

PREVISÃO DE PREÇOS MÁXIMOS E MÍNIMOS PARA GREEN REITS

Data de aceite: 01/02/2024

Hugo Martins Teixeira

Universidade Federal de Uberlândia (UFU)

Daniel Vitor Tartari Garruti

Universidade Federal de Uberlândia (UFU)

Flávio Luiz de Moraes Barboza

Universidade Federal de Uberlândia (UFU)

RESUMO: A academia postula duas hipóteses relevantes sobre o mercado financeiro, sendo uma que supõe a impossibilidade de prever os preços dos ativos e outra que acredita ser possível. Logo, é importante realizar estudos que verifiquem essas suposições. Diante disso, foram desenvolvidos métodos preditivos que auxiliam essas pessoas em suas buscas para tomarem uma decisão, tentando sempre lucrar o máximo possível mantendo uma perda baixa. Nos dias atuais é possível notar um aumento na utilização de Redes Neurais Artificiais (RNA) para realizar essa previsão, por possuírem uma capacidade em lidar com uma grande gama de conhecimento, podendo assim serem utilizadas para prever preços no mercado financeiro. Outro tópico importante e discutido atualmente

é a sustentabilidade nos investimentos, fazendo os investidores buscarem lucros com o mercado imobiliário financeiro sem deixarem de lado a preocupação com o que as empresas que elas investem fazem para melhorar os impactos deixados na natureza e na sociedade. Desta maneira, esse estudo visa realizar uma previsão de preços máximos e mínimos através de RNA com REITs considerados sustentáveis devido às suas certificações ESG e estimar em qual hipótese de mercado os ativos analisados se encaixam. Para isso, foram utilizados dados de 18 *green* REITs, do ano de 2018 até 2022. Os modelos escolhidos para realizar a previsão desses ativos foram o *Long Short Term Memory* (LSTM) e o *Random Walk* (RW). Os resultados encontrados pelo LSTM foram comparados aos do RW para verificar qual dos modelos apresentam uma previsão de preços máximos e mínimos mais precisa. Eles indicaram que o modelo RW obteve um melhor desempenho sobre o LSTM na lista de ativos utilizada. Dessa forma, foi possível inferir que os preços dos *green* REITs analisados foram previstos de melhor maneira pelo RW, corroborando assim para a hipótese de mercado eficiente, onde os preços dos ativos já refletem as informações do mercado.

1 | INTRODUÇÃO

As hipóteses de mercado são teorias que buscam descrever o funcionamento dos mercados financeiros e a possibilidade de obter ganhos superiores à média de benchmarks ou não. Duas das principais hipóteses nesse campo são a Hipótese do Mercado Eficiente (HME) e a Hipótese do Mercado Adaptativo (HMA). O primeiro é um conceito que descreve um mercado em que os preços dos ativos refletem completamente todas as informações disponíveis. Isso significa que não é possível obter lucros consistentes através de estratégias de negociação, uma vez que qualquer informação relevante já está refletida nos preços dos ativos (FAMA, 1970). Ou seja, um retorno acima da média do mercado é considerado um bom retorno.

Já a segunda hipótese, que se opõe a HME, considera que os investidores formam suas expectativas com base em informações limitadas e imperfeitas, aprendendo e se adaptando às condições do mercado (LO, 2004). Ao invés de pressupor que os investidores têm acesso a todas as informações relevantes, como na eficiência de mercado, a teoria do mercado adaptativo reconhece que os preços dos ativos são influenciados por mudanças nas expectativas e comportamentos dos investidores, resultando em padrões e tendências observáveis nos mercados financeiros. Diante disso, é possível realizar previsões de preços futuros dos ativos no mercado financeiro

Uma classe de ativos que fazem parte e podem ser influenciados pelos movimentos de mercado são os *Real Estate Investment Trusts* (REITs). Eles são uma forma de investimento que permite aos investidores negociarem no mercado imobiliário sem precisar comprar imóveis propriamente ditos, eles podem se expor a esse mercado através de ações de REITs compradas na bolsa de valores e obter lucros com a variação dos valores e aluguéis. Feng, Price e Sirmans (2011) defendem a importância dos REITs em seu estudo. Os autores aderem a ideia de que os REITs oferecem aos investidores uma oportunidade de investir no mercado imobiliário sem comprar propriedades tangíveis. Além disso, também serve como um captador de recursos para o negócio imobiliário, permitindo que essas empresas acumulem capital para novos empreendimentos. Por fim, os REITs ajudam os investidores a ampliar seu portfólio de investimentos, investindo em várias propriedades e ativos associados a imóveis.

Já os *green REITs* surgiram com a crescente conscientização de práticas ambientais sustentáveis e da responsabilidade social no âmbito imobiliário. Para minimizar estragos e reduzir impactos sociais, ambientais e de governança, esse mercado buscou formas de investir em imóveis verdes, que integram critérios rigorosos de uso responsável de recursos, diminuição da demanda energética e práticas mais responsáveis ambientalmente no ramo da construção de seus ativos. Esses REITs, assim como será mostrado ao

decorrer do estudo, buscam participar, adquirir e desenvolver propriedades que tenham uma série de certificações ESG, como o *Leadership in Energy and Environmental Design* (LEED) e o Energy Star. Através dessas práticas adotadas pelas empresas, a captação de investidores que se preocupam com práticas mais verdes foi maior e houve também por parte do governo e dos órgãos reguladores incentivos e políticas para engajar esse tipo de construção. Os *green* REITs proporcionam para aqueles que querem investir de maneira rentável e ainda assim gerar um retorno ambiental positivo, apoiando então um setor imobiliário mais sustentável e contribuindo para a sociedade como um todo.

Fundos de investimento como *green* REITs são especializados em investir em reformas ou propriedades verdes que apoiem a eficiência energética e a sustentabilidade. De acordo com o estudo de Eichholtz, Kok e Yonder (2012), aumentar a participação de propriedades verdes no portfólio de um REIT em apenas um por cento pode levar a aumentos significativos nos retornos do investimento. Especificamente, um aumento de até 7,92% para propriedades com certificação LEED e 0,66% para propriedades com certificação Energy Star torna-se plausível. Aumentar o número de propriedades verdes nessas carteiras também influencia o fluxo de caixa operacional e a proporção de recursos das operações em relação à receita total de maneira positivamente correlacionada.

Dias (2006) defende que a sustentabilidade seria denominada como uma busca entre o equilíbrio da justiça social e preservação do meio ambiente sem deixar de lado os interesses econômicos. Ademais, para as empresas, essa sustentabilidade seria um pilar para continuarem existindo em um futuro distante, porque a falta dela, tanto socialmente quando ambientalmente falando, iria afetar a forma como é vista, além de existir a possibilidade de prejudicar seus lucros por falta de atração de investimentos e captação de clientes novos (KRAEMER, 2005).

No entanto, para obter lucros com tais ativos é importante realizar a previsão de valores futuros. Como realizado por Li *et al.* (2022) para prever os preços de REITs utilizando modelo de LSTM e obtendo resultados interessantes.

Diante disso, o objetivo desse estudo é prever os preços máximos e mínimos diários de *green* REITs, utilizando o modelo LSTM de Inteligência Artificial. Para análise dos resultados, foram analisadas métricas de erros e valor acumulados das previsões deste modelo e do *Random Walk*. Verificou-se um desempenho baixo do modelo implementado em questão, o que indica uma possível eficiência desses ativos, defendido por Fama (1970). No entanto, por se tratar de negociações diárias, pode ser que tais resultados se devam pela não possibilidade de acesso aos dividendos.

Não obstante, é possível observar que este estudo apresenta resultados interessantes a gestores de carteiras e investidores de maneira geral. No entanto é preciso uma análise mais profunda desses ativos. Como estudos futuros, sugere-se uma análise da janela temporal maior para a verificação das hipóteses em questão, além de outros períodos.

Além dessa seção introdutória, o artigo apresenta as seguintes seções. Referencial teórico, abordando os temas de hipóteses de mercado financeiro, o modelo LSTM, os REITs como um todo e por fim os *green* REITs. Na metodologia é discutido os ativos que serão utilizados, os possíveis resultados que as análises poderão chegar, a utilização do modelo LSTM em si e as métricas de erro que serão usadas. Em seguida, é discutido os resultados e o trabalho se encerra com as conclusões

2 | REFERENCIAL TEÓRICO

2.1 Hipóteses do mercado financeiro

Uma das primeiras hipóteses do mercado financeiro é a proposta por Eugene Fama, a Hipótese de Mercado Eficiente (HME). Essa hipótese argumenta que os preços dos ativos financeiros refletem rapidamente e eficientemente todas as informações disponíveis no mercado, tornando extremamente difícil para os investidores obterem retornos regulares acima da média do mercado. Fama (1970) distingue três formas de eficiência: a forma fraca afirma que os preços dos ativos representam todos os dados anteriores, incluindo preços históricos e retornos dos ativos; na semiforte, os preços dos ativos refletem todas as informações públicas disponíveis, incluindo informações divulgadas pelas empresas, dados econômicos e notícias pertinentes; e a forte afirma que os preços dos ativos refletem instantaneamente todas as informações disponíveis.

Um modelo frequentemente utilizado para apoiar a HME é o *Random Walk*. Com base nisso, o movimento dos preços dos ativos financeiros ao longo do tempo é caracterizado como imprevisível. Ele argumenta que as variações de preço dos ativos são essencialmente aleatórias, impossibilitando a previsão de mudanças futuras com base em informações passadas. Como resultado, tentativas de prever movimentos de preços por meio de análise histórica ou reconhecimento de padrões são inúteis (JIRASAKULDECH; KNIGHT, 2005).

Portanto a HME afirma que, como os mercados financeiros funcionam de forma eficiente, é difícil para os investidores superarem regularmente o desempenho médio do mercado baseado em dados públicos. Diante disso, o conceito fundamental da hipótese de mercado eficiente é o modelo *random walk*, o qual sugere que prever o comportamento dos preços é um desafio devido à natureza aleatória e imprevisível dos movimentos dos preços dos ativos financeiros (FAMA, 1991), sendo este utilizado para análise dos movimentos.

Por outro lado, surge a Hipótese do Mercado Adaptativo (HMA), a qual contesta a HME. Em seu estudo, Lo (2004) por meio da HMA sugere que os mercados são compostos por agentes que aprendem, crescem e se adaptam ao seu entorno. Sua hipótese se baseia na ideia de que os agentes do mercado financeiro são capazes de aprender com o tempo e ajustar suas estratégias de investimento com base nas informações disponíveis e nas

respostas do mercado. Logo, os agentes podem usar os resultados de suas decisões anteriores como aprendizado, desafiando a visão tradicional de mercados eficientes. Em vez disso, ele sustenta que os mercados são sistemas complexos em constante mudança onde os agentes procuram oportunidades e ajustam suas estratégias à medida que aprendem uns com os outros e com seu ambiente.

Isso sugere que o comportamento adaptativo dos agentes pode afetar os preços dos ativos, destacando a importância da evolução e do aprendizado na formação dos preços. Logo, os agentes podem aprimorar suas estratégias de investimento e previsões de mercado com recursos sofisticados, como modelos de aprendizado de máquina e Inteligência Artificial, como realizado por Santos *et al.* (2021).

2.2 Long Short Term Memory

Uma solução proposta para aprimorar as previsões é a arquitetura *Long Short Term Memory* (LSTM). Diferentemente dos métodos mais simples, o LSTM permite a transmissão contínua de erros por meio de estados internos exclusivos. Essa característica possibilita o aprendizado efetivo de informações ao longo de períodos extensos, mesmo ao lidar com sequências de entrada ruidosas e incompressíveis. Além disso, o LSTM se destaca na preservação da memória armazenada, protegendo-a de interferências de entradas irrelevantes. O algoritmo de aprendizado baseado em gradiente implementado no LSTM garante o fluxo eficiente e ininterrupto de erros, evitando que eles se tornem exponencialmente grandes ou desapareçam com o tempo (HOCHREITER; SCHMIDHUBER, 1997).

Composto por unidades especiais de redes neurais recorrentes chamadas “*gates*”, o modelo LSTM ajusta pesos e trunca gradientes quando suas informações são consideradas irrelevantes. O fluxo de informações na rede é controlado principalmente por três unidades: a porta de entrada, a porta de esquecimento e a porta de saída. Em comparação com os modelos BP (*backpropagation*), o LSTM possui maior eficácia na extração de recursos temporais e possui capacidade suficiente para memória de tempo. Sua eficiência se manifesta em sua capacidade de discriminar exemplos recentes e antigos para obter previsões de movimento de preço de fechamento mais precisas (WANG; GAO, 2018).

As técnicas de inteligência artificial, incluindo o LSTM, têm sido utilizadas para previsões no mercado financeiro. O estudo de Moghar e Hamiche (2020) usou o LSTM para prever os valores futuros do mercado de ações. O objetivo principal do estudo foi construir um modelo para prever os valores futuros do mercado de acionário usando Redes Neurais Recorrentes (RNN) e, especificamente, a arquitetura LSTM. O artigo refere-se aos resultados promissores do modelo, como exemplo o ativo NKE, que para 12 épocas de treinamento a precisão dos resultados de previsão do LSTM foi de 0,0019, já para 50 épocas o modelo obteve um resultado de 0,001, concluindo que a acurácia das previsões

aumenta quando o número de épocas também aumenta. Portanto, o modelo foi utilizado no artigo como uma ferramenta eficaz para prever os valores futuros do mercado de ações, capturando dependências de longo prazo e padrões complexos nos dados financeiros.

Para prever movimentos direcionais fora do período de amostra para as ações constituintes do S&P 500 de 1992 a 2015, Fischer e Krauss (2018) utilizaram o modelo LSTM. Os resultados do modelo LSTM foram avaliados em comparação com os de outros métodos de classificação, como *Random Forest* (RF), *Deep Neural Net* (DNN) e *Logistic Regression Classifier* (LOG). Os resultados revelaram que, em termos de retornos e métricas de risco-retorno, as redes LSTM superaram esses métodos de classificação sem memória.

Outro exemplo do uso do modelo, mas no mercado de REITs é o do Li *et al.* (2022) onde utilizou o LSTM no mercado financeiro para prever o desempenho. Eles treinaram o modelo com dados históricos de transações financeiras e utilizaram a arquitetura de rede neural para capturar dependências de longo prazo nas séries temporais dos REITs. Os dados foram divididos em grupos de 6 dias, com os primeiros 5 dias como entrada (X) e o último dia como saída (Y). O modelo foi treinado para prever os valores dos REITs com base nesses grupos de dados. O resultado encontrado foi que o LSTM teve uma melhor precisão de previsão para o mercado de REITs em comparação com métodos tradicionais. Eles realizaram testes com 10 ativos selecionadas aleatoriamente e obtiveram resultados com taxas de erro tão baixas quanto quatro por 10.000. O modelo LSTM foi considerado adequado para análise e previsão do mercado de REITs, superando os métodos tradicionais aplicados aos fundos imobiliários.

2.3 *Real Estate Investment Trust* (REIT)

Os REITs são uma das opções de quem busca investir no mercado imobiliário no Estados Unidos sem precisar adquirir uma propriedade propriamente dita. Eles são empresas que possuem e gerenciam imóveis para se gerar renda de diversos tipos de propriedades dentro do setor. Além disso, são negociados na bolsa de valores e precisam atender uma série de critérios. De acordo com Li e Lei (2011), um *Real Estate Investment Trust* (REIT) é uma empresa que possui e, na maioria dos casos, opera imóveis que geram renda. Ainda de acordo com a pesquisa, após um grande crescimento impulsionado por várias mudanças na legislação, os REITs negociados publicamente nos Estados Unidos se tornaram um importante veículo de investimento imobiliário com uma capitalização de mercado de US \$ 475 bilhões em 2007.

Esse crescimento pode ser explicado pelos diversos benefícios que esses investimentos oferecem aos investidores. Segundo Odusami (2021), esses benefícios estão relacionados a vários motivos, incluindo fluxos de caixa estáveis e seguros devido à natureza contratual dos arrendamentos de imóveis comerciais, baixa sensibilidade a

mudanças nas taxas de juros, diversificação do portfólio e vínculos com ações e títulos. Excelência relevante em diferentes períodos de tempo. Os REITs são regulamentados por leis específicas e devem atender a certos requisitos para se qualificarem como REITs, incluindo a distribuição de pelo menos 90% de seus ganhos como dividendos aos acionistas.

Além disso, a CVM (U.S. *Securities and Exchange Commission*) estabelece que: i) devem derivar pelo menos 75% de sua receita bruta de fontes imobiliárias, como aluguel, juros de hipotecas e ganhos de capital de vendas de imóveis, e o restante pode vir de outras fontes, como juros de títulos e dividendos de ações. ii) investir pelo menos 75% de seus ativos em imóveis, hipotecas ou títulos lastreados em hipotecas. iii) possuir pelo menos 100 acionistas e não pode ter mais de 50% de suas ações detidas por cinco ou menos acionistas.

Eles são divididos em três categorias: REITs de capital próprio, REITs hipotecários e REITs híbridos. Cada categoria tem requisitos adicionais específicos que devem ser cumpridos para se qualificar como um REIT. (“Sec.gov”, 2017).

De acordo com o trabalho realizado por Olanrele (2014), reconhecer a importância das tendências REIT é crucial. O autor enfatiza a necessidade de investidores e empresas detentoras de ativos terem a oportunidade de selecionar suas opções de investimento e métodos de gerenciamento de portfólio. Para antecipar o desempenho futuro de um REIT, vários aspectos são avaliados, como por exemplo: valor patrimonial líquido, valor do portfólio, preço da ação e alavancagem. Ao analisar esses fatores, decisões de investimento informadas podem ser tomadas. As previsões de REITs são feitas usando modelos estatísticos e não devem ser consideradas como garantia de desempenho futuro. Ainda segundo o autor, a análise dos REITs pode destacar as tendências do mercado e revelar como as mudanças econômicas e políticas impactam seus resultados.

2.4 Green REITs

As práticas *Environmental, Social and Governance* (ESG) vêm crescendo a cada ano e a cobrança da sociedade com as empresas também. Essa prática é importante porque não leva em consideração apenas o quanto uma empresa gera de lucro, mas também qual é o impacto ambiental, social e de governança corporativa que é gerado para que essa empresa possa conseguir se alavancar financeiramente. Isso quer dizer que esse lado sustentável é levado em consideração para que ela possa se qualificar e ter uma boa imagem perante a sociedade. A ESG ajuda a promover a sustentabilidade e apela para um lado de responsabilidade social nas empresas, o que impacta diretamente a todos em fatores sociais e do meio ambiente. Além disso, ela também auxilia os investidores a tomarem decisões mais conscientes de onde investir seu capital, levando em conta não apenas o potencial de lucro que isso pode gerar, mas também o que as empresas em potencial desse investimento fazem com relação a essas práticas (HALBRITTER;

DORFLEITNER, 2015).

Os *green* REITs, também conhecido como fundos verdes, são um tipo de ativo semelhante aos REITs convencionais, porém com detalhes que os diferem deles. Esses fundos se preocupam em estar alinhados com ESG, ou seja, os imóveis que essas empresas possuem são envolvidos com a infraestrutura e a prática sustentável apresentados acima.

Como os REITs são empresas que possuem imóveis em diversas áreas do mercado imobiliário, também são atingidos por investidores que buscam opções rentáveis e socialmente responsáveis para colocarem seu dinheiro. Com isso as empresas detentoras desses REITs começaram a optar por adicionar cada vez mais ativos com essas práticas, como forma de conseguirem captar o maior número de investidores e de diminuir o impacto ambiental, social e de governança causado pela construção de seus empreendimentos.

Essa prática das empresas para obter vantagem sobre seus concorrentes é descrita em Feng e Wu (2021), que discutem a relação entre informações sobre práticas ESG, financiamento de dívida REIT e valor próprio das empresas. Os autores concluem que os REITs com altos níveis de práticas e divulgações ESG apresentam níveis mais baixos de custos de dívida, maior flexibilidade financeira e valores de mercado mais altos. Os autores também sugerem que a disseminação ativa de informações ESG pode ter um impacto favorável no financiamento da dívida e no valor das empresas REIT devido à alta transparência corporativa. O estudo utilizou dados doGRESB, o relatório ESG padrão para o setor imobiliário global.

Outro estudo que comprova a possibilidade de um maior desempenho operacional relacionado a REITs que possuem uma boa performance na escala ESG é o realizado por Aroul, Sabherwal e Villupuram (2022), que investigam a conexão entre os REITs ESG e competência em relação ao seu desempenho na operação. Foi descoberto pelos autores que os REITs que detêm uma boa participação na escala ESG possuem uma operação mais eficiente e um maior desempenho. Os autores sugerem que REITs que possuem uma fraca relação com ESG devem se preocupar com a melhoria da economia de escala e seu desempenho operacional para depois adotar as medidas sustentáveis. O período de estudos foi nos anos de 2019 e 2020, realizado nos Estados Unidos com ativos negociados publicamente.

Sah, Miller e Ghosh (2013) mostraram em seus estudos que empresas consideradas *green* REITs possuem um retorno positivo em seu valor empresarial e um efeito sobre ativos mais elevados se comparado com outras empresas não consideradas *green* REITs. Foram usados REITs participantes do Energy Star e LEED – uma iniciativa do U.S *Green Building Council* que leva em consideração diversos fatores em seu processo na construção de edifícios - como medida para avaliar se um ativo é verde. Como resultado final, as empresas consideradas verdes conseguiram um retorno de 5,68% mais alto nos anos de 2005 a 2010, e ainda destacam o crescente surgimento de mais empresas desse tipo ao decorrer dos anos.

Nos Estados Unidos, observou-se que edifícios de escritórios certificados pelo LEED e Energy Star têm aluguéis e preços de transação mais altos em comparação com edifícios não certificados, de acordo com pesquisas. O estudo também constatou que a sustentabilidade dos REITs desempenha um papel positivo em seu desempenho operacional em termos de retorno sobre os ativos, retorno sobre o patrimônio líquido e proporção de fundos operacionais em relação à receita total. No entanto, não há correlação significativa entre a «verde» das carteiras de propriedades e retornos anormais das ações. Isso implica que os preços das ações já consideraram os fluxos de caixa adicionais gerados por investimentos imobiliários mais eficientes. Em conclusão, investir em edifícios verdes certificados ou reformas de edifícios comerciais apresenta aos REITs amplas oportunidades para aumentar seus retornos operacionais. Os autores analisaram 128 ativos e observaram que as propriedades certificadas pela Energy Star são mais vistas em seus portfólios (EICHHOLTZ; KOK; YONDER, 2012).

3 | METODOLOGIA

3.1 Dados

O presente estudo utiliza dados de 18 REITs com certificações ESG utilizados também na pesquisa de Eichholtz, Kok e Yonder (2012), considerados *green*, listados em bolsa e negociados publicamente. Os ativos possuem os seguintes *tickers*: AKR, BDN, BXP, CUZ, DLR, EQC, FR, FRT, HIW, HPP, KRC, OFC, PDM, PLD, REG, SLG, SPG, VNO.

Foram reunidos os preços diários de abertura do ativo, preço máximo atingido no dia, preço mínimo correspondente e o preço de fechamento - conhecidos também como *Open*, *High*, *Low* e *Close* - de todos os REITs mencionados, com dados de 03/07/2018 a 30/12/2022. Logo após a coleta de dados dos ativos, foi realizada uma previsão de máximos e mínimos utilizando o modelo LSTM e o resultados foram comparados com o modelo RW.

Se os resultados encontrados pelo LSTM forem piores que os valores do RW, a HME é aceita e pode significar que o mercado é eficiente, ou seja, as informações disponíveis publicamente já estão totalmente refletidas nos preços dos ativos, tornando difícil obter retornos consistentemente acima da média com base em algoritmos de previsão, assim como proposto por Fama (1970).

Já se o modelo conseguir superar o RW, a HMA é aceita e uma possível explicação seria que o mercado é adaptativo e, portanto, previsível, visto que nessa teoria os preços dos ativos são influenciados por mudanças nas expectativas e comportamentos dos investidores, permitindo a identificação de padrões e tendências, como proposto por Lo (2004).

3.2 LSTM

Após realizar a coleta de dados, a estratégia adotada pelo presente artigo foi o LSTM, que é um modelo de rede neural (RNN) utilizado para solucionar problemas de previsão. O modelo foi apresentado por Hochreiter e Schmidhuber (1997). Os autores concluíram que comparação com outras abordagens, como o algoritmo de retro propagação através do tempo (BPTT) e o algoritmo de retro propagação de resíduos temporais (RTRL), a LSTM demonstrou desempenho superior em experimentos realizados. A LSTM pode resolver tarefas complexas, como prever elementos finais de sequências com padrões locais imprevisíveis e lidar com intervalos de tempo grandes. Esses resultados demonstram que a arquitetura LSTM é eficaz na superação dos problemas de outras redes recorrentes.

Na previsão de *Real Estate Investment Trusts* (REITs), o modelo LSTM (*Long Short-Term Memory*) vai ser aplicado por meio de um procedimento sistemático. Inicialmente, são coletados dados históricos dos *green* REITs, que consistem em séries temporais que abrangem preços de abertura e fechamento de mercado. Posteriormente, os dados sofrem normalização durante o estágio de pré-processamento para obter uniformidade em todas as variáveis. Por fim, os dados são particionados em conjuntos de treinamento e teste. Dentro da célula, o modelo foi construído usando uma arquitetura de redes neurais recorrentes. As células LSTM, que foram implementadas durante a etapa de construção, são essenciais para manter as informações ao longo do tempo e capturar dependências de longo prazo nas sequências de dados. Para controlar o fluxo de informações dentro da célula, os portões de entrada, esquecimento e saída são incorporados em cada célula.

O objetivo é minimizar o erro entre as previsões feitas pelo modelo LSTM e os valores reais dos preços dos REITs. Para conseguir isso, será empregado algoritmos de otimização, como gradiente descendente, para otimizar os pesos e parâmetros da rede neural. Os dados de treinamento são então alimentados em sequências temporais para treinar o modelo. Para avaliar o desempenho do modelo LSTM, será comparado suas previsões com os valores reais dos preços dos REITs usando métricas de avaliação comuns, como MAE, MAPE e RMSE. Fazendo assim uma previsão de mínimos e máximos dos ativos selecionados.

3.3 Métricas de erro

As métricas de erro são medidas utilizadas para qualificar como o modelo de regressão que foi realizado se desempenhou e o quanto ele foi preciso em relação às suas previsões. As métricas que serão realizadas no artigo são a MAE (Erro Médio Absoluto), MAPE (Erro Percentual Médio Absoluto) e a RMSE (Raiz do Erro Quadrático Médio), assim como utilizado por Laboissiere, Fernandes e Lage (2015) em seus estudos, realizados para prever preços máximos e mínimos de ações. Através dessas métricas, se pode obter informações sobre aspectos do quanto uma previsão pode estar errada e são utilizadas por

estudiosos da área de finanças e da ciência de dados.

O MAE (Erro Médio Absoluto) é utilizado para calcular a média dos erros absolutos, isto é, ele é utilizado para medir a média da diferença entre esses valores previstos absolutos e os valores que foram observados. Sua fórmula é realizada da seguinte forma:

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |p_t - \bar{p}_t|,$$

onde n é o número de amostras, p_t é o valor observado para cada amostra e \bar{p}_t é a previsão de valor do modelo para cada amostra. Quanto menor o valor do MAE, melhor se desempenha o modelo.

O MAPE (Erro Percentual Médio Absoluto) é uma medida de erro relativo assim como o MAE, entretanto ele é expresso em forma de porcentagem, já o MAE é expresso na mesma unidade do objetivo original. Sua fórmula é dada pela seguinte equação abaixo:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|p_t - \bar{p}_t|}{p_t},$$

Um valor baixo para o MAPE quer dizer que as previsões realizadas estão perto dos valores que foram observados, ou seja, o modelo está em um bom caminho, enquanto um valor alto para o MAPE significa que as previsões que foram feitas estão longe dos valores que foram observados e o modelo precisa passar por uma melhoria.

Já a RMSE (Raiz do Erro Quadrático Médio) é calculada fazendo-se a raiz quadrada da média dos quadrados dos erros, no qual seu erro bruto é a diferença entre o valor que o modelo previu com o valor real acontecido. Ela é muito utilizada para poder se trabalhar quando o objetivo do modelo foca em acertar valores mais altos. É importante ressaltar que isso faz com que ela ganhe uma maior sensibilidade a esses valores mais altos, fazendo com que seja possível que ocorra uma distorção da métrica. Sua equação é calculada da seguinte maneira:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (p_t - \bar{p}_t)^2},$$

Os resultados da RMSE indicam o valor do desvio médio que as previsões realizadas tiveram do alvo a ser atingido. Quanto menor o resultado do valor dessa métrica, melhor o modelo está se saindo de modo geral, mas é importante que se estabeleça uma referência para ser utilizada como desempenho.

O processo inteiro de modelagem e do cálculo das métricas de erro foram escritos e realizados em linguagem Python.

4 | RESULTADOS

4.1 Análise das métricas de erro

Após as análises serem realizadas, a eficácia das previsões foi testada através de MAE, MAPE E RMSE – demonstradas anteriormente com suas respectivas equações – e o resultado dessas métricas será mostrado a seguir, respectivamente pelas Tabelas 1, 2 e 3.

O resultado da métrica de MAE, que trabalha com a medida dos erros absolutos, mostrou que alguns ativos possuem maior discrepância em relação aos outros. O ativo em que melhor se performou, por possuir o resultado mais próximo de 0, em relação aos valores totais do LSTM e do RW foi o BDN com um valor de erro da previsão LOW de 0,15 e 0,16 respectivamente e HIGH de 0,14 e 0,16. Em contrapartida, quem menos performou foi o SPG com um valor total de LOW de 2,12 e 1,83 e HIGH de 2,51 e 1,74, indicando assim o BDN como uma melhor opção em relação aos demais.

Além do BDN, que possui os melhores resultados, cita-se outros 3 melhores em relação aos analisados, sendo eles: EQC, PDM e AKR. Quando verificado os piores, nota-se além do SPG, os ativos: DLR, BXP e FRT. Observa-se também, uma relação entre o LSTM com o RW, onde ativos que possuem um LSTM maior e menor, tendem a seguir a mesmas proporções no RW, que calcula a aleatoriedade dos ativos.

MAE	Preço mínimo (LOW)		Preço máximo (HIGH)	
	Modelo LSTM	<i>Random Walk</i>	Modelo LSTM	<i>Random Walk</i>
AKR	0,27	0,30	0,25	0,28
BDN	0,15	0,16	0,14	0,16
BXP	1,41	1,35	1,29	1,30
CUZ	0,55	0,41	0,41	0,40
DLR	1,52	1,57	1,32	1,50
EQC	0,24	0,21	0,31	0,20
FR	0,40	0,44	0,48	0,42
FRT	1,24	1,36	1,34	1,26
HIW	0,50	0,50	0,45	0,46
HPP	0,47	0,36	0,46	0,36
KRC	1,07	0,78	1,79	0,75
OFC	0,31	0,32	0,25	0,30
PDM	0,65	0,23	0,31	0,22
PLD	1,13	1,19	1,10	1,11
REG	0,67	0,76	0,66	0,71
SLG	1,01	1,04	1,07	1,08
SPG	2,12	1,83	2,51	1,74
VNO	0,71	0,65	0,58	0,64

TABELA 1 – MAE (Erro Médio Absoluto dos Preços mínimos e máximos).

Fonte: Elaborado pelos autores.

Laboissiere, Fernandes e Lage (2015) realizaram a aplicação de MAE em seu respectivo estudo, relacionado com a previsão de máximos e mínimos de ações brasileiras. Os resultados para suas ações foram o seguinte: CPFE3 com um MAE de 0,0009 para máximos e 0,0042 para mínimos; CEBR3 com 0,0012 para máximos e 0,0045 para mínimos, por último, CSRN3 com 0,0014 para máximos e 0,057 para mínimos. A comparação de resultados pode indicar que a carteira dos autores citados, teoricamente possuem uma menor média dos erros calculados e um resultado mais preciso do que este estudo no geral.

MAPE	Preço mínimo (LOW)		Preço máximo (HIGH)	
	Modelo LSTM	<i>Random Walk</i>	Modelo LSTM	<i>Random Walk</i>
AKR	1,53	1,66	1,39	1,50
BDN	1,31	1,42	1,19	1,33
BXP	1,38	1,31	1,23	1,24
CUZ	1,64	1,27	1,21	1,20
DLR	1,18	1,22	0,99	1,13
EQC	0,82	0,72	1,08	0,66
FR	0,96	1,06	1,12	0,97
FRT	1,24	1,34	1,27	1,20
HIW	1,28	1,28	1,11	1,16
HPP	2,04	1,56	2,03	1,51
KRC	1,64	1,26	2,60	1,19
OFC	1,20	1,24	0,95	1,15
PDM	4,39	1,42	1,85	1,30
PLD	1,14	1,18	1,14	1,06
REG	1,24	1,37	1,21	1,27
SLG	1,59	1,63	1,59	1,63
SPG	2,05	1,73	2,27	1,62
VNO	1,59	1,54	1,36	1,47

TABELA 2 – MAPE (Erro Percentual Médio Absoluto dos Preços Mínimos e Máximos).

Fonte: Elaborado pelos autores.

Já na métrica MAPE, usada para calcular erros, porém em medidas percentuais, indica um resultado mais positivo para o ativo EQC. Quanto menor o valor de MAPE, melhores são as previsões realizadas. Pode-se observar que cerca de metade do grupo de ativos tem o *benchmark* RW superado pelo modelo LSTM, para valores de mínimos e máximos, com alguns casos de ativos com um maior valor se comparado a média total do grupo. Resultados acima do valor de RW significa um resultado pior em relação aqueles que tiveram o resultado inferior, se tratando do LSTM como referência.

O resultado com o maior valor obtido para mínimos e máximas foi novamente o SPG,

com um valor para preços mínimos de 2,05 e 1,73 respectivamente e para preços máximos de 2,27 e 1,62. Isso o torna dentre os 18 ativos estudados, o REIT com a menor exatidão de resultados. Com relação aos outros 3 subsequentes que se destacam negativamente, cita-se: HPP, SLG e AKR. Já para os que se destacam positivamente, o que possui o melhor desempenho é o EQC com valores mínimos e máximos de 0,82 e 0,72 para mínimos e 1,08 e 0,66 para máximos, respectivamente. Outros 3 que possuem o desempenho superior aos demais são: FR, PLD e DLR.

A métrica MAPE foi utilizada no estudo de Li *et al.* (2016) para avaliar o quanto os modelos *Group Method of Data Handling* (GMDH) eram precisos em suas previsões se comparado com outros tipos de modelos clássicos. Como resultado, o estudo não apresenta os valores exatos de MAPE, porém afirma que a rede neural utilizada GMDH possui o menor valor para tal métrica de erro. O artigo cita também que a métrica MAPE, é procedente para se estimar e estudar a previsão do algoritmo de previsão no formato de porcentagem. Assim como os autores citados, a presente pesquisa utilizou e destacou os menores valores da métrica para o modelo LSTM.

RMSE	Preço mínimo (LOW)		Preço máximo (HIGH)	
	Modelo LSTM	<i>Random Walk</i>	Modelo LSTM	<i>Random Walk</i>
Ativo				
AKR	0,38	0,42	0,36	0,39
BDN	1,31	1,42	0,20	0,23
BXP	2,07	1,95	1,87	1,96
CUZ	0,67	0,59	0,58	0,59
DLR	2,24	2,21	1,95	2,16
EQC	0,33	0,34	0,40	0,32
FR	0,61	0,64	0,65	0,63
FRT	1,91	1,97	1,92	1,90
HIW	0,70	0,72	0,67	0,68
HPP	0,66	0,53	0,69	0,54
KRC	1,31	1,11	2,06	1,09
OFC	0,42	0,46	0,39	0,46
PDM	0,76	0,34	0,38	0,32
PLD	1,64	1,76	1,51	1,68
REG	0,96	1,08	0,98	1,07
SLG	1,45	1,49	1,54	1,57
SPG	3,12	2,58	3,27	2,52
VNO	0,94	0,94	0,86	0,92

TABELA 3 – RMSE (Raiz do Erro Quadrático Médio dos Mínimos e Máximos).

Fonte: Elaborado pelos autores.

Por fim, na métrica RMSE, que indica o quanto os valores se distanciaram do

objetivo a ser atingido, a tabela acima mostra que o ativo que mais se destacou, ficando mais próximo do alvo foi o EQC para preços mínimos, com um valor de 0,33 e 0,34 e o BDN para valores de máxima, com valores de 0,20 e 0,23. Mais 3 ativos que obtiveram um menor valor que seus concorrentes, foram: PDM para mínimas e novamente o EQC, porém, agora para máximas; AKR para preços mínimos e PDM novamente, só que para valores máximos, por fim, OFC para mínimos e AKR, agora para preços máximos. Para os piores valores encontrados, o que mais se destacou dos demais foi o SPG, com mínimos de 3,12 e 2,58 e máximos de 3,27 e 2,52. Ademais, outros 3 que não obtiveram um bom desempenho, foram: DLR, BXP e FRT.

O estudo realizado por Freire e Vaz (2021) utilizou a RMSE como um tipo de métrica de erro no mercado de REITs. Os autores calcularam a RMSE para cada tipo do modelo e fizeram uma comparação entre os modelos tradicionais e as redes neurais artificiais, além de verificarem qual das métricas obteve um melhor desempenho. Como resultado, foi observado que esses modelos artificiais tiveram para RMSE um menor resultado em suas previsões contra os modelos tradicionais. Portanto, quanto menor for o resultado de RMSE, melhor é a previsão dos dados, por se trabalhar com um menor erro. Os resultados obtidos variam de modelo para modelo. Por exemplo, o modelo ANN usado para o índice *Real Estate* 50, mostra um RMSE de 29,19; já com relação ao mesmo modelo, porém agora para o índice *Equity* REITs, é mostrado um resultado para a métrica de erro de 5,49; por fim o modelo SARIMAX usado para o índice *All U.S* REITs, possui um resultado de RMSE de 24,94. Confirmando que os modelos neurais artificiais podem apresentar um resultado melhor para a métrica e compactuando com a ideia do presente estudo de usar o modelo LSTM para realizar as previsões dos ativos. Os resultados da RMSE encontrados pelos autores possuem um desempenho melhor em relação aos encontrados pelo presente artigo e uma possível explicação para isso pode ser o fato de que a amostra de dados coletada se refere a um período de 20 anos.

4.2 Análise dos modelos

Com base na Tabela 4, que faz a comparação dos modelos LSTM e RW com os valores reais obtidos, através da soma geral dos preços de mínimos e máximas de cada um dos ativos, de 2018 até 2022 e verifica qual dos dois modelos alcançou o valor mais próximo da realidade, destacando-se em verde o ganhador, em vermelho o modelo menos eficiente e em negrito os valores reais, pode-se chegar ao resultado que o desempenho do modelo LSTM foi inferior ao do modelo *Random Walk*, com exceção dos ativos AKR e BDN na previsão de máximos. Essa constatação indica que os ativos analisados nessas circunstâncias, demonstraram-se ser mais aderente à hipótese de mercado eficiente.

Ativos	Preço mínimo (LOW)			Preço máximo (HIGH)		
	Modelo LSTM	Random Walk	Valor Real LOW	Modelo LSTM	Random Walk	Valor Real HIGH
AKR	23387,68	23437,28	23424,50	24086,88	24088,61	24075,44
BDN	14343,59	14299,37	14288,91	14650,64	14659,39	14648,78
BXP	125296,63	124328,99	124272,31	127625,20	127255,48	127197,81
CUZ	38266,31	38738,34	38725,46	39354,50	39680,17	39666,97
DLR	148932,11	148176,64	148164,74	151231,81	151675,95	151664,32
EQC	32919,14	33088,82	33082,42	33290,42	33607,91	33601,61
FR	49388,92	49312,42	49327,36	50276,66	50338,62	50353,70
FRT	126679,48	126434,34	126410,65	129983,93	129367,66	129341,92
HIW	46288,49	46543,47	46521,24	47303,43	47635,53	47612,65
HPP	23992,05	23981,09	23956,67	24384,40	24637,45	24612,61
KRC	73272,94	74064,82	74028,65	73869,48	75790,90	75753,87
OFC	29965,78	30142,76	30140,13	30797,10	30867,21	30864,16
PDM	17223,03	16606,95	16595,43	17262,52	17035,30	17023,70
PLD	114854,89	114965,51	115013,09	117994,57	117604,21	117652,35
REG	67487,48	67480,80	67481,65	69375,68	69159,27	69159,28
SLG	82752,77	83012,20	82940,25	85559,52	85396,35	85322,80
SPG	144885,18	143847,29	143795,84	149348,14	147691,20	147638,34
VNO	54048,98	54490,72	54438,79	55704,70	55915,22	55862,09

TABELA 4 – Comparação dos Resultados dos Modelos Somados de 2018 a 2022.

Fonte: Elaborado pelos autores.

Segundo Fama (1970) uma possível explicação para o ocorrido, é que o mercado financeiro em questão e os ativos analisados nessas condições, são altamente eficientes em termos de informações. Em outras palavras, os preços dos ativos refletem rápida e precisamente todas as informações disponíveis. Isso sugere que a previsão dos preços máximos e mínimos não foi facilitada pelos padrões históricos e relações de longo prazo capturados pelo modelo LSTM. Além disso, o desempenho inferior do modelo pode ter sido causado por ruídos aleatórios, falta de consistência nas tendências dos preços e imprevisibilidade do comportamento dos investidores. Para prever com precisão os preços dos ativos, pode ser difícil identificar todas as variáveis do mercado financeiro, pois é algo muito complexo e interdependente.

Ao aprofundar a análise nos resultados alcançados e restringir o período de avaliação para um ano, em vez de considerar o período como um todo, é possível observar aspectos interessantes relacionados aos preços máximos e mínimos de certos ativos. Os REITs AKR, BDN, BXP, CUZ, FRT, HIW, KRC, OFC, PDM, SLG, SPG e VNO exibem características semelhantes ao longo dos anos.

Inicialmente, em 2018, esses ativos apresentam um preço total relativamente baixo,

o que pode ser atribuído ao início do período de coleta de dados em julho do mesmo ano. Em seguida, ocorre um aumento significativo nos preços totais em 2019, já que o ano inteiro é considerado na análise, o que pode explicar esse comportamento. Posteriormente, em 2020, observa-se uma queda nos preços, possivelmente decorrente do impacto da pandemia global de COVID-19, que afetou negativamente empresas de diversos setores. Entretanto, em 2021, os preços desses ativos voltam a subir, embora não tenham se recuperado totalmente para atingir os patamares de 2019.

Esse cenário pode ser atribuído aos estímulos econômicos implementados pelo governo dos EUA para impulsionar o setor imobiliário, como a manutenção das taxas de juros próximas a zero. No entanto, tais medidas não foram suficientes para restaurar completamente os preços aos níveis anteriores. Por fim, em 2022, os preços máximos e mínimos dos REITs sofrem outra queda em relação ao ano anterior, em meio ao aumento das taxas de juros nos EUA. Esse aumento pode ter impactado negativamente o mercado imobiliário e, conseqüentemente, os REITs.

Durante a análise dos REITs DLR, FR, PLD e REG, foi observado um comportamento distinto em relação aos ativos mencionados anteriormente. Esses ativos demonstraram uma notável resiliência diante dos eventos citados, não sendo significativamente afetados. Seus preços mantiveram uma trajetória de crescimento constante desde 2018 até 2022. Por fim, os REITs EQC e HPP apresentaram padrões atípicos em relação aos demais. O EQC registrou um aumento anual de preço em 2019, enfrentou dificuldades durante a pandemia em 2020, mas não conseguiu obter um retorno considerável em 2021, apresentando uma leve queda de preço em 2022. No que diz respeito ao HPP, foi possível observar um crescimento constante em seu preço ao longo dos anos, até 2021. No entanto, em 2022, ocorreu uma diminuição em relação aos valores apresentados em 2019.

Para melhorar as previsões de máximas e mínimas dos ativos analisados, pode valer a pena explorar outras abordagens e técnicas de modelagem. É válido ressaltar que os resultados obtidos podem ser específicos para o conjunto de dados e período analisados.

5 | CONCLUSÕES

O objetivo desse estudo foi realizar a previsão dos preços de máximos e mínimos de ativos REITs considerados *green*, ou seja, ativos com certificações de sustentabilidade, como o Energy Star e o *Leadership in Energy and Environmental Design* (LEED). Para isso, foi utilizado o modelo de inteligência artificial LSTM e o modelo teórico *Random Walk*. Os resultados de ambos foram comparados com os valores reais dos preços, tanto para *High* (preço máximo) quanto para *Low* (preço mínimo), para medir qual modelo se aproximou mais dos dados verdadeiros, a fim de estimar em qual hipótese de mercado, eficiente ou adaptativa, os ativos escolhidos se encaixam melhor.

Como resultado da análise dos *green* REITs por meio dos modelos de redes neurais,

observou-se que as previsões realizadas com o modelo *Random Walk* forneceram uma estimativa mais precisa dos preços. Essa descoberta sugere que a Hipótese de Mercado Eficiente, proposta por Fama (1970), poderia ser a teoria mais adequada para explicar o comportamento dos mercados financeiros em relação à carteira de ativos sustentáveis utilizada neste estudo. Os resultados indicam ainda, que as informações disponíveis publicamente podem estar já integralmente refletidas nos preços dos ativos estudados. Isso significa que os investidores que buscam retornos acima da média com base em algoritmos de previsão podem encontrar dificuldades nesse mercado específico de *green REITs* sustentáveis.

No entanto, é importante destacar que cada mercado e contexto podem apresentar peculiaridades que influenciam o comportamento dos *green REITs*. Embora os resultados indiquem suporte à Hipótese de Mercado Eficiente, é fundamental considerar as limitações deste estudo. Por exemplo, a falta de acesso aos dividendos dos ativos utilizados pode afetar a análise completa do desempenho financeiro dos REITs. Além disso, a falta de maiores comparações com variáveis macroeconômicas relevantes pode limitar a compreensão abrangente dos fatores que influenciam os preços dos ativos sustentáveis. O período de coleta de dados também pode ser considerado relativamente curto, o que pode limitar a capacidade de identificar tendências e padrões de prazos muito longos.

Para estudos futuros sugere-se, realizar novas pesquisas e análises em diferentes contextos, levando em consideração essas fragilidades, a fim de obter uma compreensão mais completa do comportamento dos *green REITs* e sua relação com a previsão de máximos e mínimos e as teorias de mercado. Isso permitirá uma avaliação mais robusta sobre a eficiência do mercado financeiro e o potencial de investimento em ativos sustentáveis. Além de poder se considerar uma simulação de investimento, para confirmar a eficiência das previsões obtidas com os ativos.

REFERÊNCIAS

AROUL, R. R.; SABHERWAL, S.; VILLUPURAM, S. V. ESG, operational efficiency and operational performance: evidence from Real Estate Investment Trusts. **Managerial finance**, v. 48, n. 8, p. 1206–1220, 2022.

COSTA, E.; FERREZIN, N. B. ESG (Environmental, Social and Corporate Governance) e a comunicação: o tripé da sustentabilidade aplicado às organizações globalizadas. **Revista Alterjor**, v. 24, n. 2, p. 79–95, 2021.

DIAS, Reinaldo. Gestão ambiental: responsabilidade social e sustentabilidade. In: **Gestão ambiental: responsabilidade social e sustentabilidade**. 2011. p. 220-220.

EICHHOLTZ, P.; KOK, N.; YONDER, E. Portfolio greenness and the financial performance of REITs. **Journal of international money and finance**, v. 31, n. 7, p. 1911–1929, 2012.

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

FENG, Z.; PRICE, S. M.; SIRMANS, C. An overview of equity real estate investment trusts (reits). **Journal of real estate literature**, v. 19, n. 2, p. 307–343, 2011.

FENG, Z.; WU, Z. ESG disclosure, REIT debt financing and firm value. **Journal of real estate finance and economics**, 2021.

FISCHER, T.; KRAUSS, C. Deep learning with long short-term memory networks for financial market predictions. **European journal of operational research**, v. 270, n. 2, p. 654–669, 2018.

FREIRE; VAZ, D. **Forecasting U.S. REIT index prices with artificial neural networks**. Instituto Superior de Economia e Gestão: Universidade de Lisboa, set. 2021.

HALBRITTER, G.; DORFLEITNER, G. The wages of social responsibility — where are they? A critical review of ESG investing. **Review of financial economics**, v. 26, n. 1, p. 25–35, 2015.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, v. 9, n. 8, p. 1735–1780, 1997.

JIRASAKULDECH, B.; KNIGHT, J. Efficiency in the market for REITs: Further evidence. **The journal of real estate portfolio management**, v. 11, n. 2, p. 123–132, 2005.

KRAEMER, M. E. P. Responsabilidade social corporativa: uma contribuição das empresas para o desenvolvimento sustentável. **Revista Eletrônica de Ciência Administrativa**, v. 4, n. 1, p. 1–50, 2005.

LABOISSIERE, L. A.; FERNANDES, R. A. S.; LAGE, G. G. Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks. **Applied soft computing**, v. 35, p. 66–74, 2015.

LI, R. Y. M.; FONG, S.; CHONG, K. W. S. Forecasting the REITs and stock indices: Group Method of Data Handling Neural Network approach. **Pacific rim property research journal**, v. 23, n. 2, p. 123–160, 2017.

LI, J.; LEI, L. Determinants and information of REIT pricing. **Applied economics letters**, v. 18, n. 15, p. 1501–1505, 2011.

LI, J. et al. Machine learning prediction for Chinese REITs market. **SSRN Electronic Journal**, 2022.

LO, Andrew W. The adaptive markets hypothesis: Market efficiency from an evolutionary perspective. **Journal of Portfolio Management, Forthcoming**, 2004.

Malkiel, B. G., & Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work*. *The Journal of Finance*, 25(2), 383-417. doi: <https://doi.org/10.1111/j.1540.6261.1970.tb00518.x>

MOGHAR, A.; HAMICHE, M. Stock market prediction using LSTM recurrent neural network. **Procedia computer science**, v. 170, p. 1168–1173, 2020b.

ODUSAMI, B. O. Volatility jumps and their determinants in REIT returns. **Journal of Economics and Business**, v. 113, n. 105943, p. 105943, 2021.

OLANRELE, Olusegun Olaopin. REIT performance analysis: are other factor determinants constant?. **Asian Economic and Financial Review**, v. 4, n. 4, p. 492-502, 2014.

SAH, V.; MILLER, N.; GHOSH, B. Are green REITs valued more? **The journal of real estate portfolio management**, v. 19, n. 2, p. 169–177, 2013.

SANTOS, Gustavo Carvalho et al. Forecasting brazilian ethanol spot prices using lstm. **Energies**, v. 14, n. 23, p. 7987, 2021.

Sec.gov. Disponível em: <<https://www.sec.gov/>>. Acesso em: 13 jun. 2023.