

# Previsão da Direção do Preço de Ação Brasileira Utilizando Redes Neurais e Máquinas de Vetores Suporte

Carlos A. M. Monteiro<sup>1</sup>, Matheus H. D. M. Ribeiro<sup>2</sup>

<sup>1</sup>Instituto Federal Catarinense (IFC)  
Blumenau – SC – Brasil

<sup>2</sup>Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS)  
Universidade Tecnológica Federal do Paraná (UTFPR) – Pato Branco, PR – Brasil

carlos.monteiro@ifc.edu.br, mribeiro@utfpr.edu.br

**Abstract.** *The efficient market hypothesis classifies markets as efficient, in which it is not possible to predict the future price, and less efficient, in which it is possible to predict the future price. Considering the possible financial gain when predicting the future price of an asset, several studies use Artificial Intelligence techniques to predict movements in the stock market. This article aims to evaluate the effectiveness of Support Vector Machine and Neural Networks models to predict the behavior of Brazilian stocks, using technical indicators. The results indicate accuracies close to 50% for both models, suggesting that the market is efficient and questioning its forecasting capacity.*

**Resumo.** *A hipótese de mercado eficiente classifica os mercados em eficientes, que não são possíveis de prever o preço futuro, e menos eficientes, que é possível prever o preço futuro. Considerando o possível ganho financeiro ao prever o preço futuro de um ativo, diversos estudos utilizam técnicas de Inteligência Artificial para prever movimentos no mercado de ações. Este artigo se propõe a avaliar a eficácia de modelos por Máquinas de Vetores Suporte e Redes Neurais para prever o comportamento de ações brasileiras, utilizando indicadores técnicos. Os resultados indicam acurácias próximas a 50% para ambos os métodos, sugerindo que o mercado é eficiente e questionando a capacidade de previsão para o mesmo.*

## 1. Introdução

A hipótese de mercado eficiente, apresentada por Fama (1970), determina que o preço de um ativo considera todas as informações disponíveis. Neste mesmo artigo, o autor cria classificações para os mercados em relação a sua eficiência: mercados mais eficientes, em que todas as informações existentes estão embutidas no preço do ativo; e mercados menos eficientes, em que existem pessoas com informações privilegiadas e, portanto, a formação de preço não considera necessariamente todas as informações existentes sobre o ativo.

Ainda, segundo Fama (1970), para os mercados mais eficientes não é possível prever o seu valor, pois ele depende completamente de acontecimentos futuros que são imprevisíveis. Contudo, para mercados menos eficientes é possível prever o seu valor futuro, uma vez que estes seguirão determinado padrão. Maciel (2023), por exemplo,

utiliza desta premissa para comparar dados do mercado de ações brasileiro antes e depois da crise sanitária do COVID-19 visando determinar a eficiência do mesmo. Em seu estudo, o autor conclui que o mercado brasileiro não é eficiente, nem antes e nem depois da crise, permitindo assim a previsão dos movimentos do mesmo.

Muitos pesquisadores empreendem seus estudos neste assunto devido à possibilidade de altos retornos financeiros a partir da previsão do preço ou do sentido de movimento do preço de ativos do mercado de ações. A aplicação de técnicas de Inteligência Artificial - IA tem sido aplicada das mais diversas formas. Weinbaum *et al.* (2022) analisam como as notícias a respeito das ações atuam sobre o volume de seus derivativos e como isso pode ser utilizado para prever o valor do papel. Jiang *et al.* (2024) transformaram as informações dos ativos em imagens para posteriormente utilizar técnicas de IA para determinação de padrões e posterior previsão. Huang *et al.* (2023) pesquisaram sobre o uso de informações da internet para melhorar a exatidão de previsões do preço de ações para o próximo dia.

Khoa e Huynh (2022) comparam Redes Neurais Artificiais (do inglês, *Artificial Neural Network* - ANN), Máquina de Vetor Suporte (do inglês, *Support Vector Machine* - SVM) e Regressão Logística (RL) utilizando o papel da Mobile World Investment Joint Stock Company, do mercado do Vietnam. Visando a previsão do sentido para o próximo dia de negociação, são utilizados como entrada destes modelos o preço de fechamento diário, o preço de abertura diário, o maior preço do dia, o menor preço do dia e o volume de transações do dia. O trabalho obteve 53,84% de acerto para RL, 53,84% para ANN e 91,51% para SVM.

Kara *et al.* (2011) utilizaram técnicas de classificação como ANN e SVM para determinar o sentido de ações do mercado de Istambul. Eles utilizaram os preços de fechamento diário, juntamente com dados de indicadores técnicos, como entrada do modelo. O objetivo deles era de prever o sentido do movimento do dia seguinte, classificando o mesmo em alta ou baixa. Nesta pesquisa observou-se que a média de acerto das previsões usando o modelo de ANN (75,74%) foi melhor que as feitas com modelo de SVM (71,52%).

Patel *et al.* (2015) compararam quatro abordagens de predição: ANN, SVM, Floresta Aleatória (do inglês, *Randon Forest* - RF) e Naive-Bayes (NB). Neste estudo, os autores utilizam o valor de fechamento diário de índices e ações da bolsa de valores da Índia, juntamente com seus indicadores técnicos, para determinar o sentido do movimento do preço no dia seguinte. Os resultados obtidos foram de 86,69% de acerto para ANN, 89,33% para SVM, 89,98% para RF e 90,19% para NB.

Henrique *et al.* (2023) avaliaram o uso de ANN, SVM, RF e NB visando verificar os resultados de Patel *et al.* (2015) e Kara *et al.* (2011). Tais modelos foram aplicados à ativos de cinco países desenvolvidos (USA, UK, Japão, Alemanha e Canada) e a cinco países em desenvolvimento pertencentes ao BRICS (Brasil, Rússia, Índia, China e África do Sul) com frequência diária. Em seus resultados, Henrique *et al.* (2023), discordam da eficácia exposta nos artigos anteriores. Eles defendem que a utilização de indicadores técnicos que utilizam o valor a ser previsto para os seus cálculos torna o modelo não realístico. Contudo, eles propõem a aplicação dos mesmos modelos para a previsão do dia seguinte, mas sem uso do valor do dia atual nos cálculos dos indicadores técnicos, tornando-o um modelo possível de ser utilizado em cenários

reais. Para estes modelos, o autor conclui que o resultado não é muito diferente de um modelo randômico.

Na Tabela 1 apresenta-se um resumo dos artigos acima citados, e outros correlacionados com o assunto, contendo o método de modelagem do artigo, o horizonte de previsão, frequência de aquisição dos dados e métrica de avaliação.

**Tabela 1: Resumo de trabalhos correlacionados.**

| Referência                    | Método            | Frequência dos dados | Horizonte de previsão | Métrica de Avaliação                     |
|-------------------------------|-------------------|----------------------|-----------------------|--|
| Kara <i>et al.</i> (2011)     | ANN e SVM         | Diário               | + 1                   | RMS%                                     |
| Patel <i>et al.</i> (2015)    | ANN, SVM, RF e NB | Diário               | +1                    | <i>f-measure</i>                         |
| Henrique <i>et al.</i> (2023) | ANN, SVM, RF e NB | Diário               | +1                    | <i>f-measure</i>                         |
| Tay e Cao (2001)              | SVM               | Diário               | +5                    | NMSE, MAE, DS e WDS                      |
| Kim (2003)                    | SVM               | Diário               | +1                    | Proporção de acerto                      |
| Khoa e Huynh (2022)           | ANN, SVM e RL     | Diário               | +1                    | Acurácia                                 |
| Zbikowski (2015)              | VW-SVM            | Diário               | +1                    | Taxa de retorno e <i>drawdown</i> máximo |
| Nayak <i>et al.</i> (2015)    | SVM-KNN           | Diário               | +1, +5, +22           | MAPE e RMSE                              |
| Dash e Dash (2016)            | ANN               | Diário               | +1                    | Taxa de retorno                          |
| Jiang e Liu (2020)            | SVM               | Diário               | Até +30               | Acurácia                                 |

Desta forma, este artigo propõe verificar a eficácia dos modelos de ANN e SVM, como apresentados em Kara *et al.* (2011), Patel *et al.* (2015) e Henrique *et al.* (2023), para três ativos brasileiros com o horizonte de previsão de 1 dia de negociação à frente dos dados usados nos cálculos, como feito por Henrique *et al.* (2023). Para avaliação da eficácia, será utilizada a metodologia *f-measure*, como feito por Henrique *et al.* (2023) e Patel *et al.* (2015). A principal contribuição deste artigo é a verificação da eficácia dos modelos ANN com Máquina Extrema de Aprendizagem (do inglês, *Extreme Learning Machines* - ELM) e SVM para previsão do movimento de ações brasileiras utilizando os indicadores técnicos definidos nos artigos predecessores.

O restante deste artigo está estruturado da seguinte forma: na seção 2 serão apresentados os dados utilizados, sua fonte, suas características e forma de cálculo dos indicadores técnicos. Já a seção 3, traz uma breve descrição sobre os algoritmos de IA utilizados para modelagem, seguida pela seção 4 que apresenta a metodologia de parametrização e teste dos modelos. O artigo é encerrado com a apresentação dos resultados na seção 5 e uma discussão dos resultados e conclusões do trabalho na seção 6.

## 2. Dados Analisados

Com a intenção de minimizar ao máximo as características de não linearidade, descontinuidade e alta frequência ligadas a eventos políticos, condições econômicas e expectativas dos investidores (Göçken *et al.*, 2016), optou-se pela utilização das três ações com maior número de negociações na bolsa de valores brasileira: Vale ON (VALE3), Petrobrás PN (PETR4) e Itaú Unibanco PN (ITUB4). Os dados adquiridos para este trabalho foram o valor de abertura, fechamento, máximo e mínimo diário para cada dia de negociação dos ativos escolhidos, no período de 30/11/2018 a 30/11/2023.

O dado de saída dos modelos é o sentido do valor do ativo, ou seja: quando o ativo valoriza a saída é 1; já quando o ativo desvaloriza a saída é 0. Os dados coletados apresentam aproximadamente a mesma proporção de amostras com saída em 1 e saída em 0. Considerando que a proporção foi similar, não houve retirada de dados, uma vez que não há motivo para o modelo ser tendencioso para um ou outro sentido.

Diversos indicadores técnicos são utilizados para a previsão da direção do valor de ativos financeiros. Alguns indicadores são bons para momentos com tendência, outros para momentos sem tendência e outros para momentos cíclicos. Por isso, e devido a intenção de prever o sentido do ativo, Kara *et al.* (2011), se baseando nos estudos de Chen *et al.* (2003), consideraram que diversos indicadores técnicos podem ser utilizados como entrada dos modelos.

Desta forma, os modelos criados neste trabalho utilizaram 11 entradas, sendo elas: o valor de fechamento da ação e 10 indicadores técnicos. Estas entradas são as mesmas utilizadas por Kara *et al.* (2011), Patel *et al.* (2015) e Henrique *et al.* (2023). Sendo assim, os indicadores utilizados são: Média Móvel Simples de 10 dias, Média Móvel Ponderada de 10 dias, Momentum, Stochastic K%, Stochastic D%, Índice de Força Relativa (do inglês, Relative Strength Index – RSI), Moving Average Convergence Divergence (MACD), Larry William's R%, Oscilador de Acumulo/Distribuição (A/D) e Commodity Channel Index (CCI). As fórmulas dos indicadores técnicos utilizados são as mesmas apresentadas por Kara *et al.* (2011). Visando reduzir a dominância de uma ou outra entrada devido à diferença de amplitude dos valores, todas as entradas foram normalizadas, ficando com seus valores sempre entre 0 e 1.

## 3. Algoritmos Utilizados

Neste artigo foram adotados três algoritmos diferentes, SVM, ANN e um híbrido, usando o SVM e ANN para criação deste modelo. Para o SVM utilizou-se o pacote scikit-learn 1.3.1 (nuSVM) e para o ANN o pacote ELM 1.0, ambos no Python 3.10.

### 3.1. SVM

O algoritmo de SVM divide o espaço criado pelas entradas em subconjuntos, no caso deste trabalho, 2 subconjuntos (um significando alta e outro baixa), por meio de uma função matemática que define a barreira entre eles (CHANG e LIN, 2022). A função matemática, normalmente denominada de *kernel*, pode ser linear, polinomial, radial, sigmoid, entre outras. A depender do *kernel* utilizado, o modelo pode ter outras entradas. Para o *kernel* polinomial, utiliza-se o grau do polinômio, e para o radial o *gamma*, que é a influencia de uma amostra sobre o treinamento do modelo. Já o

parâmetro  $\text{Nu}$  é utilizado em todos os *kernels*, pois determina o quanto de erro é aceito durante o treinamento do modelo. Importante levar em consideração que nem sempre é possível, ou interessante, ter o erro muito baixo, pois isso pode levar a problemas de *overfit* (quando o modelo é muito específico aos dados de treinamento), por exemplo. (SCIKIT, 2024)

### 3.2. ELM

As redes neurais são um algoritmo composto por neurônios dispostos em camadas. A primeira camada é a camada de entrada, com um neurônio para cada entrada, e a última camada é a de saída, com um neurônio para cada saída. Entre as camadas de entrada e saída existem as camadas escondidas. Para as Redes Neurais do tipo ELM, existe apenas uma camada escondida a qual deve ser determinadas a quantidade de neurônios nela. Os neurônios contêm uma função de ativação que, na implementação utilizada, pode ser do tipo sigmoid, ReLu, senoidal, tangente hiperbólica ou Leaky ReLu. Desta forma é necessário determinar quantas camadas escondidas, quantos neurônios serão utilizados nas camadas escondidas, sua função de ativação e o parâmetro de regularização que serve para avaliar o erro e evitar *overfit* do modelo.

### 3.3. Híbrido

Neste trabalho propõem-se dois modelos híbridos: o primeiro por votação e o segundo por unanimidade. Ambos utilizam como modelos internos os melhores parâmetros do SVM com *kernel* polinomial, do SVM com *kernel* radial e do ANN. Na versão por votação, define-se que a saída é o valor de maior frequência entre as saídas de todos os modelos internos. Já na versão por unanimidade, define-se que a saída é válida apenas quando os 3 modelos internos têm valores iguais. Portanto, quando um dos modelos sinaliza direção diferente aos outros 2, a saída não é definida.

## 4. Metodologia

O trabalho foi dividido em duas etapas: parametrização e testes. Na parametrização, determinou-se os hiperparâmetros para cada um dos algoritmos e, no teste, verificou-se a eficácia dos algoritmos utilizando os hiperparâmetros determinados. Para ambas etapas determinou-se a acurácia dos modelos utilizando o *f-measure* que, de forma simples, calcula o percentual de acerto do modelo dividindo o número de resultados corretos pelo total de resultados.

### 4.1. Definição de Hiperparâmetros

Para determinação dos parâmetros de cada um dos modelos, fez-se uma varredura aplicando determinados conjuntos de parâmetros ao modelo e verificando a sua acurácia. Utilizou-se 600 amostras para o treinamento dos modelos e o restante para os testes. Os parâmetros utilizados para criação de cada conjunto de teste são apresentados na Tabela 3 para SVM (com *kernel* polinomial e radial) e na Tabela 4 para ANN. Verificou-se todas as possíveis combinações de parâmetros e escolheu-se a combinação de maior *f-measure* para cada um deles.

**Tabela 3: Parâmetros e valores testados para SVM.**

| Parâmetro | Valores (Polinomial)       | Valores (Radial)                            |
|-----------|----------------------------|---|
| Nu        | 0.1, 0.25, 0.5, 0.75 e 0.9 | 0.1, 0.25, 0.5, 0.75 e 0.9                  |
| Gamma     | -                          | 0.5, 1, 1.5, 2, 2.5, 3, 3.5, 4, 4.5, 5 e 10 |
| Grau      | 1, 2, 3, 4 e 5             | -   |

**Tabela 4: Parâmetros e valores testados para ANN.**

| Parâmetro                               | Valores  |
|---|--|
| Função de Ativação                      | 'sigmoid', 'relu', 'sin', 'tanh', e 'leaky_relu' |
| C (Regularização)                       | 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8 e 0.9     |
| Numero de neurônios na camada escondida | 10, 20, 30, 40, 50 e 100                         |

## 4.2. Testes

Utilizando-se o conjunto de parâmetros de maior acurácia, determinado na etapa de parametrização, executou-se os testes dos modelos. Primeiramente, separou-se os dados de treinamento e de teste iniciando com 600 amostras para treinamento. Após treinar os modelos com os dados de treinamento, aplicou-se este modelo treinado para o primeiro dado de teste subsequente ao conjunto de treinamento e seguiu-se para a próxima iteração. Então, o dado utilizado no teste passou a compor os dados de treinamento e iniciou-se uma nova iteração com o próximo dado, até alcançar 1200 amostras de treinamento. Calculou-se o valor *f-measure* a partir do resultado de todas as iterações.

## 5. Resultados

Inicia-se a apresentação dos resultados com os parâmetros obtidos no teste de parametrização. Escolheu-se o melhor valor para cada algoritmo, obtendo-se assim os parâmetros a serem utilizados para treinamento de cada um. Apresentam-se, na Tabela 5, os parâmetros escolhidos para o SVM e na Tabela 6, os parâmetros para ANN. Nos modelos marcados com \*, encontrou-se problemas para alcançar o parâmetro Nu definido em algumas iterações, sendo assim, optou-se pelo primeiro conjunto de parâmetros que não apresentou tal erro. Já os modelos marcados com \*\*, não foram os primeiros da lista por levar tempo excessivo para treinamento, utilizando então o próximo conjunto de parâmetros. Importante ressaltar que, em ambas situações, a diferença de acurácia apresentada na etapa de parametrização entre o conjunto de parâmetros de maior acurácia e o conjunto utilizado é menor que 0.5%.

**Tabela 5: Parâmetros escolhidos para os modelos de SVM.**

| Ativo | <i>f-measure</i> | <i>Kernel</i> | Nu   | <i>Gamma</i> | Grau |
|-------|------------------|---------------|------|--------------|------|
| VALE3 | 56.5%            | Polinomial    | 0.1  | -            | 3    |
|       | 51.8%            | Radial        | 0.25 | 1            | -    |
| PETR4 | 56.1%            | Polinomial    | 0.25 | -            | 1    |
|       | 53.6%            | Radial        | 0.75 | 0.5          | -    |
| ITUB4 | 54.5%            | Polinomial**  | 0.25 | -            | 3    |
|       | 51.7%            | Radial*       | 0.5  | 1.5          | -    |

**Tabela 6: Parâmetros escolhidos para os modelos ANN.**

| Ativo | <i>f-measure</i> | Função de Ativação | C   | Quantidade de Neurônios |
|-------|------------------|--------------------|-----|-------------------------|
| VALE3 | 52.6%            | leaky_relu         | 0.4 | 50                      |
| PETR4 | 58.3%            | relu               | 0.7 | 50                      |
| ITUB4 | 54.0%            | leaky_relu         | 0.1 | 100                     |

Com os parâmetros apresentados nas Tabelas 5 e 6, aplicou-se os algoritmos aos dados de teste e obtiveram-se os resultados apresentados na Tabela 7. Importante ressaltar que o modelo híbrido com unanimidade obteve resultado válido para de 23.1% dos testes para VALE3, 31.3% para PETR4 e 20% para ITUB4, portanto, o resultado apresentado para este modelo, na Tabela 7, é relativo apenas aos resultados válidos.

**Tabela 7: *f-measure* para o teste sem reaproveitamento do modelo.**

| Ativo | SVM        |        | ANN   | Híbrido |             |
|-------|------------|--------|-------|---------|-------------|
|       | Polinomial | Radial |       | Votação | Unanimidade |
| VALE3 | 47,0%      | 51,5%  | 51,8% | 50,8%   | 48,%        |
| PETR4 | 46,8%      | 54,0%  | 51,2% | 50,3%   | 52,6%       |
| ITUB4 | 49,2%      | 54,5%  | 51,2% | 54,2%   | 51,7%       |

## 6. Considerações Finais

Este trabalho se propôs a avaliar a eficácia dos métodos SVM e ANN para previsão da direção de três ações da bolsa de valores brasileira, visando reproduzir trabalhos anteriores. Os resultados obtidos neste trabalho com acurácias variando de 46,8% a 56,9% mostram-se muito próximos da probabilidade de 50% do comportamento aleatório, colaborando com a conclusão de Henrique *et al.* (2023) de que o mercado é eficiente e não há espaço para previsão. Além disso, a junção dos três algoritmos originais (SVM polinomial, SVM radial e ANN) também não mostrou nenhum ganho significativo de acurácia, seja pelo sistema de votação (escolha da maioria) ou de unanimidade (apenas quando todos concordam).

Na perspectiva da possibilidade de o mercado não ser completamente eficiente e existir margem para previsão, entende-se que futuros trabalhos podem abordar o tema com algumas sugestões de modificação. A primeira sugestão deste trabalho para os trabalhos futuros é utilizar não apenas o valor atual dos indicadores técnicos como dados de entrada dos modelos, mas também valores passados dos mesmos. Também se sugere o uso do algoritmo genético, ou outra técnica de otimização, para determinação dos melhores parâmetros de cada um dos indicadores técnicos, bem como para determinação dos parâmetros de treinamento do SVM e do ANN. Por último, se sugere o tratamento de incertezas dos modelos, bem como uma análise estatística dos seus resultados.

## Referências

- CHANG, C. LIN, C. LIBSVM: A Library for Support Vector Machines. 2022.
- DASH, R.; DASH, P. K. A hybrid stock trading framework integrating technical analysis with machine learning techniques. *The Journal of Finance and Data Science*, v. 2, n. 1, p. 42–57, mar. 2016.

- FAMA, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, v. 25, n. 2, p. 383–417, maio 1970.
- GÖÇKEN, M. et al. Integrating metaheuristics and Artificial Neural Networks for improved stock price prediction. *Expert Systems with Applications*, v. 44, p. 320–331, fev. 2016.
- HENRIQUE, B. M.; SOBREIRO, V. A.; KIMURA, H. Practical machine learning: Forecasting daily financial markets directions. *Expert Systems with Applications*, v. 233, p. 120840, 15 dez. 2023.
- HUANG, J.-Y.; TUNG, C.-L.; LIN, W.-Z. Using Social Network Sentiment Analysis and Genetic Algorithm to Improve the Stock Prediction Accuracy of the Deep Learning-Based Approach. v. 16, n. 1, 29 maio 2023.
- JIANG, J. G.; LIU, J. Predicting Stock Market N-Days Ahead Using SVM Optimized by Selective Thresholds. 15 fev. 2020.
- JIANG, M. et al. A novel interval dual convolutional neural network method for interval-valued stock price prediction. *Pattern Recognition*, p. 109920, 26 ago. 2023.
- KARA, Y.; ACAR BOYACIOGLU, M.; 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, maio 2011.
- KHOA, B. T.; HUYNH, T. T. Forecasting stock price movement direction by machine learning algorithm. *International Journal of Electrical and Computer Engineering (IJECE)*, v. 12, n. 6, p. 6625, 1 dez. 2022.
- KIM, K. Financial time series forecasting using support vector machines. *Neurocomputing*, v. 55, n. 1-2, p. 307–319, set. 2003.
- MACIEL, L. Brazilian stock-market efficiency before and after COVID-19: The roles of fractality and predictability. *Global Finance Journal*, p. 100887–100887, 1 ago. 2023.
- NAYAK, R. K.; MISHRA, D.; RATH, A. K. A Naïve SVM-KNN based stock market trend reversal analysis for Indian benchmark indices. *Applied Soft Computing*, v. 35, p. 670–680, out. 2015.
- PATEL, J. et al. Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques. *Expert Systems with Applications*, v. 42, n. 1, p. 259–268, jan. 2015.
- SCIKIT. Scikit Learn: Support Vector Machines. Disponível em: <<https://scikit-learn.org/stable/modules/svm.html#svm-classification>> Acessado em: 02/02/2024.
- TAY, F. E. H.; CAO, L. Application of support vector machines in financial time series forecasting. *Omega*, v. 29, n. 4, p. 309–317, ago. 2001.
- ŻBIKOWSKI, K. Using Volume Weighted Support Vector Machines with walk forward testing and feature selection for the purpose of creating stock trading strategy. *Expert Systems with Applications*, v. 42, n. 4, p. 1797–1805, mar. 2015.
- WEINBAUM, D. et al. Option Trading Activity, News Releases, and Stock Return Predictability. *Management Science*, 9 set. 2022.