



MACHINE LEARNING APLICADO EM AÇÕES NO MERCADO FINANCEIRO B3

MACHINE LEARNING APPLIED IN STOCKS IN THE FINANCIAL MARKET B3

Bruno Mattos Braga¹, Francisco Assis da Silva¹, Robson Augusto Siscoutto¹, Leandro Luiz de Almeida¹

¹Faculdade de Informática de Presidente Prudente, Unoeste - Universidade do Oeste Paulista, Presidente Prudente, SP.

E-mail: bruno_mattos@yahoo.com.br, chico@unoeste.br, robson@unoeste.br, llalmeida@unoeste.br

RESUMO – Todos os dias CPFs são cadastrados na bolsa de valores. Pessoas buscando maior rentabilidade, expondo-se a grandes riscos sem ao menos saber analisar as melhores oportunidades. Sempre que se inicia a aprender algo é normal ter muitas dificuldades e desafios, pois o ato de conhecer algo “novo” é desafiador, ainda mais quando envolve dinheiro. Sendo assim, foi realizada uma análise comparativa entre alguns dos métodos de Inteligência Artificial, aplicados em padrões na bolsa de valores, visando melhorar a assertividade das operações realizadas e buscando sua eficiência estatisticamente comprovada. Dessa forma, aumentando as chances das operações serem vencedoras. Os algoritmos foram treinados separadamente a partir de dados históricos de cinco ações, sendo elas: Petrobrás, Itaú, Bradesco, Vale e Ambev. E utilizou-se os algoritmos de Regressão Linear, Support Vector Machine (SVM), K Nearest Neighbor (KNN), Random Forest e Árvores de Decisão.

Palavras-chave: Inteligência Artificial; Bolsa de Valores; Candlestick.

ABSTRACT – Every day CPFs are registered on the stock exchange. People seeking greater profitability, exposing themselves to great risks without even knowing how to analyze the best opportunities. Whenever you start to learn something, it is normal to have many difficulties and challenges, because the act of knowing something “new” is challenging, even more so when it involves money. Therefore, a comparative analysis was carried out between some of the Artificial Intelligence methods, applied in standards on the stock exchange, aiming to improve the assertiveness of the operations carried out and seeking their statistically proven efficiency. In this way, increasing the chances of the operations being winners. The algorithms were trained separately from historical data of five stocks, namely: Petrobras, Itaú, Bradesco, Vale and Ambev. And the algorithms of Linear Regression, Support Vector Machine (SVM), K Nearest Neighbor (KNN), Random Forest and Decision Trees were used.

Keywords: Artificial Intelligence; Stock Exchange; Candlestick.

1. INTRODUÇÃO

Conforme dados retirados do site da B3 (Brasil Bolsa Balcão), a bolsa de valores do Brasil, mostram que o número de investidores pessoa física aumentou consideravelmente ao longo do tempo, conforme apresentado na Tabela 1. Tais investidores buscam novas oportunidades de investimento e uma rentabilidade maior, aumentando sua chance de risco para obter um retorno maior.

Tabela 1. Número de investidores pessoa física cadastrado na B3.

Distribuição da participação de homens e mulheres no total de investidores pessoa física					
Ano	Homens		Mulheres		Total PF Qtd
	Qtd	%	Qtd	%	
2002	70.219	82,37%	15.030	17,63%	85.249
2003	69.753	81,60%	15.725	18,40%	85.478
2004	94.434	80,77%	22.480	19,23%	116.914
2005	122.220	78,76%	32.963	21,24%	155.183
2006	171.717	78,18%	47.917	21,82%	219.634
2007	344.171	75,38%	112.386	24,62%	456.557
2008	411.098	76,63%	125.385	23,37%	536.483
2009	416.302	75,37%	136.062	24,63%	552.364
2010	459.644	75,24%	151.271	24,76%	610.915
2011	437.287	74,98%	145.915	25,02%	583.202
2012	438.601	74,70%	148.564	25,30%	587.165
2013	440.727	74,79%	148.549	25,21%	589.276
2014	426.322	75,57%	137.794	24,43%	564.116
2015	424.682	76,23%	132.427	23,77%	557.109
2016	433.759	76,90%	130.265	23,10%	564.024
2017	477.887	77,13%	141.738	22,87%	619.625
2018	633.899	77,94%	179.392	22,06%	813.291
2019	1.292.536	76,89%	388.497	23,11%	1.681.033
2020	2.286.397	74,58%	779.378	25,42%	3.065.775

*Posição de Setembro/2020

A partir do levantamento bibliográfico, observa-se uma gama interessante de trabalhos, que buscam alternativas para análise e geração de informações que possam ajudar na tomada de decisão dentro do mercado de investimentos ligadas diretamente a aplicabilidade da IA (Inteligência Artificial).

A análise de dados junto com a inteligência artificial se torna uma solução trivial para o problema que se deseja atacar, portanto, o uso de IA envolve uma combinação de várias tecnologias, como redes neurais artificiais, algoritmos, sistemas de aprendizagem e outras tecnologias que podem simular a capacidade humana relacionada à inteligência. Por exemplo: raciocínio, percepção do ambiente e capacidade de fazer análises de decisão.

Este trabalho tem como objetivo desenvolver uma aplicação para análise de dados de bolsa de valores fazendo uso de inteligência artificial e padrões de altas e baixas durante um curto período de tempo, como apresentados

pelos *Candlesticks*, visando facilitar o acesso e tomada de decisão para o investimento na bolsa de valores. Mostrando assim, a capacidade de confiança de predição de modelos de *Machine Learning* baseados em fatos passados, sendo uma ferramenta de auxílio para decisões de compra e venda de ações.

2. TRABALHOS RELACIONADOS

Este capítulo apresenta trabalhos que utilizam Inteligência Artificial e obtiveram sucesso ao tentar prever a Bolsa de Valores.

Segundo Khaidem, Saha e Dey (2016), devido às várias incertezas e variáveis que controlam o valor de mercado em uma data específica, como condições econômicas e sentimentos dos investidores, discernir as tendências dos preços do mercado de ações é um processo complicado. Portanto, o mercado de títulos sempre estará suscetível a rápidas mudanças, causando movimentos aleatórios no preço.

No trabalho desenvolvido por Kupa (2013), foi utilizado redes neurais MultiLayer Percepyton (MLP) combinado com o modelo de Markowitz, e os resultados obtidos foram positivos em relação ao gerenciamento de risco, pois os resultados foram maximizados nesse sentido.

Outro estudo Giacomet (2016), trabalhou com a previsão não do preço exato do ativo ao final de um período, mas na direção para onde irá o ativo, comparando com o investidor que comprou no mesmo período em que a análise foi iniciada. Os achados mostram que é possível aumentar o nível de acerto utilizando redes neurais artificiais.

No trabalho desenvolvido por Igarashi, Valdevieso e Igarashi (2020), foi desenvolvida uma análise de sentimentos e indicadores técnicos a partir da correlação dos valores de ações com a polaridade de notícias do mercado financeiro. Fez-se a análise da correlação dos preços dos ativos a partir de uma média móvel aritmética em conjunto com uma ferramenta de análise sentimental disponível no mercado. Os autores notam que em alguns momentos há correlação entre os sentimentos avaliados e a variação do preço da ação, destacando ser uma correlação moderada, mas satisfatória.

O estudo realizado por Lima (2016) apresenta a predição do mercado de ações com base na mineração de opinião, e ressalta que os resultados obtidos foram considerados

satisfatórias com a utilização do SVM (*Support Vector Machine*). Ademais que a utilização de técnicas que envolvem o processo mineração de dados teve grande importância nas tomadas de decisão.

Silva (2021) realizou um estudo de algoritmos de previsão para séries temporais, como o histórico de preço das ações, e ressalta que estes algoritmos são um grande aliado dos investidores. Isto porque prever o movimento do mercado pode os deixar mais confiantes e menos preocupados. O trabalho realizou previsões utilizando *Random Forest* e Redes Neurais Artificiais, os resultados foram considerados satisfatórios no que tange a comparação entre ganhos e perdas.

Scheremeta (2021) realizou um trabalho aplicando redes neurais MLP (*Multilayer Perceptron*) em operações na bolsa de valores, ressaltando que são capazes de auxiliar na maximização do capital, indicando o momento ideal de comprar ou de vender baseado no movimento do mercado.

O trabalho realizado por Carvalho (2018), no qual se realiza a previsão de séries temporais no mercado financeiro de ações com o uso rede neural artificial, apresenta resultados bastante favoráveis a se minimizar os riscos de perdas, tomando por base os períodos críticos da economia (Crise Financeira Mundial de 2008) e ressaltando-se a utilização de rede neural artificial MLP (*Multilayer Perceptron*). Os resultados previstos foram muito próximos dos valores reais, indicando que as redes neurais podem auxiliar na tomada de decisão no mercado financeiro.

Dantas (2017) realizou um estudo sobre a utilização de aprendizado por reforço para operações na Bolsa de Valores. Concluiu que os resultados podem ser considerados satisfatórios, pois as previsões realizadas superou o *BuyAndHold* em metade dos casos. Isso significa que o processo de comprar e não vender em um futuro próximo foi definido com qualidade e lucratividade.

3. METODOLOGIA

No desenvolvimento do trabalho, buscou-se aplicar Inteligência Artificial em dados históricos da Bolsa de Valores, sendo mais específico a B3, aplicando diversos métodos com diversos parâmetros. Foi utilizada uma base de dados onde inicialmente há: o preço de abertura,

fechamento, máxima, mínima, média móvel de 8 e 21 períodos.

O trabalho foi dividido em duas etapas, preparação dos dados e busca pelo algoritmo de melhor desempenho.

3.1. Materiais e Métodos utilizados

Para o desenvolvimento deste trabalho utilizou-se um computador com processador Intel Core i7 8400 de 2.8GHz, 8GB de memória RAM. Os dados utilizados nos experimentos foram adquiridos por meio da plataforma ProfitChart Pro, exportados para o documento Excel. Para a programação dos algoritmos foi utilizada a linguagem de programação Python. Os algoritmos utilizados foram o de Regressão Linear para chegar a um valor próximo e Support Vector Machine (SVM), K-ésimo Vizinho mais Próximo (KNN), Árvores de Decisão e Forest Random para a decisão de direção do ativo.

Na preparação dos dados são gerados alguns indicadores para ajudar na previsão do alvo que se deseja para o preço de compra ou de venda da ação, são eles: RSI, que é utilizado na análise gráfica como um rastreador de tendência; Estocástico, que busca a reversão de tendência; e o *No_trend*, que é o preço atual sem a tendência. Os indicadores utilizados para auxiliar na previsão foram gerados a partir da biblioteca *ta-Lib*, uma biblioteca de código aberto utilizada por desenvolvedores de software de negociação que precisam realizar análises técnicas de dados do mercado financeiro, possuindo mais de 150 indicadores. Na Figura 1 tem-se um exemplo dos dados que foram retirados da plataforma ProfitChar Pro e exportados para Excel. As bases de dados utilizadas foram das empresas Petrobrás (PETR4), Vale (VALE3), Banco Itaú (ITUB3), Banco Bradesco (BBDC3) e Ambev (ABEV3).

Figura 1. Dados brutos retirados da plataforma ProfitChart Pro.

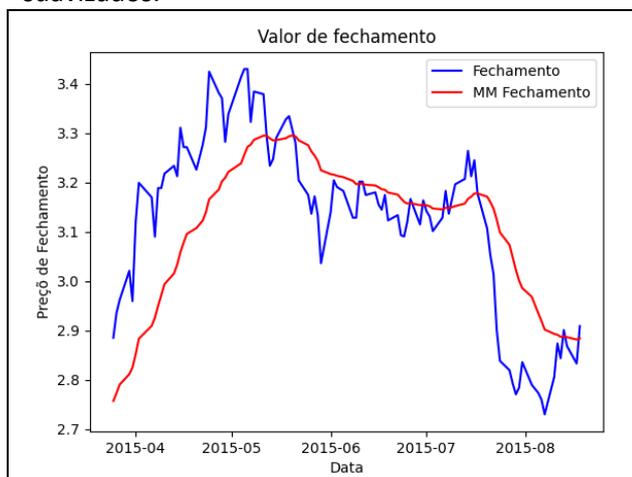
Data	abertura	maxima	minima	fechamento	volume
2021-06-04 00:00:00	17,01	17,39	17	17,24	836600614
2021-06-07 00:00:00	17,2	17,3	17,03	17,29	511760879
2021-06-08 00:00:00	17,17	17,23	16,28	16,33	1459600897
2021-06-09 00:00:00	16,4	16,45	15,81	16,4	1801495633
2021-06-10 00:00:00	16,45	16,53	15,71	16	1573884879

Fonte: (Os autores)

Os dados exibidos na Figura 2 são os dados de 'fechamento' do valor desejado da

Figura 1, suavizados exponencialmente para minimizar os ruídos e variações aleatórias.

Figura 2. Valores do preço de fechamento suavizados.



Fonte: (Os autores)

Na busca pelo melhor algoritmo é realizada a predição com todos os métodos propostos, utilizando vários períodos para realizar a suavização. O método que obtiver a melhor acurácia é julgado ser melhor para aquele tipo de dado. Na busca pelo melhor algoritmo, a média para realizar a suavização foi de 120 períodos, predizendo os dados após 30 dias, portanto, a análise de um período fechado dentro do mês.

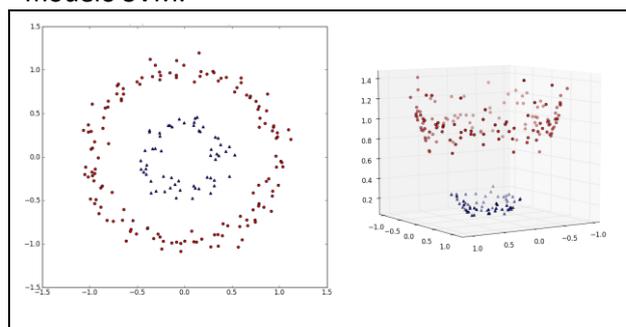
3. Algoritmos utilizados

Foram os algoritmos estudados e aplicados sobre os dados selecionados no trabalho.

3.2.1. Algoritmo 1: SVM

O *Support Vector Machine* (SVM) é utilizado por ser um algoritmo que trata os dados de forma não lineares (Nalepa & Kawulok, 2019). Isso ocorre porque utilizando o método Kernel Trick, método apresentado na Figura 3, que realiza uma transformação linear para que os dados não lineares possam ser separados linearmente.

Figura 3. Separação de dados realizados pelo modelo SVM.



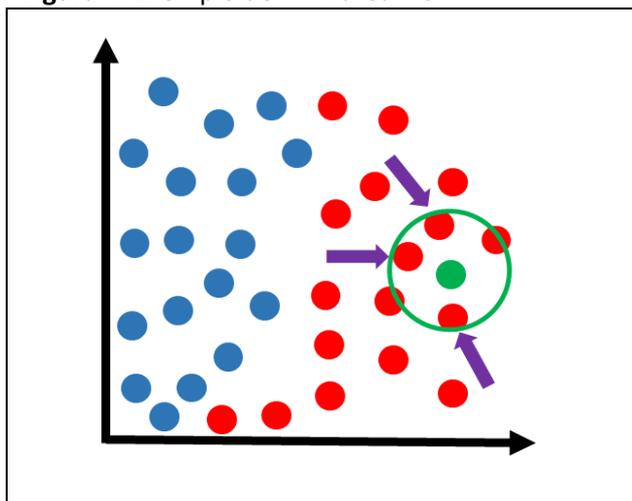
Fonte: (Eric Kim, 2021)

Segundo Eric Kim (2021), o modelo mostrado na Figura 3, tem uma alta assertividade justamente por separar os dados pelo hiperplano utilizando o conceito de Kernel, mapeando um espaço de mais alta dimensionalidade e separando melhor os dados. O kernel no SVM é responsável por transformar os dados de entrada no formato necessário para uso na ferramenta. Alguns dos kernels do SVM são lineares, polinomiais e radiais (função de base). Para criar um hiperplano não linear, utiliza-se de funções Radial Basis Function (RBF).

3.2.2. Algoritmo 2: KNN

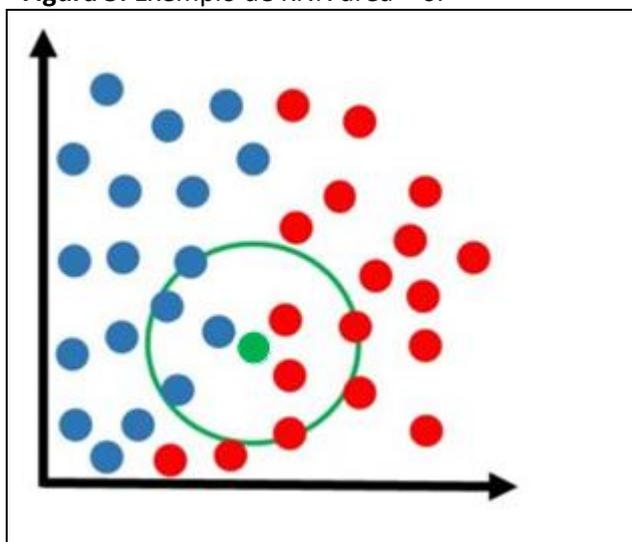
KNN (*K-Nearest Neighbors*) é um classificador não supervisionado onde o aprendizado é baseado “no quão similar” é um dado do outro. Mas o algoritmo não compara todos os dados, e sim os dados mais próximos a ele para realizar a classificação, o dado mais próximo significa o que possui a menor distância em relação à amostra. Na Figura 4 contém um exemplo de um KNN ($k = 3$) onde a bolinha verde é o dado a ser predito, como os 3 dados mais próximos são vermelhos, sua cor será vermelha. Na Figura 5 são os dados de uma KNN ($k = 6$) onde os dados que prevalecem são os azuis (ALI; NEAGU; TRUNDLE, 2019).

Figura 4. Exemplo de KNN área = 3.



Fonte: (Didática Tech - Inteligência Artificial & Data Science, 2020)

Figura 5. Exemplo de KNN área = 6.



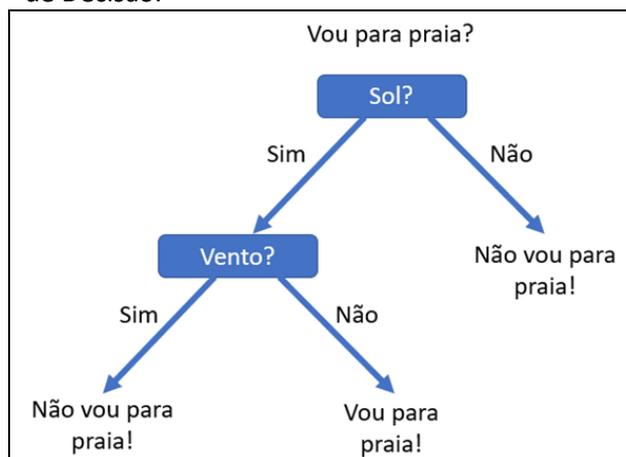
Fonte: (Didática Tech - Inteligência Artificial & Data Science, 2020)

Nota-se que, dependendo do valor de k , é possível ter resultados diferentes para cada situação.

3.2.3 Algoritmo 3: Árvores de Decisão

O fluxograma ilustrado na Figura 6 mostra o conceito de uma árvore de decisão. A decisão é tomada por meio do caminhamento a partir do nó raiz até o nó folha. Uma árvore de decisão estabelece nós (*decision nodes*) que se relacionam entre si por uma hierarquia. Existe o nó-raiz (*root node*), que é o mais importante, e os nós-folha (*leaf nodes*), que são os resultados finais. No contexto de *Machine Learning* (Aprendizado de Máquina), o elemento raiz é um dos atributos da base de dados e o nó-folha é a classe ou o valor que será gerado como resposta.

Figura 6. Exemplo de como funciona uma Árvore de Decisão.



Fonte: (Didática Tech, 2020)

3.2.4 Algoritmo 4: Floresta Aleatória

O algoritmo de florestas aleatórias cria várias árvores de decisão e as combina para obter uma predição com maior acurácia e mais estável. O conceito de florestas aleatórias (ou pelo menos a ideia inicial) surge justamente de uma das desvantagens de instabilidade existente nas Árvores de Decisão.

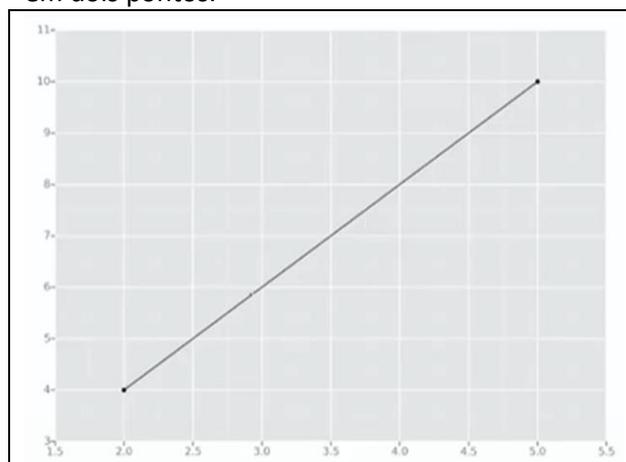
3.2.5 Algoritmo 5: Regressão Linear

Utilizam relações lineares entre algumas variáveis para prever o valor de uma terceira variável.

Na figura 7 tem-se um exemplo simples:

- Quando x vale 2, y vale 4;
- Quando x vale 5, y vale 10.

Figura 7. Exemplo simples de Regressão Linear em dois pontos.

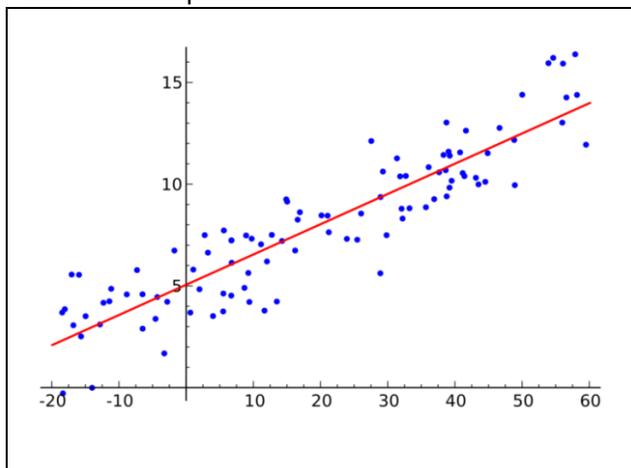


Fonte: (O autor, 2021)

De uma forma simples a Regressão Linear busca encontrar uma reta que passa o mais próximo possível de todos os pontos, na Figura 8

é uma Regressão Linear aplicada em diversos pontos, encontrando o intercepto e a inclinação de uma reta que melhor se ajuste aos dados e que minimize a variância dos erros.

Figura 8. Exemplo simples de Regressão Linear com diversos pontos.



Fonte: (Esposito, 2019)

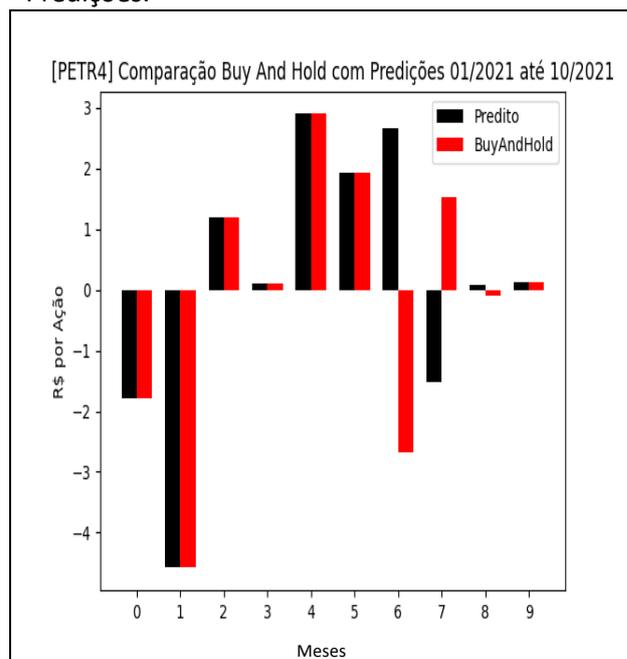
4. EXPERIMENTOS

Na aplicação dos métodos não foram consideradas as taxas de corretagem. A forma de comparação do valor predito das ações é com o *BuyAndHold* (Comprar e Segurar), a compra é realizada no início de um período e a venda no final do período, no caso deste artigo foi iniciada no primeiro dia de janeiro e vendida no último dia de outubro. O valor predito representa efetuar a compra da ação no primeiro dia do mês e vender no último dia do mês, fazendo isso de janeiro a outubro com base nos valores preditos.

Uma forma de avaliar os métodos é fazendo uma análise mês a mês, a Figura 9 exibe um gráfico onde o eixo X são os meses e o eixo Y são os lucros ou prejuízos obtidos no mês, com base em dados da empresa Petrobrás.

No mês de 0 (zero) o algoritmo predisse 1 (Compra) e o valor da ação caiu aproximadamente 2 reais, portanto o valor predito e o *BuyAndHold* perderam nesse mês. Em março a predição foi compra e o valor da ação subiu aproximadamente 1 real, fazendo com que o *BuyAndHold* e o predito tivessem uma valorização de aproximadamente 1 real por ação. No mês de julho o algoritmo predisse venda e o valor da ação caiu aproximadamente 3 reais, então, o *BuyAndHold* desvalorizou e o predito valorizou, julho é um exemplo onde o *BuyAndHold* perdeu dinheiro e o valor predito ganhou dinheiro.

Figura 9. Comparação entre *BuyAndHold* e Predições.



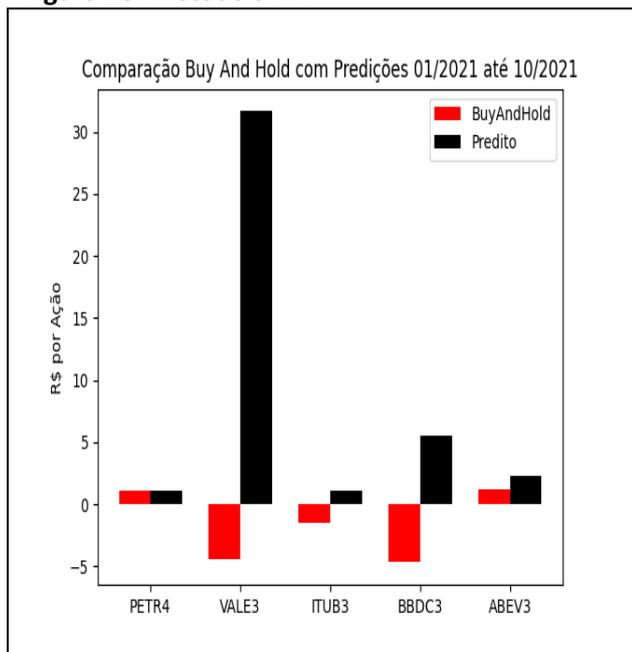
Fonte: (Autor, 2021)

Aplicando os métodos propostos obteve-se os resultados exibidos na Figura 10, Figura 11, Figura 12, Figura 13. Na Figura 10 é demonstrada a aplicação do método SVM onde o maior destaque foi a empresa VALE3, que ao longo de 10 meses obteve um lucro de R\$31,65 por ação. No *BuyAndHold* perdeu R\$4,45 por ação. Pode-se perceber que a aplicação do SVM obteve um melhor desempenho nas cinco empresas aplicadas, se saindo melhor que o *BuyAndHold*.

As demais ações são ilustradas na Tabela 2.

Tabela 2. Valores obtidos com SVM

	Buy And Hold	Valor Predito
PETR4	R\$ 1,08	R\$ 1,21
VALE3	R\$ -4,45	R\$ 31,65
ITUB3	R\$ -1,45	R\$ 1,10
BBDC4	R\$ -4,68	R\$ 5,53
ABEV3	R\$ 1,19	R\$ 2,30

Figura 10. Método SVM.

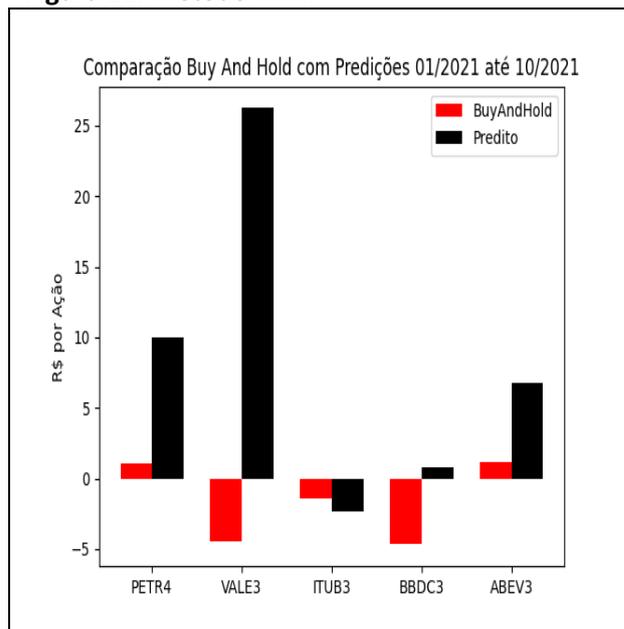
Fonte: (Autor, 2021)

A Figura 11 mostra o resultado após a aplicação do método KNN (*K-Nearest Neighbors*), onde novamente a empresa VALE3 se destacou nos lucros, sendo R\$26,23 por ação, e no *BuyAndHold* um prejuízo de R\$4,45 por ação. Na empresa ITUB3 foi obtida uma perda de R\$ 2,36 por ação, sendo pior que no *BuyAndHold* onde a perda foi de R\$ 1,45 por ação.

Os valores obtidos são evidenciados na Tabela 3.

Tabela 3. Valores obtidos com KNN.

	Buy And Hold	Valor Predito
PETR4	R\$ 1,08	R\$ 10,02
VALE3	R\$ -4,45	R\$ 26,23
ITUB3	R\$ -1,45	R\$ -2,36
BBDC4	R\$ -4,68	R\$ 0,81
ABEV3	R\$ 1,19	R\$ 6,78

Figura 11. Método KNN.

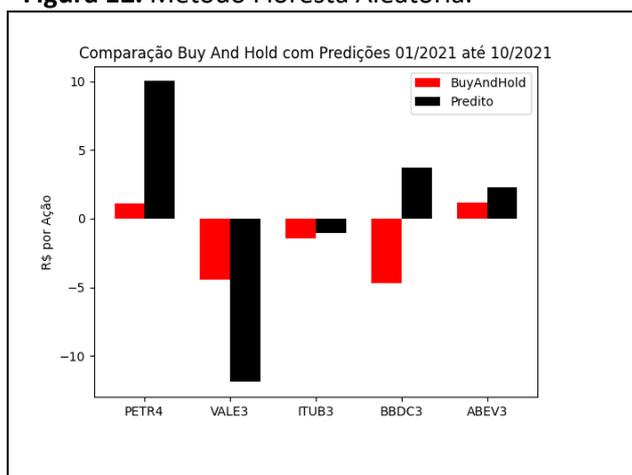
Fonte: (Autor, 2021)

Na Figura 12 foi realizado o método Floresta Aleatória, onde o maior destaque positivo foi a empresa PETR4, tendo um lucro de R\$10,02 por ação no valor predito e um lucro menor de R\$1,08 no *BuyAndHold*. Já a VALE3 foi o destaque negativo, tendo um prejuízo de R\$11,89 por ação no valor predito e no *BuyAndHold* um prejuízo de R\$4,45, fazendo com que se saísse melhor do que o valor predito.

Os valores obtidos são evidenciados na Tabela 4.

Tabela 4. Valores obtidos com Floresta Aleatória.

	Buy And Hold	Valor Predito
PETR4	R\$ 1,08	R\$ 10,02
VALE3	R\$ -4,45	R\$ -11,89
ITUB3	R\$ -1,45	R\$ -1,07
BBDC4	R\$ -4,68	R\$ 3,69
ABEV3	R\$ 1,19	R\$ 2,30

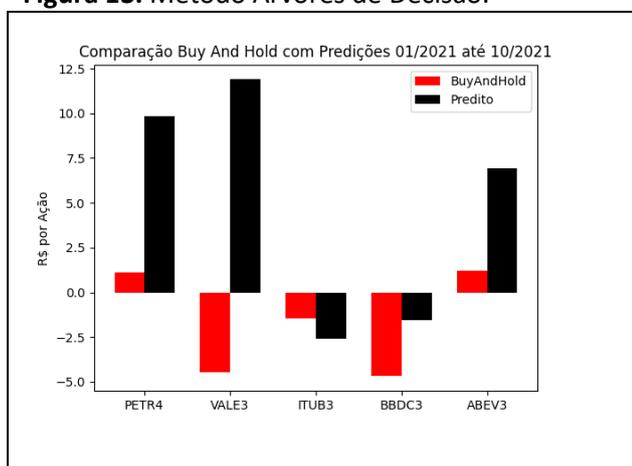
Figura 12. Método Floresta Aleatória.

Fonte: (Autor, 2021)

Na Figura 13 foi realizado o método Árvore de Decisão, tendo dois destaques positivos nas empresas PETR4 onde o lucro do valor predito foi R\$ 8,79 por ação a mais do que no *BuyAndHold* e na VALE3 onde o lucro do valor predito foi R\$ 16,34 por ação a mais do que no *BuyAndHold*, os valores obtidos são ilustrados na Tabela 5.

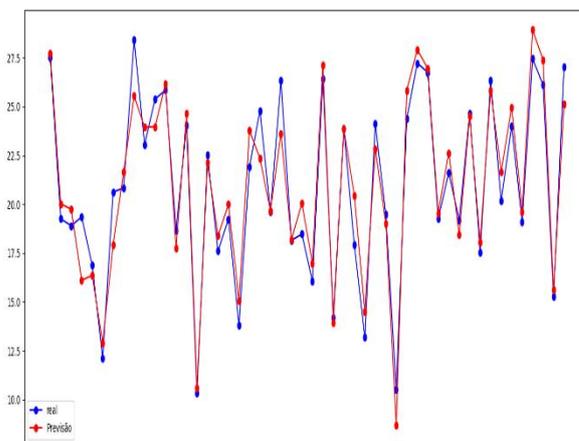
Tabela 5. Valores obtidos com Árvore de Decisão.

	Buy And Hold	Valor Predito
PETR4	R\$ 1,08	R\$ 9,84
VALE3	R\$ -4,45	R\$ 11,89
ITUB3	R\$ -1,45	R\$ -2,59
BBDC4	R\$ -4,68	R\$ -1,53
ABEV3	R\$ 1,19	R\$ 6,94

Figura 13. Método Árvore de Decisão.

Fonte: (Autor, 2021)

A Figura 14 mostra os valores preditos e os reais aplicando o método de Regressão Linear, onde os valores preditos não são apenas zero e um, mas valores onde o preço tende a chegar, sendo as bolinhas azuis o valor real da ação e as bolinhas vermelhas o valor predito.

Figura 14. Método de Regressão Linear.

Fonte: (Autor, 2021)

CONCLUSÃO

Este trabalho teve como objetivo propor um método para guiar o investidor nas suas operações financeiras utilizando Inteligência Artificial para fazer as classificações, gerando um 'sinal' de compra ou venda. Conclui-se que o método utilizado obteve um bom desempenho aplicando os dados históricos escolhido, embora os classificadores SVM e KNN tenham apresentado um maior nível de acerto que os demais métodos, ainda existem outros fatores que devem ser levados em consideração, como a média móvel utilizada na suavização, o tempo que será realizada a predição e os indicadores utilizados para escolher o melhor algoritmo utilizado. Percebe-se que cada empresa se sai melhor com um certo tipo de algoritmo, portanto a escolha certa de qual algoritmo será utilizado é fundamental.

A Regressão Linear pode ser utilizada para auxiliar na tomada de decisão ou para ter um alvo na hora de comprar ou vender a ação, portanto os valores obtidos com a predição são bem próximos ao valor real, podendo ser considerados satisfatórios.

Uma alternativa ideal para auxiliar nas ações tomadas no mercado financeiro é a junção da regressão linear com um dos métodos de classificação, aumentando ainda mais as chances de acerto, tomando a predição feita pela

regressão um possível alvo e a predição do classificador numa possível direção.

Com relação a trabalhos futuros é interessante o estudo de métodos que possam gerar linhas de suporte e resistência, linhas onde o preço tende a ter mais volume de compra e venda.

REFERÊNCIAS

ALI, N., NEAGU, D. & TRUNDLE, P. Evaluation of k-nearest neighbour classifier performance for heterogeneous data sets. *SN Appl. Sci.* 1, 1559 (2019). <https://doi.org/10.1007/s42452-019-1356-9>

CAMPOS, R.. **Árvores de Decisão**. 2017. Disponível em: <https://medium.com/machine-learning-beyond-deep-learning/%C3%A1rvores-de-decis%C3%A3o-3f52f6420b69>. Acesso em: 14 dez. 2021.

CARVALHO, V. P.. **Previsão de séries temporais no mercado financeiro de ações com o uso de rede neural artificial**. 2018. 59 f. Dissertação (Engenharia Elétrica) - Universidade Presbiteriana Mackenzie, São Paulo, 2018. Disponível em: <http://tede.mackenzie.br/jspui/bitstream/tede/3710/6/VALTER%20PEREIRA%20DE%20CARVALHO.pdf>. Acesso em: 15 dez. 2021.

DANTAS, S. G. **Utilização de aprendizado por reforço para operações em bolsa de valores**. 2017. 75 f. Trabalho de Conclusão Curso (Bacharelado em Engenharia Elétrica)— Universidade de Brasília, Brasília, 2017. Disponível em: <https://bdm.unb.br/handle/10483/28761>. Acesso em: 15 dez. 2017.

DIDÁTICA Tech Inteligência Artificial & Data Science: O que é e como funciona o algoritmo KNN?. O que é e como funciona o algoritmo KNN?. 2020. Disponível em: <https://didatica.tech/o-que-e-e-como-funciona-o-algoritmo-knn/>. Acesso em: 14 dez. 2021.

GIACOMEL, F. S. **Um método algorítmico para operações na bolsa de valores baseado em ensembles de redes neurais para modelar e prever os movimentos dos mercados de ações**. 2016. Dissertação (Mestado em Ciência da Computação) – Porto Alegre, RS, 2016. Disponível em: <https://www.lume.ufrgs.br/bitstream/handle/10>

183/134586/000988403.pdf?sequence=1&isAllo wed=y. Acesso em: 15 dez. 2021.

IGARASHI, W.; VALDEVIESO, G. S.; IGARASHI, D. C. C. Análise de sentimentos e indicadores técnicos, a partir da correlação dos preços de ações com a polaridade de notícias do mercado financeiro. *Braz. J. of Bus.*, Curitiba, v. 3, n. 1, p. 470-486 jan./mar. 2021. Disponível em: https://admpg.com.br/2020/anais/arquivos/08132020_130853_5f3564e14a5c9.pdf. Acesso em: 15 dez. 2021.

KHAIDEM, L.; SAHA, S.; DEY, S. R. Predicting the direction of stock market prices using random forest. arXiv preprint arXiv:1605.00003, 04 2016. Acesso em: 14 dez. 2021.

JOSÉ, I.. **KNN (K-Nearest Neighbors)**. Disponível em: <https://medium.com/brasil-ai/knn-k-nearest-neighbors-1-e140c82e9c4e>. Acesso em: 14 dez. 2021.

KAUPA, P. H. **Aplicação de técnicas da inteligência artificial na seleção de ações para investimento na bolsa de valores de São Paulo**. 2013. Mestrado (Engenharia de Produção) – Univove, São Paulo SP, 2013. Disponível em: <http://bibliotecatede.uninove.br/handle/tede/200>. Acesso em: 15 dez. 2021.

LIMA, M. L.. **Um modelo para predição de bolsa de valores baseado em mineração de opinião**. 2016. Dissertação (Mestrado em Engenharia de Eletricidade) – Universidade Federal do Maranhão, São Luis, MA, 2016. Disponível em: <https://tedebc.ufma.br/jspui/handle/tede/297>. Acesso em: 15 dez. 2021.

NALEPA, J.; KAWULOK, M. Selecting training sets for support vector machines: a review. *Artif Intell Rev.*, v. 52, 857–900, 2019. <https://doi.org/10.1007/s10462-017-9611-1>.

PATEL, S.. **Chapter 2: SVM (Support Vector Machine) — Theory**. 2017. Disponível em: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>. Acesso em: 14 dez. 2021.

PONTES, P. **Inteligência artificial nos investimentos**. 2011. Disponível em: <https://books.google.com.br/books?hl=pt->

BR&lr=&id=A-V7DwAAQBAJ&oi=fnd&pg=PA4&dq=Inteligencia+artificial+Bolsa+de+valores&ots=Si2PSQJyYP&sig=X5NFq3RX6yJYcKPiq5Tbzavl_Vw#v=onepage&q=Inteligencia%20artificial%20Bolsa%20de%20valores&f=false. Acesso em: 15 dez. 2021.

SANTOS, G. C. **Algoritmos de machine learning para previsão de ações da B3**. 2020. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Uberlândia, Uberlândia, 2020. DOI <https://doi.org/10.14393/ufu.di.2020.640>.

Disponível em: <https://repositorio.ufu.br/bitstream/123456789/29897/7/AlgoritmosMachineLearning.pdf>. Acesso em: 15 dez. 2021.

SCHEREMETA, L. J. P. **Desenvolvimento e avaliação de rede neural aplicada em operações em bolsa de valores**. 2021. Trabalho de Conclusão de Curso (Bacharel em Engenharia de Controle e Automação) - Instituto de Ciência e Tecnologia de Sorocaba, Universidade Estadual Paulista (UNESP), Sorocaba, 2021. Disponível em: https://www.sorocaba.unesp.br/Home/Graduacao/EngenhariadeControleeAutomacao/galdenoro1906/final-tcc-_lucas_scheremeta_2021.pdf. Acesso em: 15 dez. 2021.

SILVA, A. F. **Estudo de Caso: Estratégia de lucro na bolsa de valores utilizando algoritmos preditivos**. 2021. Trabalho de Conclusão de Curso (Bacharel em Ciências da Computação) - Pontifícia Universidade Católica de Goiás, Goiânia, GO, 2021. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/1510>. Acesso em: 15 dez. 2021.

TicTacTec LLC. **TA-Lib: Technical Analysis Library**. 2012. Disponível em: <https://ta-lib.org/http://www.ta-lib.org/>. Acesso em: 14 dez. 2021.