

INSTITUTO FEDERAL DE MINAS GERAIS - *CAMPUS* OURO BRANCO
SISTEMA DE INFORMAÇÃO

Wilson Batista Da Silva

**DESENVOLVIMENTO DE UM SISTEMA PREDITIVO PARA
ANÁLISE DE ATIVOS ACIONÁRIOS E GESTÃO DE RISCO**

Ouro Branco - MG
2026

WILSON BATISTA DA SILVA

**DESENVOLVIMENTO DE UM SISTEMA PREDITIVO PARA
ANÁLISE DE ATIVOS ACIONÁRIOS E GESTÃO DE RISCO**

Trabalho de conclusão de curso apresentado ao Curso de Sistema De Informação do Instituto Federal de Minas Gerais - *Campus* Ouro Branco para a obtenção do título de Bacharel em Sistemas de Informação.

Orientador: Ângelo Magno de Jesus

Ouro Branco - MG
2026

S586d Silva, Wilson Batista da.

Desenvolvimento de um sistema preditivo para análise de ativos acionários e gestão de risco. / Wilson Batista da Silva. – 2026.

9f.il.col.

Orientador: Ângelo Magno de Jesus.

Trabalho de Conclusão de Curso (Sistemas de Informação) – Instituto Federal de Minas Gerais. Campus Ouro Branco, 2026.

1. RNR. 2. Mercado de ações. 3. Sistema preditivo. 4. Gestão de risco. 5. LSTM.
I. Jesus, Ângelo Magno de. II. Instituto Federal de Minas Gerais. Campus Ouro Branco.
III. Título.

CDU: 004.8



**MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS
CAMPUS OURO BRANCO**

Av. Afonso Sardinha, nº 90, Bairro Pioneiros, CEP: 36.420-000, Ouro Branco - Minas Gerais
(31) 3742-2149 – gabinete.ourobranco@ifmg.edu.br

ANEXO II – ATA DE CONCLUSÃO DE TCC

Aos 19 dias do mês de Janeiro de 2026, às 21:50 horas,
Wilson Batista Da Silva, aluno(a) regularmente matriculado no Curso de Sistemas de Informação do Instituto Federal de Minas Gerais, campus Ouro Branco, matrícula 0058413, concluiu o seu Trabalho de Conclusão de Curso por meio de:

() Publicação do artigo intitulado _____
na revista/conferência _____,
cujo comprovante de aceitação será anexado a esta ata, recebendo a nota _____
pelo trabalho. Eu, na qualidade de orientador do aluno, lavrei a presente ata atestando a
conclusão do trabalho, a qual será assinada por mim e pelo aluno.

Professor Orientador

Aluno

(X) Defesa em sessão pública realizada às 21:50 horas, na sala Salão de Convenções,
3º andar do Instituto Federal de Minas Gerais, campus Ouro Branco, na presença da
banca examinadora composta pelos docentes:

- 1 - Daniela Costa Terra
- 2 - Ederson Naves Fernandes Gonçalves Júnior
- 3 - Lucas Portela Costa da Silva
- 4 - Marcio Assis Miranda

do artigo intitulado Desenvolvimento de um Sistema Preditivo para Análise de Ativos
Acionários e Gestão de Risco



**MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS
CAMPUS OURO BRANCO**

Av. Afonso Sardinha, nº 90, Bairro Pioneiros, CEP: 36.420-000, Ouro Branco - Minas Gerais
(31) 3742-2149 – gabinete.ourobranco@ifmg.edu.br

A banca examinadora, após reunião em sessão reservada, deliberou pela Aprovação do referido trabalho, atribuindo a nota 79,8. Eu, na qualidade de presidente da banca examinadora, lavrei a presente ata que será assinada por mim, pelos demais examinadores e pelo aluno.

Observações pertinentes à defesa:

NOME E ASSINATURA DOS COMPONENTES DA BANCA E DO



Documento assinado digitalmente

ANGELO MAGNO DE JESUS

Data: 29/01/2026 15:41:24-0300

Verifique em <https://validar.iti.gov.br>

RIENTADO



Documento assinado digitalmente

DANIELA COSTA TERRA

Data: 30/01/2026 12:49:21-0300

Verifique em <https://validar.iti.gov.br>

Professor Orientador



Documento assinado digitalmente

EDERSON NAVES FERNANDES GONCALVES JUN

Data: 29/01/2026 19:49:40-0300

Verifique em <https://validar.iti.gov.br>

Examinador 1



Documento assinado digitalmente

WILSON BATISTA DA SILVA

Data: 23/01/2026 20:47:36-0300

Verifique em <https://validar.iti.gov.br>

Examinador 2

Aluno

DECLARAÇÃO ANTI-PLÁGIO

Eu, Wilson Batista Da Silva, estudante do curso Bacharelado em Sistemas de Informação do IFMG – Campus Ouro Branco, declaro, para os devidos fins e efeitos, e para fazer prova junto ao IFMG – Campus Ouro Branco, que, **sob as penalidades previstas no art. 299 do Código Penal Brasileiro**, que é de minha criação



**MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS
CAMPUS OURO BRANCO**

Av. Afonso Sardinha, nº 90, Bairro Pioneiros, CEP: 36.420-000, Ouro Branco - Minas Gerais
(31) 3742-2149 – gabinete.ourobranco@ifmg.edu.br

o Trabalho de Conclusão de Curso que ora apresento.

Art. 299 do Código Penal Brasileiro, que dispõe sobre o crime de *Falsidade Ideológica*:

“Omitir, em documento público ou particular, declaração que dele devia constar, ou nele inserir ou fazer inserir declaração falsa ou diversa da que devia estar escrita, com o fim de prejudicar direito, criar obrigação ou alterar verdade sobre fato juridicamente relevante:

Pena – reclusão, de 1 (um) a 5 (cinco) anos, e multa, se o documento é público, e reclusão de 1 (um) a 3 (três) anos, e multa, se o documento é particular.

Parágrafo único. Se o agente é funcionário público, e comete o crime prevalecendo-se do cargo, ou se a falsificação ou alteração é de assentamento de registro civil, aumenta-se a pena de sexta parte”.

Este crime engloba plágio e compra fraudulenta de documentos científicos. Por ser verdade, e por ter ciência do referido artigo, firmo a presente declaração.

Ouro Branco, 23 de Janeiro de 2025

Assinatura do aluno: _____



Documento assinado digitalmente
WILSON BATISTA DA SILVA
Data: 23/01/2026 20:41:53-0300
Verifique em <https://validar.iti.gov.br>

Desenvolvimento de um Sistema Preditivo para Análise de Ativos Acionários e Gestão de Risco

Wilson Batista da Silva¹, Ângelo Magno de Jesus (Orientador)¹

¹Sistemas de Informação – Instituto Federal de Minas Gerais campus Ouro Branco (IFMG)
Rua Afonso Sardinha, 90, Bairro Pioneiros, Ouro Branco - MG, CEP 36420-000 – Brasil

wilsonescorpiao7@gmail.com, angelo.jesus@ifmg.edu.br

Abstract. *The volatility of the financial market demands robust analytical methods for decision-making and risk management. This work presents and validates a model for forecasting and analyzing financial data, combining time series analysis with advanced Machine Learning algorithms. The main advantage of this predictive model is the elimination of human emotional and cognitive bias. In this sense, the software analyzes a large amount of historical data via CSV files. This capability allows for the identification of complex patterns through statistical analysis. Furthermore, based on the collected data, the applied approach provides a data forecasting model for the following days. The LSTM (Long Short-Term Memory) model was built using the Python language, with HTML, CSS, and Javascript for the user interface. This tool allows the user to simulate capital investments, analyze the historical performance of Artificial Intelligence (AI), and predict the future volatility of the asset. It also allows the user to check the AI's performance metrics against the data, in addition to a graph for better data visualization. The results were promising, as the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) for Petrobras shares demonstrated high consistency in price forecasting.*

Resumo. *A volatilidade do mercado financeiro exige métodos de análises robustos para a tomada de decisão e gestão de riscos. Este trabalho apresenta e valida um modelo de previsão e análise de dados financeiros, combinando a técnica de séries temporais com algoritmos avançados de Aprendizado de Máquina (Machine Learning). A principal vantagem desse modelo preditivo é a eliminação do viés emocional e cognitivo humano. Neste sentido, o software analisa uma grande quantidade de dados históricos via arquivo csv. Essa capacidade permite a identificação de padrões complexos por meio de análises estatísticas. Além disso, com base nos dados coletados, a abordagem aplicada possui um modelo de previsão de dados para os dias seguintes. O modelo LSTM "Long Short-Term Memory" foi montado através da linguagem Python, utilizando HTML, CSS, e Javascript para a interface com o usuário. Essa ferramenta, possibilita que o usuário simule investimentos de capital, analise o desempenho histórico da Inteligência Artificial (IA) e preveja a volatilidade do ativo futuro. Ela também possibilita ao usuário checar as métricas de desempenho da IA com relação aos dados, além do gráfico para o melhor visualização dos dados. Os resultados foram promissores, uma vez que a Média de Erro Absoluto (MAE) e o Erro Quadrático Médio da Raiz (RMSE) para ações da Petrobras demonstraram alta consistência na previsão de preços.*

1. Introdução

O mercado financeiro brasileiro tem atraído cada vez mais investidores que buscam rentabilidades maiores que a da renda fixa. Nesse universo, o mercado de ações se destaca por seu potencial de retorno elevado mas que também trás diversos fatores de risco como: a volatilidade do mercado que pode surpreender até mesmo investidores veteranos; a falta de planejamento que pode fazer o investidor perder dinheiro devido a falta de conhecimento o que leva a fazer operações com prejuízo devido ao medo; e a saúde emocional que é afetada devido às operações de especulações sobre o preço. Neste sentido, podem haver ganhos mas também perdas o que pode fazer com que investidores que não conseguem ver seu patrimônio investido reduzir com a queda da ação [Reis 2025].

Para resolver esses problemas, este estudo propõe o desenvolvimento de um sistema de Inteligência Artificial que possa absorver tendências e volatilidade de ações ao longo dos anos e, com base nos históricos, prever como será o comportamento e o preço médio da ação possibilitando, desta forma, até mesmo fazer operações autônomas sem o viés emocional focando apenas na tendência. Como mostra a imagem O treinamento feito pela ia obteve como MAE (Mean Absolute Error) de 0,94 da ação da Petrobras (PETR4) o que significa, que durante a previsão, ela erraria o valor da cotação em média de R\$ 0,94 para cima ou para baixo.

2. Fundamentação Teórica

Conforme [Santos 2014], técnicas de Aprendizado de Máquina que visam realizar previsões de ações do mercado utilizam representações de dados montadas a partir de informações quantitativas históricas das ações.

Este estudo também utiliza o conceito de cotações. Neste sentido, uma cotação pode ser definida como preços de mercado relacionados a uma ação. Desta forma, o histórico de cotações permite que sejam derivadas diversas outras métricas, informações e medidas para representar o comportamento do ativo no mercado financeiro [Santos 2014].

Neste estudo, o histórico de ações é processado pela técnica de Aprendizado de Máquina denominada uma Rede Neural Artificial (RNA), mais especificamente do tipo Rede Neural Recorrente (RNR ou RNN na língua inglesa).

Desta forma, segundo [Mienye et al. 2024], as RNRs são uma classe de modelos de aprendizado profundo fundamentalmente arquitetadas para trabalhar com dados sequenciais [Alhajeri et al. 2024] [Shahinzadeh et al. 2024]. Ao contrário de outras técnicas de redes neurais, estes modelos processam sequências de informações por meio de uma memória de entradas anteriores usando seu estado interno. Isso as torna ideais para aplicações como processamento de linguagem natural, reconhecimento de fala e previsão de séries temporais, onde o contexto e a ordem dos pontos de dados são cruciais [Mienye et al. 2024].

3. Trabalhos Relacionados

O trabalho de [Agarwal et al. 2026] descreve um estudo que combina o modelo LSTM com o algoritmo Successive Mode Variational Decomposition (SVMD) para melhorar o desempenho da análise de preços do mercado de ações. Segundo os autores, “o SVMD é usado como uma técnica de decomposição de dados para facilitar a divisão de séries

originais complexas em suas funções de modo intrínseco decompostas, a fim de reduzir a não estacionariedade. Esta abordagem foi analisada tanto para sinais sintéticos quanto para dados de séries temporais financeiras. O LSTM é utilizado para analisar cada sinal e levar em consideração a influência dos dados históricos, a fim de aumentar a precisão da previsão”.

Além do trabalho citado anteriormente, o estudo de [Zhang et al. 2025] utilizou a junção de Decomposição de Modo Variacional (VMD) com Gráfico Triangulado Maximamente Filtrado (FMTG) e LSTM que tem como finalidade melhorar a eficiência e estabilidade computacional na previsão de preços. De acordo com os pesquisadores, *“o objetivo de melhorar a precisão da previsão, estabilidade e eficiência computacional. O modelo proposto emprega primeiro a Decomposição de Modo Variacional (VMD) para decompor as séries temporais de preços de ações em múltiplas funções de modo intrínseco suave (IMFs), reduzindo a complexidade dos dados e mitigando a interferência de ruído. Posteriormente, o algoritmo TMFG é utilizado para seleção de recursos, simplificando os dados de entrada e acelerando o processo de convergência iterativa. Finalmente, os recursos filtrados são modelados e previstos usando uma rede Long Short-Term Memory (LSTM)”.*

4. Metodologia

O desenvolvimento do trabalho seguiu as seguintes etapas:

1. Levantamento e estudo do problema a ser abordado;
2. Estudo bibliográfico;
3. Desenvolvimento dos módulos de coleta de dados das ações de empresas do sistema;
4. Identificação e desenvolvimento das técnicas de Aprendizagem de Máquina;
5. Desenvolvimento da interface gráfica com o usuário;
6. Realização dos testes e experimentos; e
7. Desenvolvimento de relatório técnico/artigo sobre o projeto.

O sistema de previsão utiliza a Rede Neural Recorrente do tipo Memória de Curto e Longo Prazo ou LSTM (*Long Short-Term Memory* em inglês) - esta técnica foi implementada no software por meio da utilização da biblioteca *tensorflow.keras*. Portanto, a técnica de Inteligência Artificial utilizada no trabalho deriva de abordagens de *Deep Learning* (Aprendizado Profundo), especificamente uma arquitetura de Rede Neural projetada para lidar com series temporais.

4.1. Linguagem de programação, folha de estilo e linguagem de marcação

Foi utilizado no back-end, a linguagem de programação Python junta para o desenvolvimento lógico da Inteligência Artificial e a manipulação dos dados de treinamento. Já para o front-end, foi utilizado HTML (*HyperText Markup Language*) para criação da interface juntamente com o CSS (*Cascading Style Sheets*) e JavaScript para melhorar, organizar o layout e torna a aplicação interativa com o usuário.

4.2. Inteligencia Artificial e Manipulação de Dados

Para a construção e treinamento da inteligência artificial, foi utilizado as bibliotecas e frameworks de Deep Learning Scikit-Learn, Pandas e NumPy para o processamento

primário dos dados e normalização com o MinMaxScaler. A análise e manipulação das tabelas e séries temporais foi realizada com o Pandas e Numpy para manipulação do array que irá alimentar a rede neural.

4.3. Integração IA com Usuário

A integração da ferramenta IA com o usuário, foi feita através das bibliotecas Flask, Flask-CORS e FetchAPI. O Flask foi utilizado para a criação do servidor web que faz a conexão entre o sistema preditivo e a interface gráfica do usuário. Além disso, o Flask-CORS foi utilizado para permitir a conexão do JavaScript com os dados da API sem que haja bloqueios.

A Fetch API foi utilizada para enviar e receber dados da interface do usuário.

4.4. Consultas e Armazenamento do Modelo Treinado

Para a consulta, foi utilizada a API da Alpha Vantage com o objetivo de captar os dados históricos da ação. Isso foi realizado utilizando também as bibliotecas Requests e Joblib para salvar e carregar o modelo treinado juntamente com o escalonador salvo no diretório de modelos.

5. Resultados

O Sistema possui três áreas digitáveis na tela principal, sendo elas

1. Ação (Ticker): Nome do ticker da ação negociada;
2. Capital Inicial (R\$): sendo valor onde o usuário pode simular um valor a ser investido;
3. Dias de Simulação/Análise: na qual pode-se simular os últimos dias em que o dinheiro ficaria investido de acordo com dados teste ou quantos dias para frente a ferramenta irá prever a partir do último treino efetuado.

Esta interface gráfica também apresenta os respectivos botões: (1) “Simular Investimento” que irá fazer uma simulação de acordo com a informação digitada no campo superior; (2) “Analisar Histórico” que mostra em um gráfico a performance da IA em comparação com o ativo alvo, utilizando informação da área “Dias de Simulação/Análise” para pegar os últimos dias separados no teste de comparação; e (3) o botão “Previsão Futura” que irá fazer a previsão futura a partir do último dia de análise e realizar o treino da IA como mostra Figura 1.

Figura 1. Tela de preenchimento

Análise Preditiva de Ações B3

Ação (Ticker):	cp1e6
Capital Inicial (R\$):	50
Dias de Simulação/Análise:	30
Simular Investimento Analisar Histórico Previsão Futura Treinar IA	

Fonte: Elaborado pelo autor (2025).

Nessa mesma tela, temos também a tabela Métricas de Desempenho (Teste), e a tabela Simulação Swing Trade como mostra a Figura 2


Figura 2. Análise de desempenho



Fonte: Elaborado pelo autor (2025).


Para melhor visualização e compreensão das informações, os dados são sumarizados e exibidos em um gráfico dinâmico no qual é possível visualizar tanto o desempenho do modelo - como na Figura 3, quanto a previsibilidade futura do ativo - como mostra a Figura 4.

Figura 3. Análise preditiva da Petrobrás (PETR4)



Fonte: Elaborado pelo autor (2025).

Figura 4. Previsão futura da Petrobrás (PETR4)



Fonte: Elaborado pelo autor (2025).

O botão “Treinar” irá levar o usuário para a tela de “Treinamento do Modelo LSTM”. Nesta tela, o investidor poderá escolher o Ticker da Ação para realizar o treino e o Percentual de Dados para Teste (%) - sendo este número um valor inteiro utilizado para a separação dos dados da API para testar a IA e fazer comparações. Além disso, nesta interface de Treinamento do Modelo LSTM o usuário também poderá escolher a Sequência de Dias de Entrada (Timesteps) - para escolher quantos dias para trás a IA irá considerar de análise para fazer a previsão do dia seguinte - e a Quantidade de Neurônios (LSTM Units) - na qual irá transmitir informações e ajudar a IA a aprender. Por fim, o usuário poderá configurar o Número de Épocas (que representa a quantidade máxima de vezes que a IA permanecerá nos treinos) e definir se irá utilizar a Early Stopping que monitora a cada 15 época se a IA aprendeu, caso sim ele interrompe o processamento para evitar overfitting (decoração). Esta interface é ilustrada na Figura 5.

Figura 5. Tela de treinamento

Treinamento do Modelo LSTM

Ticker da Ação para Treinar:

vale3

Percentual de Dados para Teste (%):

20

Sequência de Dias de Entrada (Timesteps):

60

Quantidade de Neurônios (LSTM Units):

35

Número de Épocas:

300

Usar Early Stopping:

Sim (Recomendado)

🔥 Requisitar Dados API

🚀 Iniciar Treinamento

⬅ Voltar

✅ SUCESSO: Modelo para cmig4 treinado com sucesso.. Retorne à página principal para analisar.

Fonte: Elaborado pelo autor (2025).

Após o treinamento da IA com a ação da empresa Petrobrás (PETR4), foi obtido o resultado de acurácia de valor de 97,04% e acurácia de direção de 50,41% como mostra a Figura 6.

Figura 6. Métricas de desempenho referente à ação Petrobrás (PETR4)

Desempenho da PETR4
MÉTRICAS DE DESEMPENHO (TESTE) MAE (Erro Absoluto Médio): 0.94 MSE (Erro Quadrático Médio): 1.51 RMSE (Raiz do Erro Quadrático Médio): 1.23 Acurácia (Valor): 97.04% Acurácia (Direção): 50.41%

Fonte: Elaborado pelo autor (2025).

A Tabela 1 mostra um comparativo de performasse da IA com diferentes outros ativos utilizando 150 neurônios, para 150 dias de entrada utilizando Early Stopping (técnica que evita decoraç o de dados). Neste sentido, a Tabela inclui os seguintes campos: MAE (Erro Absoluto M dio) que ir  fazer uma m dia do erro, MSE (Erro Quadr tico M dio) que ir  penalizar os erros mais graves tornando-os mais evidentes, RMSE (Raiz

do Erro Quadrático Médio) que mostra a media dos erros mais próximo do MAE mas levado em conta os erros graves, Acurácia (Valor) que irá mostrar quanto próximo a previsão está do valor real e Acurácia (Direção) que irá mostrar quanto a direção da tendência está em relação a Petrobras (PETR4),

Tabela 1. Comparação de performance entre alguns ativos.

Ativo	MAE	MSE	RMSE	Acurácia de valor (%)	Acurácia de direção (%)
Petrobras (PETR4)	0,66	0,82	0,91	97,87	50,67
Vale (VALE3)	1,21	2,81	1,63	98,32	51,31
Copel (CPLE6)	0,19	0,06	0,24	97,75	48,88
Taesá (TAEE11)	0,37	0,28	0,53	98,99	49,11

6. Conclusão

A Inteligência Artificial trás como vantagens uma melhor gestão de tempo, possibilitado com que a tomada de decisão segue instantânea com relação a compra ou venda do ativo, e uma melhor gestão emocional, pois não se influencia por viés sentimental focando apenas em realizar análises estatísticas. Desta forma, conforme os testes realizadas, o sistema desenvolvido apontou ser promissor para ser utilizado como uma ferramenta para suporte na análise de ativos acionários.

No entanto, o sistema também tem seus pontos negativos como limitações nas análises econômicas e políticas, além do preconceito da não interpretação do contexto regulatórios, geopolítico e análise de sentimento do mercado que não estão nos dados históricos, mas que pode mudar repentinamente a direção do comportamento da ação.

Como trabalhos futuros, propõe-se a realização de uma mudança na API de coleta de dados, uma vez que está sendo utilizada uma API gratuita que se tornou paga. Além disso, sugere-se realizar modificações para aplicar análise de sentimento do mercado através de consulta em redes sociais - como o X (antigo Twitter), fóruns e comunidades relacionadas a investimentos ou até mesmo no site Google Trends. Outra proposta de trabalho futuro está relacionada em se acrescentar uma tela de login que deverá separar a tela de treinamento da tela de análise preditiva. Por fim, uma possível implementação futura poderia incluir fazer conexão entre o software e uma corretora para manipulação em tempo real da carteira.

Referências

- Agarwal, S., Sharma, S., Faisal, K. N., and Sharma, R. R. (2026). Título do trabalho. *Nome da Revista*.
- Alhajeri, M. S., Ren, Y. M., Ou, F., Abdullah, F., and Christofides, P. D. (2024). Model predictive control of nonlinear processes using transfer learning-based recurrent neural networks. *Chemical Engineering Research and Design*, 205:1–12.
- Mienye, I. D., Swart, T. G., and Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, 15(9):517.

- Reis, T. (2025). Swing trade: saiba o que é, como funciona e se realmente vale a pena. <https://www.suno.com.br/guias/swing-trade/>. Acessado em: 16 Dezembro 2025.
- Santos, D. S. (2014). Predição de mínimos e máximos locais para investimento em bolsa de valores utilizando aprendizado de máquina.
- Shahinzadeh, H., Mahmoudi, A., Asilian, A., Sadrarhami, H., Hemmati, M., and Saberi, Y. (2024). Deep learning: a overview of theory and architectures. In *2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP)*, pages 1–11. IEEE.
- Zhang, Z., Liu, Q., Hu, Y., and Liu, H. (2025). Previsão de preços de ações com vários recursos por redes LSTM baseadas em VMD e TMFG. *Journal of Big Data*, 12(1):74.