistas, ou seja, métricas baseadas nos balanços financeiros das empresas. Kim, Jung e Cho (2009) aplicaram o TOPSIS para seleção de ativos no mercado acionário coreano. Bulgurcu (2012) utilizou o TOPSIS para avaliar companhias de tecnologia do mercado acionário de Istambul. Janani, Ehsanifar e Bakhtiarnezhad (2012) utilizaram uma variação do TOPSIS

para formação de carteira de investimento e ranqueamento de ações para o mercado acionário de Teerã. Saleh e Kimiagari (2017) utilizaram *fuzzy* TOPSIS para ranquear as ações do mesmo mercado. Para o mercado brasileiro, Costa e Junior (2013) realizaram uma pré-seleção de ações usando o TOPSIS tendo como critérios: índices financeiros, uma medida de risco e um parâmetro qualitativo de governança corporativa das empresas. Todos os trabalhos citados acima se basearam em critérios fundamentalistas.

1.2 Motivação

Como mencionado anteriormente, a maioria dos trabalhos que utilizam métodos de tomada de decisão multicritérios para realizar a seleção de ações se baseiam na análise fundamentalista. Entretanto, a análise fundamentalista é mais indicada para investidores de longo prazo, pois os balanços financeiros das empresas só são divulgados de tempos em tempos (intervalo de alguns meses). Investidores de curto prazo normalmente utilizam a análise técnica. A análise técnica consiste em analisar o comportamento de uma ação do mercado financeiro através do uso de gráficos e indicadores, com o propósito de prever a futura tendência dos preços (MURPHY, 1999). A análise técnica é comumente utilizada por meio de indicadores técnicos, os quais são calculados sobre o histórico de preços. A vantagem dessa análise é que os preços estão disponíveis a qualquer momento e, consequentemente, os indicadores também.

Assim, para investimentos de curto prazo, a combinação de um método de tomada de decisão multicritérios como o TOPSIS e critérios provindos da análise técnica pode ser mais adequada. No entanto, a técnica TOPSIS apenas ranqueia as ações mais aptas para se investir. Porém, há dias em que a maioria das ações tem queda de preço, sendo muito provável assim, que a escolha do TOPSIS esteja incorreta naquele dia. Dessa forma, utilizar outra técnica em conjunto pode aumentar a confiabilidade do investimento, ou seja, da realização da compra ou não de determinada ação.

Metodologias combinando técnicas de decomposição de séries temporais e redes neurais artificiais têm tido sucesso em aplicações como: previsão da velocidade do vento (GUO et al., 2012), fluxo de passageiros do metrô (WEI; CHEN, 2012), energia solar (MAJUMDER; BEHERA; NAYAK, 2017), conversão de moedas (DAS; BISOI; DASH, 2018), entre outras. A combinação específica entre decomposição de modo empírico (do inglês: *empirical mode decomposition*, abreviado por EMD) e máquina de aprendizado extremo (do inglês: *extreme learning machine*, abreviado por ELM) é utilizada em Lian et al. (2013), Majumder, Behera e Nayak (2017) e Das, Bisoi e Dash (2018).

Assim, a técnica decomposição de modo empírico pode ser utilizada para realizar a decomposição da série de preços da ação selecionada pelo TOPSIS e extrair a componente de tendência. A seguir, a máquina de aprendizado extremo pode ser usada para realizar a

predição da tendência, ou seja, se vai subir ou cair. Com isso, há uma confirmação (ou não) de que a ação selecionada deve ser comprada.

Os indicadores da análise técnica também podem indicar pontos de compra ou venda de uma ação. Dessa forma, eles podem ser utilizados como uma segunda confirmação para a compra da ação.

1.3 Objetivos

O objetivo geral deste trabalho é construir um método capaz de analisar várias ações ao mesmo tempo e decidir qual ação deve ser comprada no final do dia. A ação comprada é vendida no final do dia seguinte. Além disso, o método deve ser construído de forma a ser aplicável no mundo real.

Com base nisso, o primeiro objetivo desse trabalho é realizar a seleção de ações para compra a curto prazo. Para isso será investigado o uso de indicadores de análise técnica como critérios e a técnica TOPSIS para a tomada de decisão. A cada dia uma ação é selecionada para compra e vendida no dia seguinte.

O segundo objetivo é confirmar a compra da ação selecionada pelo TOPSIS, realizando a predição de tendência por meio da combinação de EMD e ELM.

Por último, o objetivo é analisar o uso de uma segunda confirmação para compra, por meio de regras de negociação baseadas na análise técnica.

1.4 Estrutura do trabalho

O restante do trabalho está dividido como segue. No capítulo 2 é definida a análise técnica e os indicadores utilizados no trabalho. No capítulo 3 são descritas as técnicas utilizadas no trabalho. No capítulo 4 é descrito o funcionamento do método híbrido de negociação de ações. No capítulo 5 são apresentados os resultados experimentais para o mercado acionário brasileiro e no capítulo 6 são expostas as conclusões e apontadas direções para trabalhos futuros.

1.5 Lista de publicações

As publicações geradas durante a elaboração deste trabalho estão listadas a seguir:

- Ebermam, Knidel e Krohling (2018): é proposto a utilização da técnica TOPSIS para seleção de ações na bolsa de valores brasileira, tendo como critérios indicadores da análise técnica. Este artigo apresenta os resultados da primeira parte do método híbrido usado neste trabalho.

- Ebermam et al. (2018): é feita uma comparação entre metodologias que combinam EMD e redes neurais artificiais para predição de séries temporais. Uma das combinações utilizada nesse artigo é a do EMD com ELM, a qual também foi utilizada nesta dissertação como a segunda parte do método híbrido.

2 Análise Técnica

A análise técnica consiste na análise do comportamento de uma ação do mercado financeiro, com o propósito de prever a futura tendência dos preços (MURPHY, 1999). Os indicadores técnicos são calculados usando a série histórica de preços e de volume. Há diversos tipos de indicadores, sendo que alguns são seguidores de tendência, outros são osciladores de preços, de análise de volume, de momento, entre outros.

2.1 Índice de Força Relativa (RSI)

2.1.1 Definição

O RSI é um indicador formulado por Wilder (1978). Ele mede a relação entre forças compradoras e vendedoras do mercado para um determinado ativo. É calculado por:

$$RSI_t = 100 - \frac{100}{1 + RS_t} \tag{2.1}$$

onde RS_t é a força relativa, calculado por:

$$RS_t = \frac{media(\Delta_{pos}, n)}{media(\Delta_{neg}, n)} \tag{2.2}$$

onde $media(\Delta_{pos}, n)$ é a média das variações positivas (quando o preço do dia i for maior do que o preço do dia $i - 1$) dos últimos n períodos, e $media(\Delta_{neg}, n)$ é a média das variações negativas (quando o preço do dia i for menor do que o preço do dia $i - 1$) dos últimos n períodos.

O indicador, no geral, é usado para definir áreas de sobrecompra e sobrevenda. Quando o indicador está abaixo de um limite (normalmente 30), pode-se interpretar que o preço do ativo se encontra em uma zona de sobrevenda, ou seja, a força vendedora está perdendo força e isso pode ser um sinal que o preço irá subir. Acima do limite superior (normalmente 70) o preço está na zona de sobrecompra, indicando que a força compradora está perdendo força, sendo provável que o preço comece a cair.

2.1.2 Regra de negociação

O indicador pode ser utilizado de diferentes formas. Normalmente quando o indicador intercepta algum dos limites, é gerado ou um sinal de compra ou de venda. A regra de negociação para o RSI é mostrada na Tabela 1.

Caso o valor do indicador intercepte o limite inferior de baixo para cima, é gerado um sinal de compra. Caso intercepte o limite superior de cima para baixo, é gerado um

Tabela 1 – Regra RSI

Condição	Sinal
se $RSI_{t-1} < 30$ e $RSI_t > 30$	compra
se $RSI_{t-1} > 70$ e $RSI_t < 70$	venda
nenhuma das condições acima	neutro

sinal de venda. Caso não haja interceptação, nenhuma decisão é sinalizada, ou seja, o sinal é neutro.

2.2 Oscilador estocástico

2.2.1 Definição

O oscilador estocástico é um indicador de momento desenvolvido por George Lane (TREUHERZ, 2008). Ele pode ser interpretado de forma similar ao RSI, porém os limites mais utilizados são 20 e 80. Esse indicador é formado por duas linhas: $\%K$ e $\%D$. A linha $\%K$ é calculada por:

$$\%K_t = \frac{C_t - min(L_t, \ldots, L_{t-n})}{max(H_t, \ldots, H_{t-n}) - min(L_t, \ldots, L_{t-n})} \cdot 100 \tag{2.3}$$

onde C_t é o preço de fechamento do dia t, L_t e H_t são, respectivamente, o preço mínimo e máximo do dia t e n é o número de períodos utilizados.

Já a linha $\%D$ é uma média móvel da linha $\%K$, calculado por:

$$\%D_t = \frac{\sum_{i=0}^{n-1} \%K_{t-i}}{n} \tag{2.4}$$

2.2.2 Regra de negociação

As regras de negociação para as linhas $\%K$ e $\%D$ são semelhantes ao RSI. A regra de negociação para a linha $\%K$, denominada 'regra K' é mostrada na Tabela 2.

Tabela 2 – Regra K

Condição	Sinal
se $\%K_{t-1} < 20$ e $\%K_t > 20$	compra
se $\%K_{t-1} > 80$ e $\%K_t < 80$	venda
nenhuma das condições acima	neutro

A regra de negociação para a linha %D, denominada 'regra D' é mostrada na Tabela 3.

Outra interpretação possível para o indicador está no cruzamentos das duas linhas. A regra para o cruzamento da linhas, denominada 'regra KD' é mostrada na Tabela 4.

Tabela 3 – Regra D

Condição	Sinal
se $\%D_{t-1} < 20$ e $\%D_t > 20$	compra
se $\%D_{t-1} > 80$ e $\%D_t < 80$	venda
nenhuma das condições acima	neutro

Tabela 4 – Regra KD

Condição	Sinal
se $\%K_{t-1} < \%D_{t-1}$ e $\%K_t > \%D_t$	compra
se $\%K_{t-1} > \%D_{t-1}$ e $\%K_t < \%D_t$	venda
nenhuma das condições acima	neutro

Quando a linha $\%K$ cruza $\%D$ para cima é um sinal de compra, caso contrário é um sinal de venda. Caso não haja cruzamento das linhas, o sinal permanece neutro.

2.3 Índice de Canal de Commodities (CCI)

2.3.1 Definição

O CCI é um indicador desenvolvido por Donald R. Lambert, o qual compara o preço atual com uma média móvel de determinado período e então normaliza o oscilador usando um divisor baseado no desvio médio (MURPHY, 1999). O indicador é calculado por:

$$CCI_t = \frac{P_t - media(P, n)}{0.015 \cdot DMA(P)} \tag{2.5}$$

onde P_t é o preço típico do dia t, $media(P, n)$ é a média dos preços típicos dos últimos n dias e $DMA(P)$ é o desvio médio absoluto dos preços típicos dos últimos n dias.

O preço típico é calculado por:

$$P_t = \frac{C_t + L_t + H_t}{3} \tag{2.6}$$

2.3.2 Regra de negociação

A regra de negociação para o indicador, denominada 'regra CCI' é mostrada na Tabela 5.

Um sinal de compra é dado quando o indicador cruza de baixo para cima o nível de 100 ou -100. O sinal de venda se dá quando o indicador intercepta esses mesmos níveis, porém de cima para baixo.

Tabela 5 – Regra CCI

Condição	Sinal
se $(CCI_{t-1} < -100$ e $CCI_t > -100)$ ou $(CCI_{t-1} < 100$ e $CCI_t > 100)$	compra
se $(CCI_{t-1} > -100$ e $CCI_t < -100)$ ou $(CCI_{t-1} > 100$ e $CCI_t < 100)$	venda
nenhuma das condições acima	neutro

2.4 Bandas de Bollinger (BB)

2.4.1 Definição

As Bandas de Bollinger são bandas contidas em torno do preço em um gráfico (BOLLINGER, 2001). Elas foram criadas por John Bollinger na década de 1980. A principal caraterística desse indicador é que ele leva em consideração a volatilidade dos preços. O indicador é formado por três linhas: linha central, banda superior e banda inferior. Elas são calculadas por:

$$\text{linha central} = \textit{média}(C, n) \tag{2.7}$$

$$\text{banda superior} = \textit{média}(C, n) + 2 \cdot \sigma(C) \tag{2.8}$$

$$\text{banda inferior} = \textit{média}(C, n) - 2 \cdot \sigma(C) \tag{2.9}$$

onde a linha central é simplesmente uma média móvel (normalmente de 20 dias) do preço, e as duas bandas são obtidas somando ou subtraindo o desvio padrão do preço (no mesmo período).

A Figura 1 ilustra as Bandas de Bollinger para o caso da ação Petrobras (PETR4) durante o ano de 2016.

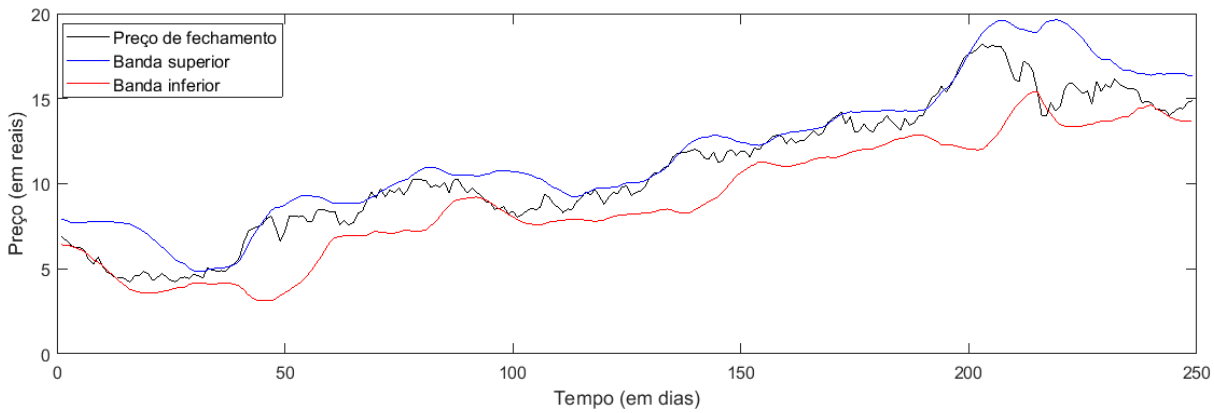

Figura 1 – Indicador Bandas de Bollinger aplicado sobre a ação da empresa Petrobras (PETR4) durante o ano 2016

2.4.2 Regra de negociação

A regra de negociação para o indicador, denominada 'regra BB' é mostrada na Tabela 6.

Tabela 6 – Regra BB

Condição	Sinal
se $C_{t-1} < banda - inferior_{t-1}$ e $C_t > banda - inferior_t$	compra
se $C_{t-1} > banda - superior_{t-1}$ e $C_t > banda - superior_t$	venda
nenhuma das condições acima	neutro

Os sinais de negociação acontecem na fuga do preço em relação as bandas. Quando o preço cruza de baixo para cima a banda inferior, é dado um sinal de compra. Quando o preço intercepta de cima para baixo a banda superior, o sinal é de venda. Em outros casos, o sinal é neutro.

3 Algoritmos utilizados

3.1 Técnica para preferência de ordem por similaridade à solução ideal (TOPSIS)

A técnica TOPSIS recebe como entrada uma matriz formada pelas alternativas e critérios. Considere a matriz de decisão A:

$$A = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & \dots & \dots & x_{mn} \end{bmatrix} \tag{3.1}$$

onde cada linha é uma alternativa, cada coluna é um critério e x_{ij} é o desempenho da alternativa i de acordo com o critério j.

Como os critérios podem não ser necessariamente da mesma escala, é preciso normalizá-los. Os métodos de normalização mais conhecidos são: normalização vetorial, transformação em escala linear (máximo-mínimo), transformação em escala linear (máximo) e transformação em escala linear (soma) (ÇELEN, 2014). As fórmulas são descritas pelas equações 3.2, 3.3, 3.4 e 3.5 respectivamente.

$$q_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^{m} x_{ij}^2}} \tag{3.2}$$

$$q_{ij} = \frac{x_{ij} - x_j^{min}}{x_j^{max} - x_j^{min}} \tag{3.3}$$

$$q_{ij} = \frac{x_{ij}}{x_j^{max}} \tag{3.4}$$

$$q_{ij} = \frac{x_{ij}}{\sum_{i=1}^{m} x_{ij}} \tag{3.5}$$

onde q_{ij} é o elemento normalizado da matriz Q.

Alguns critérios podem ser mais importantes que outros para tomada de decisão, por isso eles precisam ser ponderados por pesos w_j. Esses pesos devem ser definidos tal que:

$$\sum_{j=1}^{n} w_j = 1 \tag{3.6}$$

Definidos os pesos de cada critério, é preciso ponderar cada coluna da matriz pelo respectivo peso do critério, conforme:

$$v_{ij} = q_{ij} \cdot w_j \tag{3.7}$$

onde v_{ij} é um elemento da matriz ponderada V.

Antes de aplicar o TOPSIS é preciso especificar qual o tipo de cada critério. Existem dois tipos de critérios: custo e benefício. O critério do tipo custo, indica que quanto menor o valor, mais adequado será. De outra forma, o critério do tipo benefício indica que quanto maior o seu valor, mais apto será.

O primeiro passo do TOPSIS é calcular a solução ideal positiva e a solução ideal negativa dado pelas equações 3.8, 3.9, 3.10 e 3.11.

$$v^+ = (v_1^+, v_2^+, \ldots, v_n^+) \tag{3.8}$$

$$v^- = (v_1^-, v_2^-, \ldots, v_n^-) \tag{3.9}$$

onde:

$$v_j^+ = \begin{cases} \max(v_{ij}), i = 1, 2, \ldots, m & \text{se critério é beneficio} \\ \min(v_{ij}), i = 1, 2, \ldots, m & \text{se critério é custo} \end{cases} \tag{3.10}$$

$$v_j^- = \begin{cases} \min(v_{ij}), i = 1, 2, \ldots, m & \text{se critério é beneficio} \\ \max(v_{ij}), i = 1, 2, \ldots, m & \text{se critério é custo} \end{cases} \tag{3.11}$$

O segundo passo é calcular a distância Euclidiana de cada alternativa para cada critério em relação à solução ideal positiva e à solução ideal negativa conforme as equações 3.12 e 3.13.

$$d_i^+ = \sqrt{\sum_{j=1}^{n} (v_j^+ - v_{ij})^2} \tag{3.12}$$

$$d_i^- = \sqrt{\sum_{j=1}^{n} (v_j^- - v_{ij})^2} \tag{3.13}$$

onde d_i^+ é a distância positiva da alternativa i e d_i^- é a distância negativa da alternativa i.

O terceiro passo é calcular o coeficiente de proximidade relativa ξ para cada alternativa, conforme:

$$\xi_i = \frac{d_i^-}{d_i^- + d_i^+} \tag{3.14}$$

A seguir, ordenam-se as alternativas em relação aos seus valores de ξ_i; quanto maior o valor mais apta é a alternativa.

Neste trabalho, para a melhor alternativa (no caso uma ação), é feita a predição da tendência da mesma para aumentar a confiabilidade da seleção. A decomposição de modo empírico (EMD) se mostra promissora para a extração da componente de tendência.

3.2 Decomposição de Modo Empírico (EMD)

A decomposição de modo empírico é uma técnica de análise de dados proposta por Huang et al. (1998). A decomposição é baseada na extração direta de energia associada a várias escalas de tempo intrínsecas (HUANG et al., 1998). Cada sub-série gerada pela decomposição é chamada de função de modo intrínseca (do inglês: *Intrinsic Mode Function*, abreviada por IMF), sendo a última denominada como resíduo.

Uma IMF é uma função que deve satisfazer duas condições: (1) em todo conjunto de dados, o número de extremos e o número de cruzamentos em zero, devem ser iguais ou diferirem no máximo em um; e (2) em qualquer ponto, o valor médio do envelope, definido pelos máximos e mínimos locais, deve ser zero (HUANG et al., 1998).

O método de decomposição consiste, primeiramente, em identificar todos máximos e mínimos locais de uma série temporal X. Após isso, os pontos de máximo locais são conectados por meio de uma interpolação cúbica, formando o envelope superior u. Da mesma forma, conectando os mínimos locais é formado o envelope inferior l. Uma nova série temporal m_1 é formada pela média dos dois envelopes: $(u + l)/2$. Subtraindo essa série da série original, tem-se a primeira componente (h_1), conforme:

$$h_1 = X - m_1 \tag{3.15}$$

No entanto, essa componente precisa satisfazer as duas condições da IMF para se tornar uma. Se esse fato não ocorrer, o processo é feito novamente, porém, desta vez, a série h_1 é tratada como a série original. Dessa forma, os envelopes são calculados a partir de h_1, e é feita a média entre eles (m_{11}). Uma nova componente h_{11} é então calculada conforme:

$$h_{11} = h_1 - m_{11} \tag{3.16}$$

Novamente é verificado se essa componente atende as condições de uma IMF. Se não atender, o processo é repetido novamente. Esse processo é repetido k vezes, até que

uma IMF seja obtida:

$$h_{1k} = h_{1(k-1)} - m_{1k} \tag{3.17}$$

Assim, h_{1k} se torna a primeira IMF (c_1) da série:

$$c_1 = h_{1k} \tag{3.18}$$

O restante da série é chamado de resíduo (r), calculado conforme:

$$r_1 = X - c_1 \tag{3.19}$$

A partir do resíduo gerado pela subtração da primeira componente (r_1), é calculada a segunda componente (c_2), ou seja, é aplicado o mesmo procedimento, porém, o resíduo é tratado como a série original. O processo é repetido n vezes, até que mais nenhuma IMF possa ser extraída, ou seja, quando o valor da componente ou do resíduo é muito pequeno ou quando o resíduo é uma função monotônica. Assim a série pode ser reconstruída por:

$$X = \sum_{i=1}^{n} c_i + r_n \tag{3.20}$$

onde n é o número de IMFs geradas e r_n é o resíduo final da série.

A Figura 2 ilustra a decomposição de uma série temporal feita pelo EMD. No topo da Figura 2 está a série original, a qual é seguida pela primeira, segunda, terceira e quarta IMF e por último o resíduo.

Haja visto que se tem várias componentes da série decomposta, será utilizada uma rede neural artificial para a predição da componente de tendência (nesse caso, o resíduo da série).

3.3 Máquina de aprendizado extremo (ELM)

A máquina de aprendizado extremo (do inglês: *extreme learning machine*, abreviado por ELM) é um algoritmo de aprendizagem para redes neurais artificiais com uma única camada escondida (HUANG; ZHU; SIEW, 2004). Uma rede neural artificial é uma estrutura de processamento de informações paralela e distribuída que consiste em processar elementos interconectados por meio de sinais unidirecionais chamados conexões (HECHT-NIELSEN et al., 1988). Elas são formadas pela conexão de vários processadores simples, chamados de neurônios artificiais, cada um produzindo uma sequência de ativações de valores reais (SCHMIDHUBER, 2015).

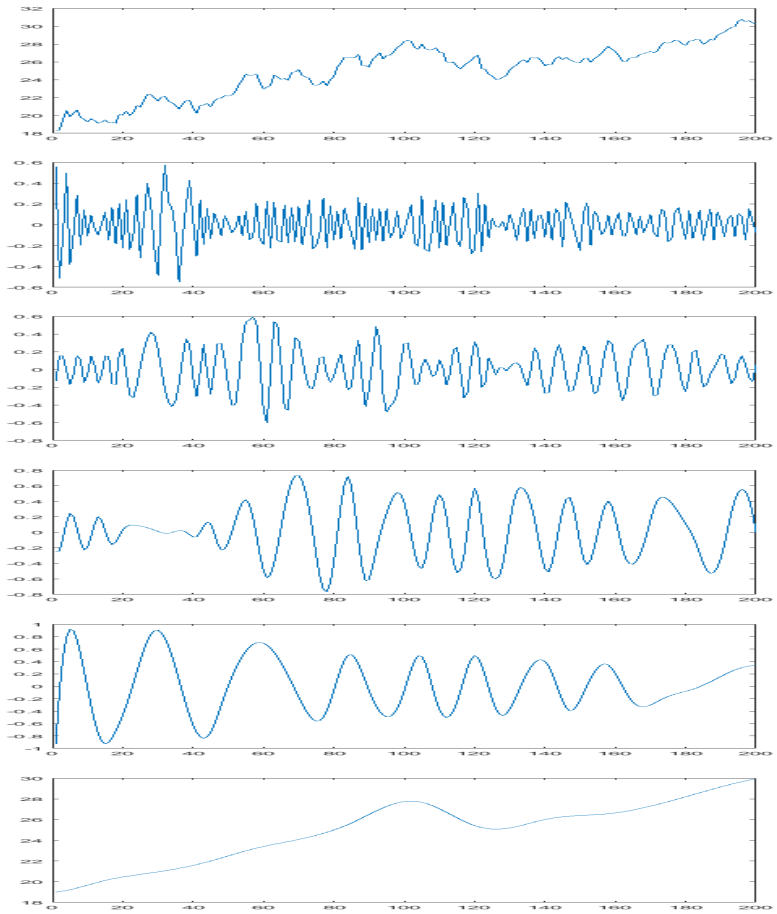

Figura 2 – Decomposição de série temporal feita pelo EMD

O neurônio artificial é a unidade básica de processamento dessas redes. Ele recebe sinais de entrada x_i, os quais se propagam por meio de canais chamados conexões. Cada conexão tem um determinado valor, chamado de peso w_i, e ele pondera as entradas $(x_i \cdot w_i)$. As entradas ponderadas são somadas e é adicionado a essa soma um deslocamento linear, conhecido como *bias* (b), gerando assim um único sinal (u). Esse sinal passa por uma função de ativação $f(u)$, resultando assim na saída do neurônio (y). A Figura 3 ilustra um neurônio artificial.

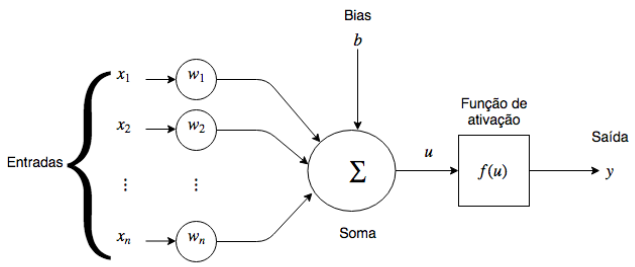

Figura 3 – Neurônio artificial

A função de ativação confere às redes neurais a capacidade de resolver problemas não-lineares (no caso de funções de ativação não-lineares). As mais utilizadas são: sigmoidal

logística, tangente hiperbólica e unidade linear retificada (do inglês: *Rectified Linear Unit*, abreviada por ReLU). Elas são calculadas pelas Equações 3.21, 3.22 e 3.23 respectivamente.

$$f(u) = \frac{1}{1 + e^{-u}} \tag{3.21}$$

$$f(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \tag{3.22}$$

$$f(u) = max(0, u) \tag{3.23}$$

Os neurônios se conectam entre si e assim formam uma rede neural artificial. Normalmente eles são agrupados em camadas. A primeira camada é a camada de entrada, onde não ocorre nenhum tipo de processamento, apenas a transmissão dos sinais de entrada. As camadas seguintes, com exceção da última, são chamadas de camadas escondidas (podendo ser uma ou mais camadas) e são responsáveis pelo processamento dos sinais. A última camada, tem por objetivo, apresentar a resposta da rede para o problema em questão. Na Figura 4 é mostrada a arquitetura de uma rede neural com uma única camada escondida.

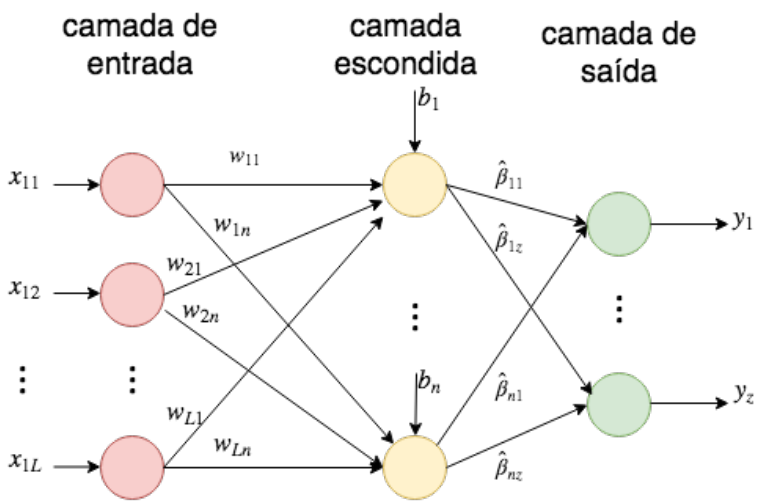

Figura 4 – Exemplo de arquitetura de uma rede neural

Na ELM, há apenas uma camada escondida (além das camadas de entrada e de saída). Sua principal diferença para outras redes neurais, é que o treinamento ocorre de forma determinística. Os pesos entre a camada inicial e a camada escondida, assim como os *bias*, são inicializados de forma aleatória. Os pesos entre a camada escondida e a camada de saída são determinados de forma analítica.

O primeiro passo do algoritmo ELM é a construção da matriz H, que é a matriz resultante da saída dos neurônios da camada escondida para cada uma das amostras de

entrada, conforme:

$$H = \begin{bmatrix} f(x_1 w_1 + b_i) & \dots & f(x_1 w_n + b_m) \\ \vdots & \ddots & \vdots \\ f(x_m w_1 + b_i) & \dots & f(x_m w_n + b_n) \end{bmatrix} \tag{3.24}$$

onde cada linha corresponde a uma amostra e cada coluna representa um neurônio da camada escondida, m é a quantidade de amostras de entrada e n é a quantidade de neurônios na camada escondida. Nesse caso, x_i é uma amostra composta por um vetor de atributos e w_i é um vetor de pesos de um neurônio.

O segundo passo consiste em calcular a matriz de pesos entre a camada escondida e a camada de saída, denominada $\hat{\beta}$. Ela é calculada como a solução dos mínimos quadrados para o sistema linear $H\hat{\beta} = T$, sendo $\hat{\beta} = H^{\dagger}T$, onde $H^{\dagger}$ é a inversa generalizada de Moore-Penrose da matriz H e T é o vetor de respostas para as amostras de entrada (HUANG; ZHU; SIEW, 2004; HUANG; ZHU; SIEW, 2006).

O pseudo-código do treinamento da ELM é apresentado no algoritmo 1.

Algoritmo 1 Treinamento ELM

1: **Inicialização**:
2: Preparar amostras de entrada
3: Inicializar pesos e bias entre a primeira e segunda camada com valores aleatórios
4: Definir número de neurônios da camada escondida
5: Calcular matriz H, conforme 3.24
6: Calcular $\hat{\beta}$ conforme: $\hat{\beta} = H^{\dagger}T$

A seguir, será apresentado um exemplo para o treinamento usando ELM.

Considere o problema da porta lógica AND onde há dois tipos de entrada: 1 (passagem de corrente elétrica) e 0 (sem passagem de corrente elétrica). A porta lógica recebe duas entradas e retorna uma resposta: 0&0 = 0, 0&1 = 0, 1&0 = 0 e 1&1 = 1. Assim, X e T são definidos conforme:

$$X = \begin{bmatrix} 0 & 0 \\ 0 & 1 \\ 1 & 0 \\ 1 & 1 \end{bmatrix}, \quad T = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} \tag{3.25}$$

Considere também que a ELM tenha dois neurônios na camada escondida com função de ativação sigmoidal logística, e que os pesos W e os *bias* B foram definidos

aleatoriamente conforme:

$$W = \begin{bmatrix} 0.2 & 0.5 \\ 0.6 & 1 \end{bmatrix}, \quad B = \begin{bmatrix} -0.5 & 0.5 \end{bmatrix} \tag{3.26}$$

Assim $\hat{\beta}$ é calculado conforme:

$$\begin{aligned}
\hat{\beta} =& H^{\dagger}T \\
\hat{\beta} =& (f(XW+B))^{\dagger}T \\
\hat{\beta} =& \begin{bmatrix} f(x_{11}\cdot w_{11}+x_{12}\cdot w_{21}+b_1) & f(x_{11}\cdot w_{21}+x_{12}\cdot w_{22}+b_2) \\ f(x_{21}\cdot w_{11}+x_{22}\cdot w_{21}+b_1) & f(x_{21}\cdot w_{21}+x_{22}\cdot w_{22}+b_2) \\ f(x_{31}\cdot w_{11}+x_{32}\cdot w_{21}+b_1) & f(x_{31}\cdot w_{21}+x_{32}\cdot w_{22}+b_2) \\ f(x_{41}\cdot w_{11}+x_{42}\cdot w_{21}+b_1) & f(x_{41}\cdot w_{21}+x_{42}\cdot w_{22}+b_2) \end{bmatrix}^{\dagger} T \\
=& \begin{bmatrix} f(0\cdot 0.2+0\cdot 0.6+(-0.5)) & f(0\cdot 0.5+0\cdot 1+0.5) \\ f(0\cdot 0.2+1\cdot 0.6+(-0.5)) & f(0\cdot 0.5+1\cdot 1+0.5) \\ f(1\cdot 0.2+0\cdot 0.6+(-0.5)) & f(1\cdot 0.5+0\cdot 1+0.5) \\ f(1\cdot 0.2+1\cdot 0.6+(-0.5)) & f(1\cdot 0.5+1\cdot 1+0.5) \end{bmatrix}^{\dagger} T \\
=& \begin{bmatrix} f(-0.5) & f(0.5) \\ f(0.1) & f(1.5) \\ f(-0.3) & f(1) \\ f(0.3) & f(2) \end{bmatrix}^{\dagger} T \\
=& \begin{bmatrix} \frac{1}{1+e^{-(-0.5)}} & \frac{1}{1+e^{-0.5}} \\ \frac{1}{1+e^{-0.1}} & \frac{1}{1+e^{-1.5}} \\ \frac{1}{1+e^{-(-0.3)}} & \frac{1}{1+e^{-1}} \\ \frac{1}{1+e^{-0.3}} & \frac{1}{1+e^{-2}} \end{bmatrix}^{\dagger} T \\
=& \begin{bmatrix} 0.38 & 0.62 \\ 0.53 & 0.82 \\ 0.43 & 0.73 \\ 0.57 & 0.88 \end{bmatrix}^{\dagger} T \\
=& \begin{bmatrix} -6.4520 & 6.9861 & -17.0639 & 12.2380 \\ 4.3023 & -4.0280 & 10.9916 & -7.2892 \end{bmatrix} T \\
=& \begin{bmatrix} -6.4520 & 6.9861 & -17.0639 & 12.2380 \\ 4.3023 & -4.0280 & 10.9916 & -7.2892 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} \\
=& \begin{bmatrix} 12.2380 \\ -7.2892 \end{bmatrix}
\end{aligned} \tag{3.27}$$

O cálculo da inversa generalizada é um pouco mais complexo, porém a maioria das linguagens de programação tem bibliotecas para o cálculo da mesma. Uma vez obtido a matriz $\hat{\beta}$, a saída y da ELM para uma amostra de teste Z é dada conforme:

$$y = f(ZW + B) * \hat{\beta} \tag{3.28}$$

4 Método híbrido para negociação de ações

4.1 Introdução

Para decidir qual ação comprar e em que momento ela deve ser comprada, foi desenvolvida uma metodologia combinando várias técnicas. Esse método híbrido foi construído de forma incremental, ou seja, adicionando novas técnicas para confirmação da tomada de decisão. Ele é composto por TOPSIS, EMD, ELM e regras de negociação provindas de indicadores técnicos.

Na primeira parte, é feita a seleção de ações. A técnica TOPSIS é utilizada para selecionar a ação mais apta para compra, dentre um conjunto de ações. Nesse conjunto, estão contidas apenas ações com grande volume de negociação e que geralmente fazem parte do índice Bovespa. Assim, a cada dia uma ação é comprada e vendida no dia seguinte.

Na segunda parte, a ação selecionada pelo TOPSIS passa por uma confirmação para que a compra seja realizada. Para isso o modelo híbrido composto por EMD e ELM classifica a tendência de preço da ação em alta ou baixa. Se a tendência é de alta, então a compra é realizada, caso contrário é recusada.

Na terceira parte, uma segunda confirmação para compra é realizada. Nesse caso, são utilizados os indicadores técnicos. Muitos desses indicadores, sinalizam pontos de compra e de venda. Assim, se na ação selecionada pelo TOPSIS e confirmada pelo EMD-ELM, o indicador sinalizar compra, então ela é realizada. Serão testadas regras de negociação de um indicador individualmente e a combinação de dois deles.

4.2 Seleção de ação para compra através do TOPSIS

Para a seleção de ações, primeiramente são coletados os valores históricos dos preços e volume das ações, e a partir desses dados, são calculados os indicadores técnicos para cada ação no dia t. Logo após, é formada a matriz de entrada com as alternativas e os critérios para o método de tomada de decisão. As alternativas são as ações, e os critérios são os indicadores técnicos. Dessa forma, a matriz de entrada tem dimensão (*número de ações*) por (*número de critérios*).

Os critérios utilizados foram os indicadores RSI de 14 dias, linha %K do estocástico de 14 dias, linha %D do estocástico de 3 dias e CCI de 14 dias. O número de dias escolhido para cada indicador são valores padrão. Todos os critérios foram definidos como sendo critérios de custo. O peso de cada critério foi definido como uniforme, ou seja, igual para todos.

A técnica TOPSIS é aplicada sobre a matriz, a fim de realizar o ranqueamento das ações. A melhor ação ranqueada é selecionada e avança-se para o dia seguinte $(t + 1)$. Então é verificado se o preço dela aumentou ou diminuiu e qual o valor dessa variação. A partir de então, o processo é repetido várias vezes.

É importante destacar que, selecionar uma ação com o TOPSIS, também significa lidar com o comportamento dinâmico e estocástico das séries temporais financeiras. Elas, ainda que sejam processadas pelos indicadores técnicos, são as informações de entrada para o TOPSIS.

A metodologia para seleção de ações baseado no TOPSIS utilizando critérios da análise técnica está ilustrada na Figura 5.

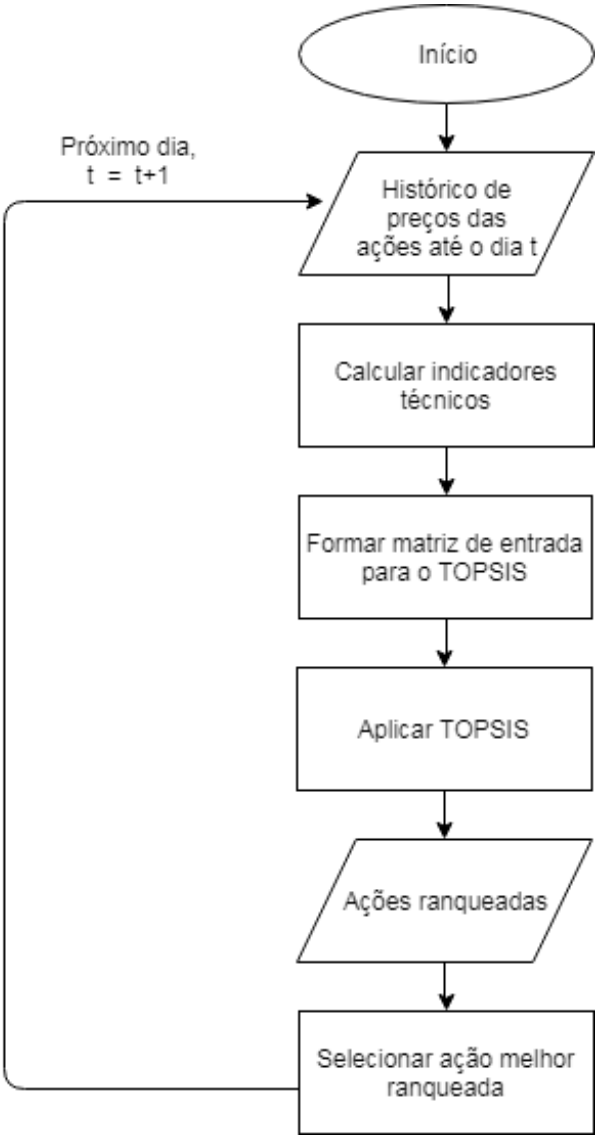

Figura 5 – Metodologia baseada no TOPSIS usando indicadores da análise técnica

Para efeitos de negociação, a seleção da ação é feita ao final do dia, ou seja, é comprada pelo preço de fechamento. A venda da ação ocorre no final do dia seguinte e

uma outra ação é então comprada.

Por exemplo, suponha que o TOPSIS seja aplicado para selecionar uma ação num conjunto de dez ações em um determinado dia. Os dados das ações são coletados e os indicadores técnicos são calculados, formando a matriz de decisão, como mostrado na Tabela 7.

Tabela 7 – Exemplo de formação da matriz de decisão para aplicação do TOPSIS para seleção de ações

Alternativas/critérios	RSI	Estocástico K	Estocástico D	CCI
Ação A	37.46	7.43	9.13	-86.35
Ação B	7.58	3.48	2.33	-166.79
Ação C	17.65	5.41	4.27	-150.15
Ação D	29.47	14.29	13.08	-105.43
Ação E	49.13	10.80	19.73	-65.99
Ação F	20.93	8.62	6.12	-97.30
Ação G	14.00	4.80	4.12	-106.82
Ação H	17.71	1.09	2.71	-194.24
Ação I	26.38	4.52	6.57	-98.28
Ação J	20.16	4.16	3.40	-154.57

Com base nos dados fornecidos, o TOPSIS realiza o ranqueamento das ações como mostrado na Tabela 8.

Tabela 8 – Exemplo da aplicação do TOPSIS para seleção de ações

Alternativa	Valor de ξ	Posição
Ação A	0.4049	8
Ação B	0.8660	2
Ação C	0.7336	4
Ação D	0.3179	9
Ação E	0.1231	10
Ação F	0.5285	7
Ação G	0.6578	5
Ação H	0.8847	1
Ação I	0.5632	6
Ação J	0.7590	3

Dessa forma, ao final do primeiro dia, a ação 'H' será comprada. No dia seguinte, ao final do dia, ela será vendida e com base em novos dados o TOPSIS irá selecionar outra ação para compra, repetindo assim o processo.

4.3 Classificação de tendência com EMD-ELM

O modelo híbrido EMD-ELM consiste na decomposição da série de preços por meio do EMD e a predição da tendência do preço pela rede neural ELM. Neste trabalho, é utilizado apenas a principal componente extraída pelo EMD como entrada para a ELM.

As primeiras componentes extraídas pelo EMD são de frequências mais altas e também mais ruidosas. Nesse trabalho, é proposto a utilização somente da última componente, o resíduo. Normalmente, para séries financeiras, essa componente é pouco ruidosa e contém o maior percentual do valor do preço. Além disso, ela contém a tendência do preço, ou seja, aponta a direção dos preços, ignorando pequenas variações.

Após o TOPSIS selecionar a ação para compra do dia, a série de preços históricos dessa ação é utilizada para aplicação do EMD. São utilizados p dias anteriores, sendo que o último elemento da série é o dia atual t. Dessa forma, é formada a série $S = [x_{t-p}, x_{t-p+1}, \ldots, x_t]$, onde x_i é o preço da ação em um determinado dia. A série é então normalizada entre 0 e 1, conforme:

$$S_i = \frac{S_i - min(S)}{max(S) - min(S)} \tag{4.1}$$

Ao aplicar o EMD sobre essa série, são geradas várias IMFs, sendo que a última é o resíduo, a qual será utilizada pelo ELM. A série de resíduos $[r_1, r_2, \cdots, r_n]$ é modelada para ser usada como entrada da rede neural, conforme Tabela 9.

Tabela 9 – Modelagem de série temporal

entradas				alvo
r_1	r_2	$\ldots$	$r_{1+(\mu-1)}$	$r_{1+\mu}$
r_2	r_3	$\ldots$	$r_{2+(\mu-1)}$	$r_{2+\mu}$
$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$r_{n-\mu}$	$r_{n-(\mu-1)}$	$\ldots$	r_{n-1}	r_n

Os dados da série temporal são processadas em μ colunas (número de atrasos) representando as entradas da rede e uma coluna que representa os valores esperados para a saída da rede neural. A rede neural é então treinada a partir da matriz de entradas. Os pesos são gerados aleatoriamente no intervalo de -1 a 1, e a função de ativação foi definida como sigmoidal logística. Assim, de acordo com o algoritmo ELM, a matriz $\hat{\beta}$ é calculada.

Tendo a rede neural já treinada, os dados de teste são informados à mesma: $[r_{n-(\mu-1)}, r_{n-(\mu-2)} \ldots r_n]$. A resposta da rede é uma expectativa do valor de r_{n+1}. O valor real de r_{n+1} não é conhecido, pois está no futuro. Além disso, ele também não pode ser conhecido no futuro, pois ao incluir o valor do preço do dia seguinte, a estrutura da série muda e aplicando o EMD novamente, IMFs diferentes são geradas. No entanto, o objetivo é descobrir se a tendência é de alta ou de baixa. Isso é feito comparando o último valor da componente (r_n) com a saída da rede neural (y), a qual é a predição para r_{n+1}, conforme 4.2:

$$tendência = \begin{cases} alta & \text{se } y > r_n \\ baixa & \text{se } y \leq r_n \end{cases} \tag{4.2}$$

Se a rede neural indicar um aumento de valor, então a compra da ação é confirmada, caso contrário, nenhuma ação é comprada. Naturalmente, isso reduz o número total de negociações realizadas.

O método composto pelo TOPSIS e EMD-ELM é ilustrado na Figura 6.

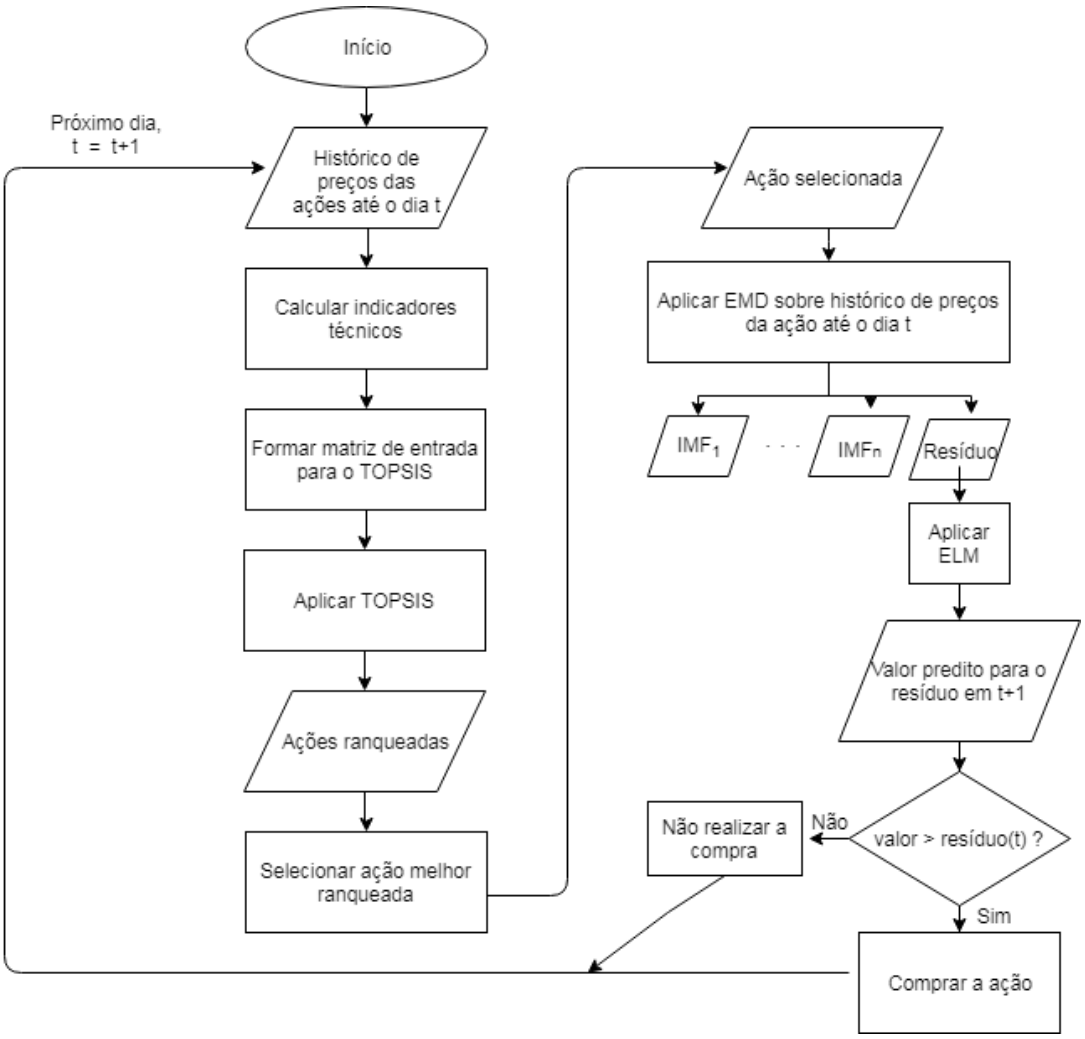

Figura 6 – Método combinando TOPSIS e EMD-ELM

Suponha que o TOPSIS tenha selecionado uma determinada ação e que é utilizada uma janela de 20 preços passados (totalizando 21 com o preço do dia), como mostrado na Tabela 10.

A série é primeiramente normalizada e então decomposta pelo EMD, conforme Tabela 11.

São geradas três componentes após a aplicação do EMD. A última componente é modelada como entrada para rede neural. A modelagem utilizando 6 atrasos é mostrada na Tabela 12.

Com bases nesses dados, a rede neural ELM é treinada. Então são apresentados os dados de teste para a ELM: [0.5720, 0.5844, 0.5952, 0.6036, 0.6096, 0.6134]. A rede

Tabela 10 – Serie temporal de uma ação selecionada pelo TOPSIS

Tempo	Preço	Tempo	Preço	Tempo	Preço
$t-20$	11.23	$t-13$	15.87	$t-6$	12.92
$t-19$	10.57	$t-12$	16.85	$t-5$	14.21
$t-18$	10.55	$t-11$	14.41	$t-4$	14.86
$t-17$	11.32	$t-10$	13.90	$t-3$	14.70
$t-16$	12.28	$t-9$	13.42	$t-2$	14.52
$t-15$	13.63	$t-8$	13.30	$t-1$	14.79
$t-14$	14.98	$t-7$	12.89	t	13.54

Tabela 11 – Aplicação do EMD sobre a série normalizada

Tempo	Preço normalizado	IMF1	IMF2	Resíduo
$t-20$	0.1079	-0.4825	-0.0694	0.6599
$t-19$	0.0032	-0.5781	-0.0576	0.6388
$t-18$	0	-0.5786	-0.0380	0.6167
$t-17$	0.1222	-0.4592	-0.0130	0.5944
$t-16$	0.2746	-0.3122	0.0136	0.5733
$t-15$	0.4889	-0.1029	0.0376	0.5543
$t-14$	0.7032	0.1099	0.0547	0.5386
$t-13$	0.8444	0.2563	0.0609	0.5272
$t-12$	1.0000	0.4267	0.0525	0.5208
$t-11$	0.6127	0.0652	0.0285	0.5190
$t-10$	0.5317	0.0150	-0.0044	0.5212
$t-9$	0.4556	-0.0336	-0.0378	0.5269
$t-8$	0.4365	-0.0359	-0.0632	0.5356
$t-7$	0.3714	-0.1031	-0.0721	0.5466
$t-6$	0.3762	-0.1256	-0.0572	0.5591
$t-5$	0.5810	0.0280	-0.0190	0.5720
$t-4$	0.6841	0.0677	0.0320	0.5844
$t-3$	0.6587	-0.0145	0.0780	0.5952
$t-2$	0.6302	-0.0524	0.0789	0.6036
$t-1$	0.6730	0.0555	0.0080	0.6096
t	0.4746	-0.0590	-0.0798	0.6134

neural gera uma saída como 0.6157 por exemplo. Como 0.6157 é maior que o último valor (0.6134), então a previsão da rede neural é de uma alta no valor da componente. Dessa forma, a compra da ação é feita pelo preço do momento (13.54 reais).

4.4 Confirmação de compra por meio de regras de negociação de indicadores técnicos

Uma segunda confirmação de compra é utilizada com o intuito de aumentar a confiabilidade da compra. Previamente também é sabido que isso reduzirá ainda mais o número de negociações. Para isso são utilizadas as regras de negociação dos indicadores

Tabela 12 – Série modelada como entrada para rede neural

entradas						alvo
0.6599	0.6388	0.6167	0.5944	0.5733	0.5543	0.5386
0.6388	0.6167	0.5944	0.5733	0.5543	0.5386	0.5272
0.6167	0.5944	0.5733	0.5543	0.5386	0.5272	0.5208
0.5944	0.5733	0.5543	0.5386	0.5272	0.5208	0.5190
0.5733	0.5543	0.5386	0.5272	0.5208	0.5190	0.5212
0.5543	0.5386	0.5272	0.5208	0.5190	0.5212	0.5269
⋮	⋮	⋮	⋮	⋮	⋮	⋮
0.5212	0.5269	0.5356	0.5466	0.5591	0.5720	0.5844
0.5269	0.5356	0.5466	0.5591	0.5720	0.5844	0.5952
0.5356	0.5466	0.5591	0.5720	0.5844	0.5952	0.6036
0.5466	0.5591	0.5720	0.5844	0.5952	0.6036	0.6096
0.5591	0.5720	0.5844	0.5952	0.6036	0.6096	0.6134

técnicos apresentadas no Capítulo 2.

Em um primeiro momento, as regras dos indicadores foram testadas individualmente. Somente é analisada a ação selecionada pelo TOPSIS e confirmada pelo EMD-ELM. Se o indicador técnico sinalizar que é o momento de compra para aquela ação, então ela é comprada.

Outra proposta testada foi combinar dois indicadores. Uma solução seria realizar a compra somente se dois indicadores concordassem. Entretanto essa combinação entre pares de indicadores é pouco efetiva, visto que são raros os momentos em que indicam pontos de compra ao mesmo tempo. Então, ao invés disso, foi testada a união entre dois indicadores. Assim, se um dos dois indicadores sinalizar um ponto de compra, então a compra é feita.

O método conbinando TOPSIS, EMD-ELM e regras de negociação de indicadores de análise técnica é ilustrado na Figura 7.

4.5 Seleção de parâmetros

O método híbrido possui vários parâmetros importantes que precisam ser determinados. Para isso, a determinação dos parâmetros se baseia nos resultados do ano anterior. As configurações são escolhidas com base em dois critérios: maior percentual de operações com lucro e maior retorno.

Para o TOPSIS, os parâmetros são quais indicadores técnicos serão utilizados como critérios. Neste trabalho foram utilizados quatro ao total: RSI, estocástico K e D e CCI. Além da utilização de todos juntos, serão testadas combinações de dois e três indicadores.

Com base nos resultados do TOPSIS, a configuração com maior percentual de acertos e a com maior retorno continuam a ser utilizadas para seleção. Então é integrada

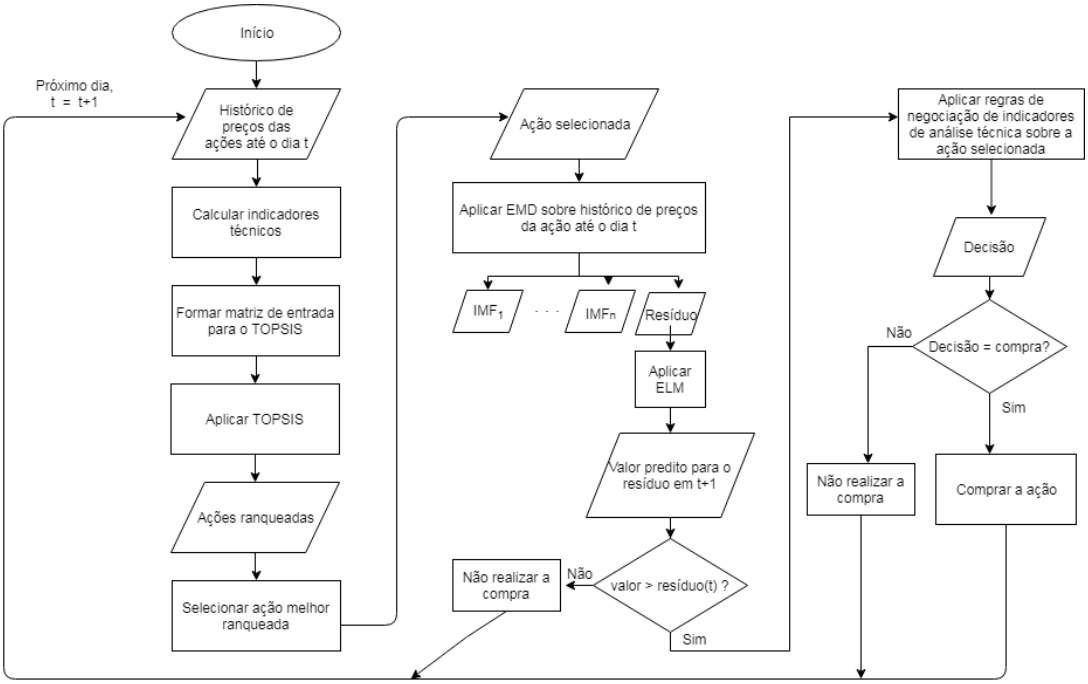

Figura 7 – Método híbrido combinando TOPSIS, EMD-ELM e regras de negociação de indicadores de análise técnica

a elas a metodologia de confirmação da compra de ação feita pelo EMD-ELM.

Para o EMD-ELM, o parâmetro mais influente é o tamanho da janela de dados utilizada. Ela será testada com valores de 20 a 400, variando de 10 em 10.

Por último, com base também nas duas melhores configurações anteriores do método, é preciso determinar a combinação de regras de negociação de indicadores técnicos. Serão testados os indicadores individualmente e combinações entre dois indicadores.

4.6 Efeito do viés de olhar à frente

O efeito do viés de olhar à frente (do inglês: *look-ahead bias*) envolve o uso inadvertido de informações que ainda não estariam disponíveis naquele momento (MAHFOUD; MANI, 1996). Ou seja, qualquer forma de utilização de dados futuros pode ser caracterizado como *look-ahead bias*. Até mesmo técnicas de normalização como min-max e z-score, quando aplicados sobre toda a série temporal são consideradas *look-ahead bias* (FURLANETO et al., 2017).

Muitos trabalhos aplicam técnicas de pré-processamento ou normalização sobre toda a série temporal, inclusive na parte de teste. Isso, como mostrado em Furlaneto et al. (2017), logicamente causa uma melhora nos resultados. Entretanto, para aplicações em tempo real, como negociação de ações, tais metodologias são inaplicáveis, pois não há como conhecer os dados do futuro.

Neste trabalho, embora os experimentos sejam feitos com dados do passado, é utilizado um protocolo semelhante a Furlaneto et al. (2017) para não utilização de dados ainda não disponíveis. O método híbrido toma as suas decisões ao final do dia, somente com as informações disponíveis até aquele dia. Em nenhum momento os dados são normalizados com base em dados ainda não disponíveis. A técnica EMD é aplicada somente na série de preços disponível até o momento.

5 Resultados experimentais

5.1 Base de dados

A base de dados é composta pelos valores diários de preço de abertura, preço mínimo, preço máximo, preço de fechamento e volume de negociação de diversas ações da bolsa de valores brasileira. Foram coletados dados dos anos 2016 e 2017 por meio do software MetaTrader 5 (MetaQuotes Software Corp., 2018). No total, 50 ações foram utilizadas como alternativas para o TOPSIS. Foram consideradas apenas ações com grande volume de negociação e que geralmente fazem parte do índice Bovespa. O nome das ações e seus códigos de negociação são mostrados na Tabela 13.

Tabela 13 – Códigos e nomes das ações consideradas nesse trabalho

Código	Ação	Código	Ação
ABEV3	Ambev SA	GOAU4	Gerdau Met
BBAS3	Brasil	HYPE3	Hypera
BBDC3	Bradesco ON	ITSA4	Itaúsa
BBDC4	Bradesco PN	ITUB4	Itaú Unibanco
BBSE3	BB Seguridade	JBSS3	JBS
BRAP4	Bradespar	KROT3	Kroton
BRFS3	BRF SA	LAME4	Lojas Americanas
BRKM5	Braskem	LREN3	Lojas Renner
BRML3	BR Malls Par	MRFG3	Marfrig
BVMF3	B3	MRVE3	MRV
CCRO3	CCR SA	MULT3	Multiplan
CIEL3	Cielo	NATU3	Natura
CMIG4	Cemig	PCAR4	P. Açúcar CDB
CPFE3	CPFE Energia	PETR3	Petrobras ON
CPLE6	Copel	PETR4	Petrobras PN
CSAN3	Cosan	QUAL3	Qualicorp
CSNA3	Sid. Nacional	RADL3	Raia Drogasil
CYRE3	Cyrela Realt	SANB11	Santander BR
ECOR3	Ecorodovias	SBSP3	Sabesp
EMBR3	Embraer	TIMP3	Tim Part SA
ENBR3	Energias BR	UGPA3	Ultrapar
EQTL3	Equatorial	USIM5	Usiminas
ESTC3	Estácio Part	VALE3	Vale
FIBR3	Fibria	VIVT4	Telef Brasil
GGBR4	Gerdau	WEGE3	Weg

5.2 Métricas de avaliação

A primeira métrica utilizada para avaliação do desempenho da metodologia foi a acurácia da seleção. Nela, é medido o percentual de seleções de ações que tiveram aumento no preço no dia seguinte. A acurácia da seleção é calculada conforme:

$$Acurácia = \frac{número\ de\ seleções\ corretas}{total\ de\ seleções} \cdot 100 \tag{5.1}$$

A outra métrica utilizada foi o retorno cumulativo (Rc), que é basicamente o retorno agregado sobre o período de investimento. Seu calculo é dado por:

$$Rc = \prod_{i=1}^{n}(1 + \frac{C_{i+1} - C_i}{C_i}) \tag{5.2}$$

onde C_i é o preço de fechamento de uma ação no dia i e n é o total de dias de negociação.

O retorno cumulativo apresenta, como resultado, a relação entre o investimento inicial e o montante final. Por exemplo um Rc de 2.5 significa que, ao investir 1000 Reais, o montante ao final do investimento é de 2500 Reais. No entanto, neste trabalho esse valor será convertido para retorno percentual, ou seja, o percentual de lucro gerado, calculado conforme:

$$\text{Retorno percentual} = (Rc - 1) \cdot 100 \tag{5.3}$$

O retorno percentual utilizado neste trabalho corresponde ao lucro bruto, ou seja, não são considerados os custos de transação e impostos.

É importante ressaltar que ao utilizar o retorno cumulativo, não se determina um investimento inicial, simplesmente considera-se que todo o capital (independente da quantia) é investido, ou seja, convertido em ações. Entretanto, em um investimento real, nem sempre todo capital pode ser convertido em ações. Isso ocorre porque, por padrão compra-se lotes de ações no mercado (normalmente um lote contém 100 ações de uma empresa), e assim ao comprar o máximo de lotes possível pode ainda sobrar dinheiro.

Por exemplo, considere um investimento inicial R$100000,00. No primeiro dia o algoritmo sugere a compra da ação A, que vale R$15,00. Esse ativo tem um lote mínimo de 100 ações, e nesse caso, cada lote custa R$1500,00. Assim, é possível comprar 66 lotes e sobram R$1000,00 (sem considerar taxas de transação e impostos).

No dia seguinte o valor da ação passa a ser R$16,00. Ao final do segundo dia, a venda dos 66 lotes da ação A (R$1600,00 cada) gera R$105600,00 e somando com os R$1000,00 que sobraram tem-se R$106600,00. Ainda no segundo dia, o algoritmo sugere a compra da ação B, que vale R$10,00. Dessa forma são comprados 106 lotes da ação e sobram R$600,00.

No terceiro dia, a ação B sobre para R$11,00. A venda dos lotes da ação B gera R$116600,00 e somando com os R$600,00 restantes tem-se R$117200,00.

Para o mesmo caso o retorno cumulativo é de:

$$\prod_{i=1}^{n}(1+\frac{C_{i+1}-C_i}{C_i}) = (1+\frac{16-15}{15}) * (1+\frac{11-10}{10}) = 1.0667 * 1.1 = 1.1733 \tag{5.4}$$

A Tabela 14 faz uma comparação entre o retorno cumulativo e uma simulação com um investimento inicial de R$100000,00 para o exemplo descrito anteriormente.

Tabela 14 – Comparação entre retorno cumulativo e simulação com investimento inicial determinado

Momento	Ação vendida	Preço de compra	preço de venda	Retorno cumulativo	Capital (simulação)
Final do primeiro dia	-	-	-	1	R$100000,00
Final do segundo dia	A	R$15,00	R$16,00	1.0667	R$106600,00
Final do terceiro dia	B	R$10,00	R$11,00	1.1733	R$117200,00

Como pode ser observado, há uma pequena diferença entre os ganhos gerado na simulação (17,2%) e no retorno cumulativo (17,33%). Assim como também, simulações com capitais iniciais diferentes podem gerar resultados diferentes. O retorno cumulativo porém, é uma medida mais generalizada, não estando ligada diretamente ao capital investido.

5.3 Resultados usando TOPSIS

5.3.1 Estratégias usadas para comparação

Para avaliar a seleção de ativos feito pelo TOPSIS, uma estratégia de seleção aleatória é utilizada para comparação. Nessa estratégia, a cada dia é escolhido um ativo aleatoriamente. Para gerar medidas estatísticas como média e desvio padrão, a estratégia foi executada 1000 vezes.

A taxa de retorno gerada pela seleção feita pelo TOPSIS é comparado com o retorno do índice Bovespa no mesmo período de negociação. O índice Bovespa é formado por uma carteira teórica das ações mais negociadas no mercado brasileiro e que tem o objetivo de representar o desempenho médio das ações mais representativas do mercado (BM&FBOVESPA, 2018). A estratégia aleatória também foi utilizada para comparação em termos de retorno percentual.

5.3.2 Aplicação para o ano de 2016

Uma das etapas mais importantes na utilização do TOPSIS é a escolha dos critérios, uma vez que eles influenciam fortemente o resultado final do algoritmo. Foram testadas todas as combinações dos indicadores utilizados e os resultados foram comparados com

o índice Bovespa e a estratégia aleatória, em termos de acurácia de seleção e retorno percentual, como apresentado na Tabela 15.

Tabela 15 – Resultados da aplicação do TOPSIS para o ano de 2016

Método	Critérios	Acurácia	Retorno percentual
TOPSIS	RSI, est. K	49.39%	66.48%
TOPSIS	RSI, est. D	43.72%	14.36%
TOPSIS	RSI, CCI	53.85%	134.84%
TOPSIS	est. K, est. D	54.25%	141.61%
TOPSIS	est. K, CCI	57.89%	248.39%
TOPSIS	est. D, CCI	57.89%	**326.77%**
TOPSIS	RSI, est. K, est. D	49.39%	50.16%
TOPSIS	RSI, est. K, CCI	55.87%	222.13%
TOPSIS	RSI, est. D, CCI	52.63%	89.06%
TOPSIS	est. K, est. D, CCI	**58.30%**	269.73%
TOPSIS	RSI, est. K, est. D, CCI	53.44%	133.70%
Aleatório	-	51.86±2.73%	55.15±59.94%
Ibovespa	-	-	42.91%

5.3.3 Análise dos critérios utilizados para o TOPSIS

Como esperado, o uso de diferentes critérios altera os resultados do TOPSIS. No entanto, é possível observar que alguns indicadores impactam positivamente os resultados e outros negativamente.

O indicador CCI está presente nos melhores resultados tanto em acurácia quanto em retorno. Ao utilizar todos os indicadores, por exemplo, a acurácia é de $53,44\%$ e o retorno é de $133,70\%$. Ao retirar o indicador CCI, a acurácia cai para $49,39\%$ e o retorno para $50,16\%$.

Por outro lado, o indicador RSI está presente nos piores resultados do algoritmo. Ao retirar apenas esse indicador, a acurácia da técnica sobe para $58,30\%$ e o retorno para $269,73\%$.

Nem sempre os indicadores se comportam de acordo com o seu tipo de critério, por exemplo, quando um indicador do tipo custo tem um valor baixo, a ação deveria subir no dia seguinte. Entretanto, a maximização ou minimização dos indicadores nem sempre tem uma relação direta com o comportamento futuro do preço da ação. Esse fato é ilustrado através de histogramas na Figura 8.

Os histogramas foram construídos com base nos valores dos indicadores para todas as 50 ações. No eixo horizontal estão as faixas de valores para os indicadores e, no eixo vertical está a frequência dos mesmos, ou seja, a quantidade de vezes que ocorreram. Para cada faixa de valor há duas classes: alta (representada pela barra verde) e baixa

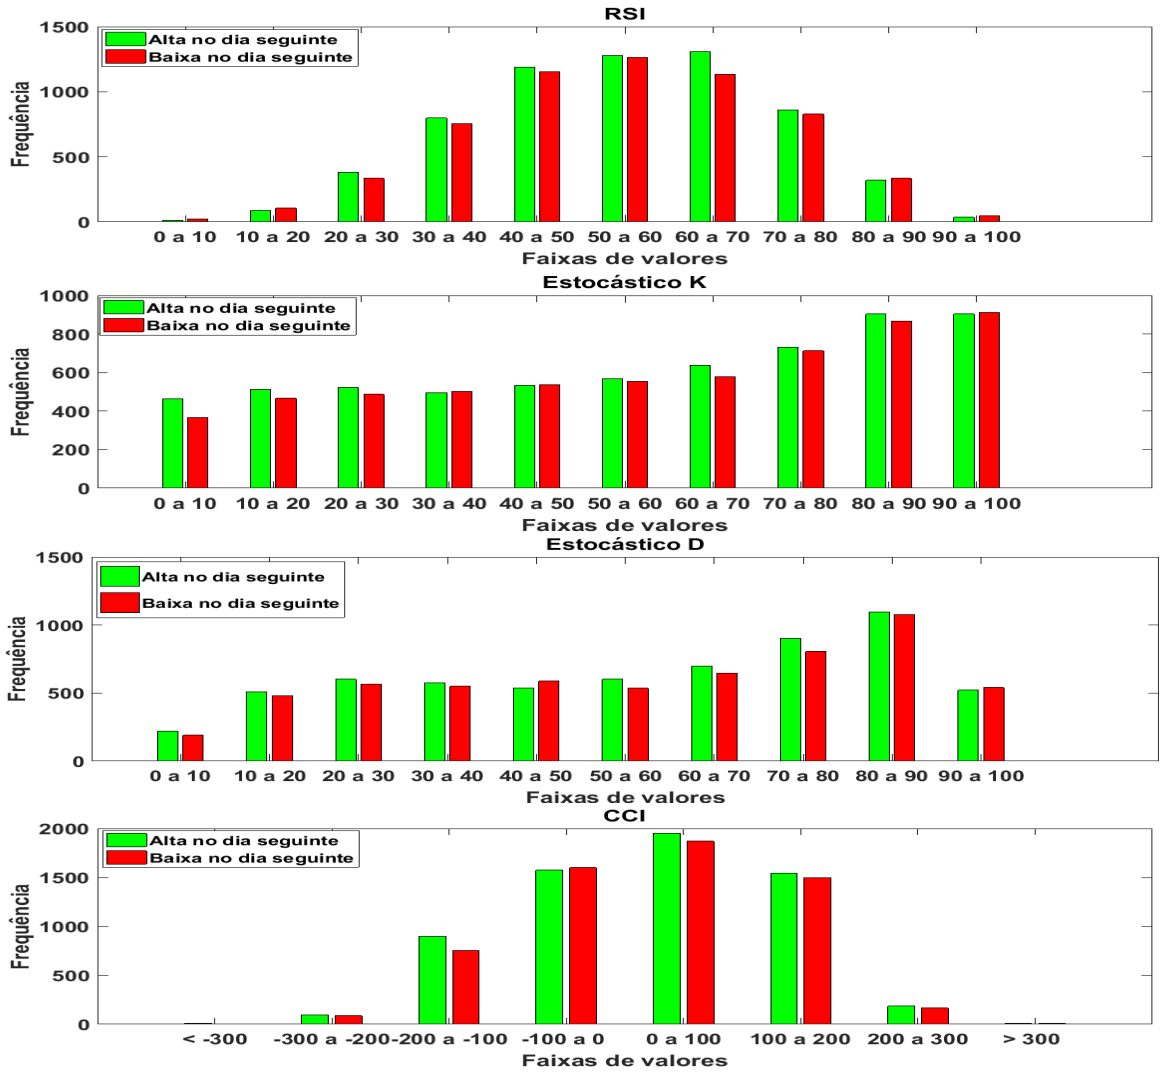

Figura 8 – Histogramas dos indicadores

(representada pela barra vermelha). A classe 'alta' representa os casos em que ação sobe no dia seguinte. Por exemplo, uma ação tinha o preço de fechamento de 20 reais e o valor do RSI era 25 no dia t e, no dia seguinte o preço de fechamento sobe para 21 reais. Nesse caso, o RSI será contabilizado para a classe 'alta' na terceira faixa de valor (20 a 30) do histograma do indicador. A classe 'baixa' ocorre de forma contrária a classe 'alta'.

No histograma do RSI é possível observar que, quando o valor do indicador está abaixo de 20 (primeiras duas faixas), o número de ocorrências das classes 'alta' e 'baixa' são próximos, com uma leve vantagem da última. O mesmo ocorre para as últimas duas faixas. O ideal para o TOPSIS seria que, nas primeiras classes houvesse uma dominância da classe 'alta'.

Já no histograma do estocástico K, pode-se notar um certo domínio da classe 'alta' para as três primeiras faixas. Isso mostra que, o indicador consegue, de certa forma, se adequar ao critério do tipo custo. Com isso, ele auxilia no desempenho do TOPSIS.

O indicador estocástico D, apresenta um histograma parecido com o estocástico K. Nas quatro primeiras faixas, há um número um pouco maior de ocorrências da classe 'alta'. Como o indicador anterior, ele consegue uma certa adequação ao critério do tipo custo.

O histograma do indicador CCI apresenta quantidades significativas apenas da segunda a sétima faixa. Nas faixas iniciais (segunda e terceira), a classe 'alta' é mais frequente. Sendo assim, ele é, em certa medida, compatível com o critério de custo.

De forma geral, a frequência das duas classes nas diversas faixas de valores dos indicadores são quase proporcionais. Essa proporcionalidade dificulta a adequação dos indicadores aos tipos de critérios do TOPSIS. Indicadores que se mostram mais apropriados ao seu tipo de critério, tendem a melhorar o resultado do método.

Foi feita também outra análise em forma de histograma, porém, agora em relação ao coeficiente de proximidade relativa do TOPSIS, como mostrado na Figura 9.

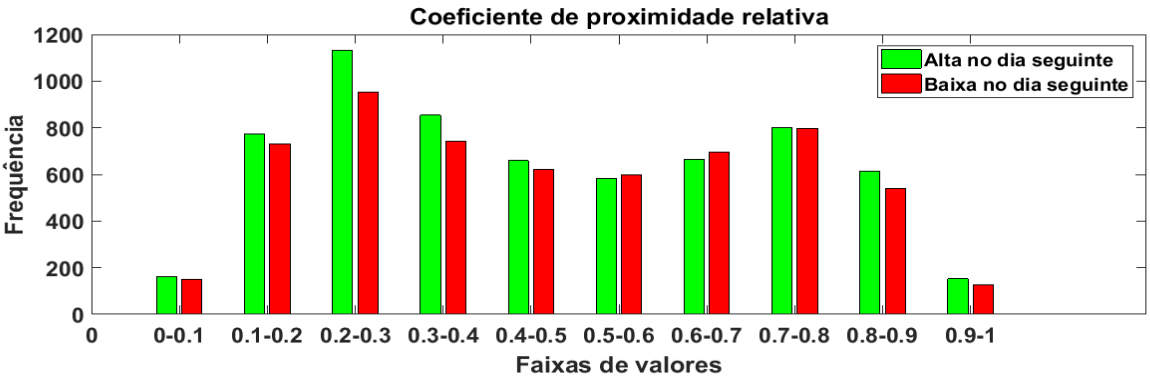

Figura 9 – Histograma do coeficiente de proximidade relativa

O histograma segue o mesmo padrão dos anteriores, porém, as faixas de valores são as saídas dos TOPSIS para cada ação em cada dia. Assim como nos histogramas dos indicadores técnicos, o resultado não é o ideal, ou seja, deveria haver a dominância da classe 'alta' nas faixas superiores, e o contrário nas faixas inferiores. Entretanto é importante ressaltar que as faixas mais importantes são as superiores, pois a ação selecionada a cada dia é sempre a de maior coeficiente de proximidade relativa. Nessa simulação, os valores dos coeficientes para as ações que foram selecionadas para compra, sempre se concentraram em uma das duas últimas faixas. Nessas faixas, nota-se um relativo predomínio da classe 'alta', justificando assim o desempenho positivo do TOPSIS na seleção de ações para compra.

5.4 Resultados usando TOPSIS + EMD-ELM

A primeira parte do método tem o objetivo de selecionar a melhor ação dentre as disponíveis. Para isso é utilizada a técnica TOPSIS com indicadores da análise técnica como critérios. Os melhores resultados da técnica foram com a utilização dos critérios

estocástico K e D e CCI (melhor acurácia) e com a utilização de apenas estocástico D e CCI (melhor retorno).

A segunda parte do método é responsável por confirmar ou não a compra da ação selecionada pelo TOPSIS. Entretanto, o algoritmo EMD-ELM tem parâmetros importantes a serem definidos: a quantidade de amostras utilizadas para treinamento a cada dia (tamanho da janela de treinamento), o número de atrasos utilizados como entrada para a ELM e a quantidade de neurônios da camada intermediária para a ELM.

O número de atrasos e a quantidade de neurônios foram definidos empiricamente como 6 e 20, dado que foi constatado através de simulações que esses parâmetros não apresentaram grande influência nos resultados.

O parâmetro de maior influência é o tamanho da janela de treinamento. Ele foi testado na faixa de 20 a 400 variando o valor de 10 em 10. Os testes foram realizados utilizando o TOPSIS com os dois conjuntos de critérios com melhores resultados para o ano de 2016, descritos anteriormente, e um terceiro conjunto que utiliza todos os indicadores.

Os resultados utilizando TOPSIS, com os critérios estocástico K e D e CCI para seleção, são mostrados na tabela 16.

O melhor resultado alcançado para a acurácia foi utilizando uma janela de treinamento de 270 dias para o EMD-ELM, no qual são feitas 100 negociações, sendo 66% com lucro. O melhor retorno é gerado com uma janela de 370 dias, atingindo 132.79%.

Os resultados utilizando TOPSIS com os critérios estocástico D e CCI para seleção, são mostrados na tabela 17. Nesse caso, os melhores resultados tanto de retorno quanto de acurácia, são conseguidos utilizando uma janela de treinamento de 50 dias. São feitas 79 negociações, sendo que 65.82% são lucrativas, gerando assim um retorno de 135.89%.

Os resultados utilizando TOPSIS, com todos os indicadores do conjunto como critérios, são mostrados na tabela 18.

O TOPSIS, com os quatro indicadores como critérios, apresenta resultados inferiores às configurações anteriores. A melhor acurácia é alcançada com uma janela de 50 dias e o melhor retorno com uma janela de 290 dias.

5.5 Regras de negociação da análise técnica

A terceira parte do método se baseia em regras de negociação provindas dos indicadores técnicos. Foram testados vários indicadores técnicos individualmente, além da combinação deles. Foram selecionadas duas combinações do método que apresentaram a melhor acurácia e melhor retorno. A primeira configuração utiliza o TOPSIS tendo estocástico K e D e CCI como critérios e o EMD-ELM tendo a janela de treinamento com 270 amostras, 6 atrasos e 20 neurônios. A segunda configuração tem o TOPSIS com os

Tabela 16 – Resultados do TOPSIS (K-D-CCI) + EMD-ELM para o ano de 2016

Janela	Negociações	Negociações com lucro	Acurácia	Retorno percentual	Tempo (s) de execução
20	78	44	56.41	6.78	4.6
30	70	38	54.29	0.23	5.2
40	78	42	53.85	44.13	5.5
50	68	43	63.24	78.68	5.7
60	71	43	60.56	49.63	5.7
70	75	47	62.67	57.95	6.1
80	86	54	62.79	73.19	6.3
90	91	53	58.24	53.31	6.6
100	89	51	57.30	44.51	6.7
110	94	55	58.51	81.59	6.9
120	82	50	60.98	66.91	7.0
130	85	54	63.53	72.28	7.0
140	79	46	58.23	30.09	7.0
150	82	50	60.98	54.64	7.3
160	92	52	56.52	11.74	7.4
170	87	54	62.07	61.94	7.6
180	97	54	55.67	25.49	7.7
190	91	53	58.24	19.97	7.9
200	90	50	55.56	64.05	7.9
210	96	55	57.29	30.46	8.0
220	105	65	61.90	86.30	8.0
230	89	56	62.92	85.85	8.3
240	86	51	59.30	58.13	8.5
250	101	62	61.39	91.45	8.5
260	89	50	56.18	18.62	8.5
270	100	66	**66.00**	89.81	8.6
280	104	60	57.69	63.16	8.6
290	95	59	62.11	63.31	8.8
300	105	63	60.00	65.96	8.8
310	100	64	64.00	93.60	9.1
320	116	73	62.93	71.80	9.1
330	101	62	61.39	96.31	9.3
340	117	71	60.68	83.96	9.5
350	119	70	58.82	63.92	9.7
360	104	63	60.58	36.01	9.7
370	111	69	62.16	**132.79**	9.7
380	110	65	59.09	67.83	9.9
390	120	69	57.50	42.80	9.9
400	115	73	63.48	85.81	9.9

critérios estocástico D e CCI e EMD-ELM com janela de treinamento de 50, 6 atrasos e 20 neurônios.

5.5.1 Regras utilizando apenas um indicador

As primeiras regras de negociação utilizam apenas o sinal de um indicador. Se o indicador sinalizar compra, então é confirmada a compra da ação. Por exemplo, a primeira regra nomeada como RSI é dada da seguinte forma: "**se** o sinal do indicador RSI é compra **então** a decisão é compra". Os resultados são mostrados na Tabela 19.

Tabela 17 – Resultados do TOPSIS (D-CCI) + EMD-ELM para o ano de 2016

Janela	Negociações	Negociações com lucro	Acurácia	Retorno percentual	Tempo (s) de execução
20	76	46	60.53	70.03	4.4
30	76	39	51.32	-4.03	5.0
40	78	42	53.85	57.32	5.4
50	79	52	**65.82**	**135.89**	5.5
60	78	50	64.10	73.71	5.7
70	81	49	60.49	76.14	6.0
80	93	58	62.37	77.87	6.2
90	93	55	59.14	79.28	6.5
100	91	55	60.44	94.33	6.6
110	92	57	61.96	116.93	6.7
120	84	49	58.33	55.59	6.9
130	87	56	64.37	98.80	7.0
140	80	47	58.75	44.41	7.1
150	81	47	58.02	64.21	7.2
160	93	51	54.84	25.92	7.4
170	80	48	60.00	30.51	7.4
180	95	50	52.63	18.23	7.6
190	90	48	53.33	0.71	7.6
200	88	48	54.55	53.17	7.8
210	90	51	56.67	32.20	8.0
220	103	61	59.22	93.69	8.0
230	86	55	63.95	84.27	8.4
240	86	51	59.30	57.76	8.4
250	100	59	59.00	77.59	8.5
260	87	48	55.17	25.11	8.5
270	92	58	63.04	86.98	8.7
280	96	54	56.25	64.78	8.7
290	92	53	57.61	55.10	8.8
300	106	61	57.55	72.64	9.0
310	98	58	59.18	82.67	9.1
320	110	65	59.09	61.47	9.1
330	98	58	59.18	89.72	9.4
340	116	66	56.90	72.52	9.4
350	111	63	56.76	74.20	9.5
360	106	64	60.38	67.72	9.7
370	108	63	58.33	120.21	9.7
380	111	62	55.86	68.61	9.8
390	128	71	55.47	54.01	9.9
400	114	68	59.65	93.67	9.9

A maioria dos casos apresentou menos de 10 negociações. A utilização da regra KD foi a que apresentou mais negociações e também o melhor retorno (segunda configuração, com 36.16%).

Tabela 18 – Resultados do TOPSIS (RSI-K-D-CCI) + EMD-ELM para o ano de 2016

Janela	Negociações	Negociações com lucro	Acurácia	Retorno percentual	Tempo (s) de execução
20	94	49	52.13	7.24	4.5
30	89	48	53.93	59.15	5.2
40	87	45	51.72	33.60	5.3
50	73	44	**60.27**	73.43	5.7
60	70	40	57.14	41.31	5.9
70	72	39	54.17	20.03	6.2
80	79	45	56.96	51.59	6.3
90	93	51	54.84	25.76	6.7
100	90	48	53.33	26.24	6.7
110	95	53	55.79	23.51	6.9
120	82	43	52.44	16.83	6.9
130	81	47	58.02	27.35	7.1
140	80	42	52.50	9.70	7.4
150	76	43	56.58	45.47	7.5
160	96	48	50.00	6.92	7.5
170	74	38	51.35	23.89	7.6
180	81	40	49.38	1.30	7.7
190	78	38	48.72	18.14	8.0
200	77	41	53.25	75.34	8.0
210	91	47	51.65	22.04	8.1
220	98	53	54.08	59.66	8.1
230	87	50	57.47	78.37	8.4
240	77	43	55.84	60.29	8.4
250	86	47	54.65	38.54	8.5
260	81	43	53.09	14.08	8.6
270	88	53	60.23	51.19	8.8
280	89	48	53.93	57.71	8.8
290	84	50	59.52	**80.60**	8.9
300	101	59	58.42	69.97	8.9
310	100	54	54.00	50.70	9.2
320	100	54	54.00	22.17	9.3
330	101	57	56.44	56.97	9.5
340	111	57	51.35	-2.27	9.5
350	112	56	50.00	11.68	9.7
360	104	55	52.88	10.02	9.7
370	106	58	54.72	66.07	9.7
380	110	60	54.55	23.19	9.8
390	119	63	52.94	7.05	9.9
400	117	66	56.41	23.90	9.9

5.5.2 Regras utilizando dois indicadores

Indicadores podem ser combinados para gerar sinais de negociação. Nesse caso, a combinação deles foi feita pelo conector OU. Assim, se um dos indicadores confirmar a compra de uma ação, então ela é realizada. Por exemplo, a regra "RSI ou K"é entendida

Tabela 19 – TOPSIS (RSI-K-D-CCI) + EMD-ELM + regras

Critérios	janela	Regra	Negociações	Negociações com lucro	Acurácia	Retorno	Tempo (s) de execução
K-D-CCI	270	RSI	3	3	**100.00**	2.90	9.0
D-CCI	50	RSI	4	3	75.00	2.54	6.0
K-D-CCI	270	K	7	4	57.14	4.90	9.1
D-CCI	50	K	4	3	75.00	12.41	5.9
K-D-CCI	270	D	1	1	**100.00**	7.53	9.0
D-CCI	50	D	1	1	**100.00**	7.53	5.9
K-D-CCI	270	KD	15	8	53.33	1.90	8.9
D-CCI	50	KD	19	12	63.16	**36.16**	5.8
K-D-CCI	270	CCI	3	2	66.67	1.56	9.0
D-CCI	50	CCI	6	3	50.00	5.86	5.8
K-D-CCI	270	BB	6	5	83.33	7.69	8.9
D-CCI	50	BB	8	6	75.00	10.99	5.9

como: "**se** sinal do RSI é compra **ou** sinal do estocástico K é compra **então** decisão é compra". Os resultados são mostrados na Tabela 20.

Utilizando regras compostas o número de negociações aumentou. O melhor resultado alcançado foi utilizando a regra "KD ou BB"na segunda configuração, atingindo 51.26% de retorno tendo 66.67% de negociações lucrativas. Em termos de acurácia os melhores resultados foram utilizando a regra "RSI ou D", entretanto o número de negociações é pequena.

5.6 Resultados para o ano de 2017

A partir dos experimentos para o ano de 2016, foram selecionadas as configurações que apresentaram melhores resultados. O método foi testado de maneira sequencial, ou seja, primeiro apenas com TOPSIS, depois adicionando EMD-ELM e, então, finalizando com as regras de negociação dos indicadores.

O TOPSIS foi aplicado com base nos melhores critérios encontrados para o ano de 2016. As configurações usadas foram as que apresentaram melhor retorno e melhor acurácia. Além disso, foi utilizado também o TOPSIS com todos os indicadores, a estratégia aleatória e o índice Bovespa para comparação. Os resultados são apresentados na Tabela 21.

Assim como no ano anterior, a seleção feita pelo TOPSIS superou a seleção aleatória e o índice Bovespa. A configuração com os indicadores estocástico D, CCI e estocástico K apresentou o melhor resultado. O TOPSIS que utiliza estocástico D e CCI, o qual apresenta melhor retorno para o ano de 2016, não conseguiu manter o melhor desempenho para 2017. Entretanto, manteve a acurácia competitiva com as outras configurações. O desempenho dos métodos, exceto o aleatório, pode ser observado ao longo do ano, em termos de retorno, como mostrado na Figura 10.

Tabela 20 – TOPSIS (RSI-K-D-CCI) + EMD-ELM + regras

Critérios	janela	Regra	Negociações	Neg c/ lucro	Acurácia	Retorno	Tempo (s) de execução
K-D-CCI	270	RSI ou K	9	6	66.67	5.42	9.0
D-CCI	50	RSI ou K	9	7	77.78	16.46	5.8
K-D-CCI	270	RSI ou D	4	4	**100.00**	10.64	9.0
D-CCI	50	RSI ou D	6	5	83.33	11.40	5.8
K-D-CCI	270	RSI ou KD	17	10	58.82	4.61	8.8
D-CCI	50	RSI ou KD	22	14	63.64	39.30	5.8
K-D-CCI	270	RSI ou CCI	6	5	83.33	4.50	8.8
D-CCI	50	RSI ou CCI	10	6	60.00	8.55	5.8
K-D-CCI	270	RSI ou BB	8	7	87.50	10.56	8.8
D-CCI	50	RSI ou BB	13	9	69.23	11.66	5.7
K-D-CCI	270	K ou D	7	4	57.14	4.90	8.9
D-CCI	50	K ou D	4	3	75.00	12.41	5.7
K-D-CCI	270	K ou KD	18	11	61.11	13.96	9.1
D-CCI	50	K ou KD	21	14	66.67	50.36	5.8
K-D-CCI	270	K ou CCI	9	5	55.56	6.35	8.8
D-CCI	50	K ou CCI	10	6	60.00	19.00	5.7
K-D-CCI	270	K ou BB	13	9	69.23	12.98	8.8
D-CCI	50	K ou BB	11	8	72.73	21.48	5.7
K-D-CCI	270	D ou KD	16	9	56.25	9.57	8.9
D-CCI	50	D ou KD	20	13	65.00	46.41	5.7
K-D-CCI	270	D ou CCI	4	3	75.00	9.20	8.9
D-CCI	50	D ou CCI	7	4	57.14	13.83	5.7
K-D-CCI	270	D ou BB	7	6	85.71	15.80	8.9
D-CCI	50	D ou BB	10	7	70.00	16.15	5.8
K-D-CCI	270	KD ou CCI	16	9	56.25	3.79	8.8
D-CCI	50	KD ou CCI	21	14	66.67	39.97	5.8
K-D-CCI	270	KD ou BB	19	11	57.89	7.34	8.8
D-CCI	50	KD ou BB	24	16	66.67	**51.26**	6.0
K-D-CCI	270	CCI ou BB	9	7	77.78	9.37	9.0
D-CCI	50	CCI ou BB	15	9	60.00	14.35	5.9

Tabela 21 – Resultados do TOPSIS para o ano de 2017

Método	Critérios	Acurácia	Retorno percentual
TOPSIS	est. D, CCI	55.10%	44,17%
TOPSIS	est. K, est. D, CCI	**55.92%**	**86.31%**
TOPSIS	Todos	51.84%	43,97%
Aleatório	-	51.06±2.75%	30.50±35.53%
Ibovespa	-	-	28.21%

A seguir é adicionada a segunda parte do método, o EMD-ELM, para confirmação da compra da ação selecionada pelo TOPSIS. Novamente foram testadas as configurações como melhor acurácia e melhor retorno. A primeira configuração utiliza o TOPSIS tendo estocástico K e D e CCI como critérios e o EMD-ELM tendo a janela de treinamento com 270 amostras, 6 atrasos e 20 neurônios. A segunda configuração tem o TOPSIS com os

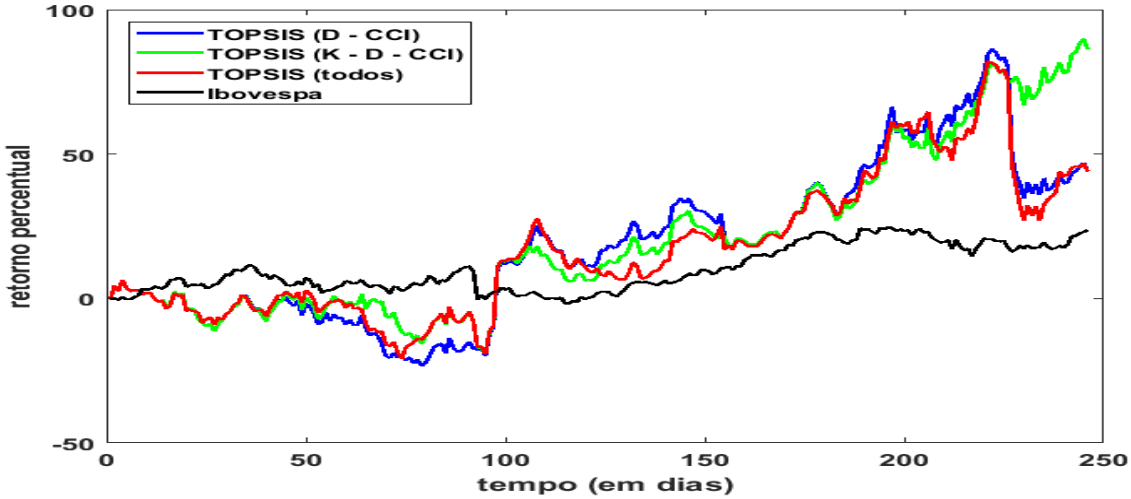

Figura 10 – Retorno percentual dos métodos ao longo do ano de 2017

critérios estocástico D e CCI e ELM-ELM com janela de treinamento de 50, 6 atrasos e 20 neurônios. Os resultados são apresentados na Tabela 22.

Tabela 22 – Resultados TOPSIS+EMD-ELM para o ano de 2017

Critérios	janelas	Negociações	Negociações com lucro	Acurácia	Retorno	Tempo (s) de execução
K-D-CCI	270	96	57	59.38%	49.28%	9.0
D-CCI	50	80	44	55%	4.87%	6.2

A primeira configuração apresentou os melhores resultados, tanto em retorno quanto em acurácia. Ao acrescentar EMD-ELM, há um aumento no percentual de negociações com lucro, entretanto o retorno diminui.

Finalmente, é simulado o método com as três partes. Foi adicionada às duas configurações testadas anteriormente, uma regra de negociação provinda dos indicadores técnicos. A regra escolhida para a primeira configuração foi a combinação do estocástico D com o cruzamento das linhas do estocástico (KD). Para a segunda combinação foi escolhida a combinação de bandas de Bollinger (BB) com a intersecção das duas linhas do estocástico (KD). Os resultados são apresentados na Tabela 23.

Tabela 23 – Resultados TOPSIS+EMD-ELM+regras para o ano de 2017

Critérios	janela	Regra	Negociações	Neg c/ lucro	Acurácia	Retorno	Tempo (s) de execução
K-D-CCI	270	D ou KD	19	9	47.37	-3.83	9.0
D-CCI	50	KD ou BB	24	11	45.83	-2.61	6.3

A terceira parte do método, embora tenha melhorado a acurácia para o ano de 2016, no ano de 2017 os resultados foram piores tanto em acurácia quanto em retorno.

5.7 Análise dos resultados

Em 2016, o TOPSIS, na maioria dos casos, conseguiu superar a seleção aleatória e o índice Bovespa, tanto em acurácia (exceto no índice Bovespa, para o qual não é possível calcular acurácia) quanto em retorno. A configuração com melhor acurácia foram: estocástico D, estocástico K e CCI, atingindo 58.30%. Já para o retorno, a melhor configuração utiliza estocástico D e CCI, alcançando 326.77%. Nas diversas configurações de critérios, somente em uma que ele não supera o índice Bovespa. É importante notar que, nem sempre a melhor acurácia gera o melhor retorno. Uma seleção com baixo lucro é contabilizada como acerto da mesma forma que outra com alto lucro.

A escolha dos critérios corretos tem grande influência sobre o resultado da seleção feita pelo TOPSIS. Por meio dos resultados é possível observar que alguns indicadores parecem gerar melhores resultados quando utilizados, como o CCI.

Com base na avaliação das diversas combinações de indicadores para o ano de 2016, foi possível escolher boas configurações para o ano de 2017. O TOPSIS continua apresentando melhores resultados em termos de acurácia e retorno. O retorno em 2017 porém, não é tão alto quanto em 2016, mas ainda assim é considerável.

A segunda parte do método, o EMD-ELM, tem a função de confirmar se a ação selecionada pelo TOPSIS deve ser comprada. Por isso, o EMD-ELM às vezes recusa a compra de uma ação e, consequentemente, isso reduz o número de negociações. No entanto, nem sempre essa rejeição está correta, reduzindo assim o número de operações com lucro. Dessa forma, o retorno foi menor, porém a confiabilidade das operações aumentou.

Um fator importante para o EMD-ELM foi determinar o tamanho da janela de treinamento. Esse parâmetro é muito importante, pois a tendência detectada pelo EMD para um mês pode ser diferente da de um ano por exemplo. Foram testadas várias configurações para o tamanho da janela de treinamento, para três configurações do TOPSIS testadas anteriormente no ano de 2016.

A maior acurácia foi alcançada utilizando o TOPSIS com os critérios estocástico K e D e CCI e uma janela de 270 dias. Nesse casso o EMD-ELM conseguiu aumentar a acurácia de 58.3% (utilizando apenas o TOPSIS) para 66%. O retorno porém caiu de 269.73% para 89.81%.

Já o melhor retorno foi conseguido através do uso do TOPSIS com os critérios estocástico D e CCI e uma janela de 50 dias. Entretanto, em relação a utilização somente do TOPSIS, houve uma redução de 326.77% para 132.79%. Porém, a acurácia aumentou de 57.89% para 65.82%.

Utilizando as duas configurações citadas acima para o ano de 2017, o comportamento permaneceu semelhante a 2016, em relação ao uso somente do TOPSIS. Utilizando o

EMD-ELM com a janela de 270 dias, a acurácia sobe de 55.92% para 59.3% e o lucro cai de 86.31% para 49.28%. Já utilizando a segunda configuração, com janela de 50 dias, a acurácia permanece praticamente no mesmo caindo de 55.1% para 55% e o retorno cai de 44.17% para 4.87%.

Com a utilização das regras de negociação provinda dos indicadores da análise técnica, o método atinge uma alta acurácia em 2016, embora tenham o retorno reduzido. No entanto, para o ano de 2017, as regras reduzem tanto a acurácia quanto o retorno do método.

Quanto ao tempo, o algoritmo leva em torno de 4 a 10 segundos para realizar o processamento de um ano inteiro. Isso significa que ele pode ser aplicado também a escalas de tempo de negociação bem menores do que a de um dia, como de minutos e até mesmo de segundos.

Uma comparação direta com resultados de trabalhos similares é difícil, devido ao fato de utilizarem cenários e abordagens diferentes. No entanto, objetivando posicionar os resultados obtidos nesse trabalho, apresentamos aqui alguns deles a seguir.

Vargas, Lima e Evsukoff (2017) utilizaram métodos de aprendizagem profunda, para predizer a direção do movimento do índice S&P500, tendo usado como entrada indicadores técnicos e títulos de notícias. A metodologia conseguiu 62.03% de acertos.

Nelson, Pereira e Oliveira (2017) utilizaram *Long-Short term memory* (LSTM) para predição da tendência dos preços de ações do mercado brasileiro, baseado em preços históricos e indicadores técnicos. Eles utilizaram o intervalo de tempo de 15 minutos, e conseguiram uma acurácia média de 55.9%.

Kara, Boyacioglu e Baykan (2011) utilizaram redes neurais artificiais e *support vector machine* (SVM) para predizer o movimento do ISE (*Istanbul Stock Exchange*). Nos resultados experimentais a rede neural alcançou em média 75.74% e a SVM 71.52% de acurácia.

6 Conclusão

Neste trabalho foi desenvolvido um método híbrido para negociação de ações combinando TOPSIS, EMD, ELM e análise técnica. O método foi construído de forma incremental, começando apenas com a técnica TOPSIS, adicionando o modelo híbrido EMD-ELM e finalizando com regras de negociação da análise técnica.

O TOPSIS é responsável por selecionar a ação mais apta para compra dentre um conjunto de ações. O modelo híbrido EMD-ELM é responsável por confirmar ou recusar a compra da ação. O EMD decompõe a série, extraindo a componente principal, e o ELM classifica a tendência da mesma. Por último, uma segunda confirmação é feita por meio de regras provindas de indicadores técnicos.

O método foi testado no mercado brasileiro, para um ambiente de 50 ações. Os dados foram coletados com base nos anos 2016 e 2017. Os dados de 2016 foram utilizados para configurar os parâmetros do método.

A seleção feita pelo TOPSIS foi comparada com a seleção aleatória e o índice Bovespa. As métricas usadas foram o percentual de negociações com lucro e o retorno gerado. O TOPSIS conseguiu bons resultados para 2016, superando os outros dois métodos na maioria dos casos. A técnica é muito influenciada pelos critérios utilizados. Alguns critérios como CCI, mostraram uma melhora considerável nos resultados.

A partir dos indicadores utilizados como critérios, selecionados com base no ano de 2016, a técnica continuou apresentando bons resultados para 2017.

A confirmação da compra pelo EMD-ELM aumentou o percentual de negociações com lucro, porém reduziu o número total de negociações. O método também apresentou uma redução no retorno. O tamanho da janela de treinamento tem grande influência sobre o método.

Por último, a utilização de regras de negociação de análise técnica acabou não trazendo melhorias para o método. Embora tenha mostrado conseguir bons percentuais de negociações com lucro para o ano de 2016 (embora realizando poucas negociações), não trouxe melhoria em nenhum quesito para 2017.

O modelo proposto, consegue analisar várias ações ao mesmo tempo. Com isso, há uma base mais ampla para a tomada de decisão. A decisão não é somente em que momento comprar uma ação, mas qual ação comprar.

O modelo, principalmente em relação ao TOPSIS e ao EMD-ELM se mostrou promissor. Com base nisso, trabalhos futuros podem incorporar diferentes técnicas a eles ou mesmo modificar as técnicas utilizadas nele. Outros métodos de tomada de decisão,

assim como outros tipos de redes neurais podem ser testados. Além disso, a lógica *fuzzy* poderia substituir regras convencionais de indicadores técnicos.

Uma observação interessante, é que, a medida em que são utilizados métodos para confirmar a compra de ações, menos negociações são feitas, aumentando o tempo entre uma compra e outra. As vendas, neste trabalho, sempre ocorrem no dia seguinte a compra. No entanto, um sistema de tomada de decisão para venda seria interessante nessa situação, pois poderia definir um ponto mais propício para a venda.

Referências

ALMEIDA, R. de; REYNOSO-MEZA, G.; STEINER, M. T. A. Multi-objective optimization approach to stock market technical indicators. In: *2016 IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2016. p. 3670–3677.

BM&FBOVESPA. *Índice Bovespa (Ibovespa)*. 2018. <http://www.bmfbovespa.com.br/pt_br/produtos/indices/indices-amplos/indice-bovespa-ibovespa.htm>. Acessado em: 3 de Março de 2018.

BODAS-SAGI, D. J. et al. Multiobjective optimization of technical market indicators. In: *Proceedings of the 11th Annual Conference on Genetic and Evolutionary Computation: Late Breaking Papers*. [S.l.: s.n.], 2009. p. 1999–2004.

BOLLINGER, J. *Bollinger on Bollinger bands*. [S.l.]: McGraw Hill Professional, 2001.

BRASILEIRO, R. C. et al. Automatic method for stock trading combining technical analysis and the artificial bee colony algorithm. In: *2013 IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2013. p. 1810–1817.

BULGURCU, B. K. Application of TOPSIS technique for financial performance evaluation of technology firms in Istanbul stock exchange market. *Procedia-Social and Behavioral Sciences*, v. 62, p. 1033–1040, 2012.

ÇELEN, A. Comparative analysis of normalization procedures in TOPSIS method: with an application to turkish deposit banking market. *Informatica*, Vilnius University Institute of Mathematics and Informatics, v. 25, n. 2, p. 185–208, 2014.

CHEUNG, W. M.; KAYMAK, U. A fuzzy logic based trading system. In: *Proceedings of the Third European Symposium on Nature-inspired Smart Information Systems*. [S.l.: s.n.], 2007. v. 59.

COSTA, L. S. da; JUNIOR, A. M. D. Uma metodologia para a pré-seleção de ações utilizando o método multicritério TOPSIS. *Simpósio Brasileiro de Pesquisa Operacional*, p. 518–529, 2013.

DAS, P.; BISOI, R.; DASH, P. Data decomposition based fast reduced kernel extreme learning machine for currency exchange rate forecasting and trend analysis. *Expert Systems with Applications*, v. 96, p. 427 – 449, 2018.

DESWAL, M.; GARG, S. Application of TOPSIS: A multiple criteria decision making approach in supplier selection. In: *2nd International Conference on recent Innovation in Science, Engineering and Management, JNU Convention Centre, Jawaharlal Nehru University, New Delhi, 22nd Nov. India*. [S.l.: s.n.], 2015.

DOURRA, H.; SIY, P. Investment using technical analysis and fuzzy logic. *Fuzzy sets and systems*, v. 127, n. 2, p. 221–240, 2002.

EBERMAM, E. et al. Empirical mode decomposition, extreme learning machine and long short-term memory for time series prediction: A comparative study. In: *2018 Brazilian Conference on Intelligent Systems (BRACIS)*. [S.l.: s.n.], 2018. No prelo.

EBERMAM, E.; KNIDEL, H.; KROHLING, R. A. Negociação de ações usando TOPSIS e análise técnica. *Simpósio Brasileiro de Pesquisa Operacional*, 2018.

FAMA, E. F. Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, JSTOR, v. 25, n. 2, p. 383–417, 1970.

FAYEK, M. B.; EL-BOGHDADI, H. M.; OMRAN, S. M. Multi-objective optimization of technical stock market indicators using GAs. *International Journal of Computer Applications*, Foundation of Computer Science, v. 68, n. 20, 2013.

FERNÁNDEZ-BLANCO, P. et al. Technical market indicators optimization using evolutionary algorithms. In: *Proceedings of the 10th annual conference on Genetic and evolutionary computation*. [S.l.: s.n.], 2008. p. 1851–1858.

FURLANETO, D. C. et al. Bias effect on predicting market trends with EMD. *Expert Systems with Applications*, v. 82, p. 19–26, 2017.

GUO, Z. et al. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model. *Renewable Energy*, v. 37, n. 1, p. 241–249, 2012.

HECHT-NIELSEN, R. et al. Theory of the backpropagation neural network. *Neural Networks*, v. 1, n. Supplement-1, p. 445–448, 1988.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: a new learning scheme of feedforward neural networks. In: *2004 IEEE International Joint Conference on Neural Networks*. [S.l.: s.n.], 2004. v. 2, p. 985–990.

HUANG, G. B.; ZHU, Q. Y.; SIEW, C. K. Extreme learning machine: theory and applications. *Neurocomputing*, v. 70, n. 1-3, p. 489–501, 2006.

HUANG, N. E. et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. In: *Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences*. [S.l.: s.n.], 1998. v. 454, n. 1971, p. 903–995.

HWANG, C.-L.; YOON, K. *Multiple attribute decision making: methods and applications*. [S.l.]: Springer-Verlag Berlin, 1981.

IJEGWA, A. D. et al. A predictive stock market technical analysis using fuzzy logic. *Computer and information science*, v. 7, n. 3, p. 1, 2014.

JADIDI, O.; FIROUZI, F.; BAGLIERY, E. TOPSIS method for supplier selection problem. *World Academy of Science, Engineering and Technology*, v. 47, p. 956–958, 2010.

JANANI, M. H.; EHSANIFAR, M.; BAKHTIARNEZHAD, S. Selection of portfolio by using multi attributed decision making (Tehran stock exchange). *American Journal of Scientific Research*, v. 44, n. 2, p. 15–29, 2012.

KARA, Y.; BOYACIOGLU, M. A.; BAYKAN, Ö. K. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the istanbul stock exchange. *Expert systems with Applications*, v. 38, n. 5, p. 5311–5319, 2011.

KIM, G.; JUNG, S.; CHO, S. Determine the preference ordering of the stocks listed in

KOSPI with TOPSIS. In: *IEEE International Conference on Industrial Engineering and Engineering Management*. [S.l.: s.n.], 2009. p. 1396–1400.

KROHLING, R. A.; SOUZA, T. T. M. Dois exemplos da aplicação da técnica TOPSIS para tomada de decisão. *Revista de Sistemas de Informação da FSMA*, n. 8, p. 31–35, 2011.

LIAN, C. et al. Displacement prediction model of landslide based on a modified ensemble empirical mode decomposition and extreme learning machine. *Natural hazards*, v. 66, n. 2, p. 759–771, 2013.

LØKEN, E. Use of multicriteria decision analysis methods for energy planning problems. *Renewable and Sustainable Energy Reviews*, v. 11, n. 7, p. 1584–1595, 2007.

MAHFOUD, S.; MANI, G. Financial forecasting using genetic algorithms. *Applied artificial intelligence*, v. 10, n. 6, p. 543–566, 1996.

MAJUMDER, I.; BEHERA, M. K.; NAYAK, N. Solar power forecasting using a hybrid EMD-ELM method. In: *2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT)*. [S.l.: s.n.], 2017. p. 1–6.

MALKIEL, B. G. The efficient market hypothesis and its critics. *Journal of economic perspectives*, v. 17, n. 1, p. 59–82, 2003.

MARTINEZ, L. C. et al. From an artificial neural network to a stock market day-trading system: A case study on the BM&F Bovespa. In: IEEE. *International Joint Conference on Neural Networks*. [S.l.], 2009. p. 2006–2013.

MetaQuotes Software Corp. *Plataforma de negociação MetaTrader 5*. 2018. <https://www.metatrader5.com/pt/trading-platform>. Acessado em: 3 de Março de 2018.

MURPHY, J. J. *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. [S.l.]: Penguin, 1999.

NARANJO, R.; ARROYO, J.; SANTOS, M. Fuzzy modeling of stock trading with fuzzy candlesticks. *Expert Systems with Applications*, v. 93, p. 15–27, 2018.

NASCIMENTO, R. C. et al. Avaliação de oportunidades de investimento no mercado futuro brasileiro na escala de dezenas de segundos. *Simpósio Brasileiro de Pesquisa Operacional*, 2017.

NELSON, D. M.; PEREIRA, A. C.; OLIVEIRA, R. A. de. Stock market's price movement prediction with LSTM neural networks. In: *2017 International Joint Conference on Neural Networks (IJCNN)*. [S.l.: s.n.], 2017. p. 1419–1426.

OLIVEIRA, F. A. de et al. The use of artificial neural networks in the analysis and prediction of stock prices. In: *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. [S.l.: s.n.], 2011. p. 2151–2155.

PAPACOSTANTIS, E. *Competitive co-evolution of trend reversal indicators using particle swarm optimisation*. Tese (Doutorado) — University of Pretoria, 2009.

SALEH, E.; KIMIAGARI, A. Ranking Tehran's stock exchange top fifty stocks using fundamental indexes and fuzzy TOPSIS. *Engineering, Technology & Applied Science Research*, v. 7, n. 4, p. pp–1863, 2017.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. *Neural networks*, Elsevier, v. 61, p. 85–117, 2015.

TAN, T. Z.; QUEK, C.; NG, G. S. Biological brain-inspired genetic complementary learning for stock market and bank failure prediction. *Computational Intelligence*, v. 23, n. 2, p. 236–261, 2007.

TREUHERZ, R. M. *Investindo em Ações na Era Digital: Com estratégias em tempo de crise*. [S.l.]: Atlas, 2008.

VARGAS, M. R.; LIMA, B. S. de; EVSUKOFF, A. G. Deep learning for stock market prediction from financial news articles. In: *IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications*. [S.l.: s.n.], 2017. p. 60–65.

WEI, Y.; CHEN, M.-C. Forecasting the short-term metro passenger flow with empirical mode decomposition and neural networks. *Transportation Research Part C: Emerging Technologies*, v. 21, n. 1, p. 148–162, 2012.

WILDER, J. W. *New concepts in technical trading systems*. [S.l.]: Trend Research, 1978.