



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Marcos Antenor de Souza Morais

**Previsão de preços de ações no setor bancário brasileiro por
meio do uso de redes neurais recorrentes de tipo LSTM**

Uberlândia

2023

Marcos Antenor de Souza Moraes

**Previsão de preços de ações no setor bancário brasileiro por meio do uso de
redes neurais recorrentes de tipo LSTM**

Trabalho de Conclusão de Curso apresentado à Uni-
versidade Federal de Uberlândia como requisito à
Conclusão de curso em Gestão da Informação
Orientador Prof. Dr. Flavio Luiz de Moraes Barboza

Uberlândia
2023

AGRADECIMENTOS

Em primeiro lugar, quero agradecer a minha família, em especial minhas irmãs Larissa e Letícia Novais, por terem sempre sido, cada uma a seu modo, exemplos pessoais de determinação e caráter.

Aos incontáveis amigos, companheiros e camaradas que contribuíram de maneira direta ou indireta, respondendo dúvidas, indicando caminhos e soluções quando problemas pequenos pareciam grandes demais.

Ao professor Flávio Barboza, que me ensinou que a ciência se faz com muito trabalho, honestidade e atenção aos detalhes. Estendo meus agradecimentos a todos os valorosos professores da rede pública de ensino deste país, sem os quais eu jamais poderia ter chegado até aqui.

À minha melhor amiga, companheira de jornada e de vida Beatriz Ortiz, pelo apoio e inspiração, essenciais para que eu pudesse concluir essa etapa. E por ter me ajudado a colocar os pingos nos is, literalmente.

E à minha mãe, Alba Valéria, por tudo.

*Though our smoke may hide the Heavens from your eyes,
It will vanish and the stars will shine again,
Because, for all our power and weight and size,
We are nothing more than children of your brain!*

— Rudyard Kipling, “The Secret of the Machines”

RESUMO

A partir da concepção da Hipótese dos Mercados Adaptativos (HMA), estudos aplicando técnicas de aprendizado de máquina surgiram para identificar como é possível obter ganhos financeiros acima da média a partir de previsões. O objetivo deste estudo é realizar previsões com modelos baseados em redes neurais de tipo *Long Short-Term Memory (LSTM)* a respeito do preço de fechamento de 5 dos principais bancos em atividade no mercado brasileiro, utilizando variáveis macroeconômicas e indicadores do sistema *CAMELS*. Os resultados demonstraram que, de forma geral, os modelos propostos não foram capazes de generalizar novos dados e produzir previsões melhores do que o modelo teórico do *Random Walk (RW)*. Testes de Diebold-Mariano foram realizados comparando as métricas produzidas pelos modelos *LSTM* em relação às produzidas pelo modelo teórico. Devido a significância estatística verificada, há indícios de que os ativos analisados seguem a teoria da eficiência de mercado. No entanto, cenários específicos demonstraram que o modelo foi capaz de produzir previsões superiores às do modelo *Random Walk*, abrindo caminhos e oportunidades para que novos estudos possam ser desenvolvidos a fim de aprofundar as discussões.

Palavras-chave: Previsão de preços; *Machine Learning*; *LSTM*; setor bancário brasileiro;

LISTA DE FIGURAS

Figura 1 –	14
Figura 2 –	17
Figura 3 –	22
Figura 4 –	26
Figura 5 –	26
Figura 6 –	27
Figura 7 –	27
Figura A.1 –	40
Figura B.1 –	42
Figura C.1 –	44
Figura E.1 –	47

LISTA DE ABREVIATURAS E SIGLAS

ANN	Artificial Neural Networks
API	Application Programming Interface
AT	Algorithmic Trading
B3	Brasil, Bolsa, Balcão
BACEN	Banco Central do Brasil
CAMELS	Capital adequacy, Asset quality, Management efficiency, Earning quality, Liquidity, Sensitivity to Market Ratio
CAR	Capital Adequacy Ratio
DTW	Dynamic time warping
EPS	Earnings Per Share
HMA	Hipótese dos Mercados Adaptativos
HME	Hipótese dos Mercados Eficientes
IBOV	Índice Bovespa
IDX	Indonesia Stock Exchange
IFNC	Índice Financeiro
ISE	Índice de Sustentabilidade Empresarial
LDR	Loan to Deposit Ratio
LSTM	Long Short-Term Memory
MAE	Mean absolute error
MAPE	Mean absolute percentage error
MSE	Mean squared error
NPL	Non-Performing Loan
NPM	Net Profit Margin
NSE	National Stock Exchange of India
NYSE	New York Stock Exchange
OHLC	Open, High, Low e Close
PER	Prices Earning Ratio
ReLU	Rectified Linear Unit
RF	Random Forest
RMSE	Root mean square error
RNA	Redes Neurais Artificiais
RNR	Redes Neurais Recorrentes
ROA	Return On Assets
ROE	Return On Equity
RW	Random Walk
SELIC	Sistema Especial de Liquidação e de Custódia
SVM	Support Vector Machine

SUMÁRIO

1	INTRODUÇÃO	8
2	LITERATURA RELACIONADA	10
2.1	SETOR BANCÁRIO: CARACTERÍSTICAS E DETERMINANTES .	10
2.2	MERCADO EFICIENTE VERSUS MERCADO ADAPTATIVO . . .	11
2.3	REDES NEURAIS E SUAS APLICAÇÕES NO SETOR FINANCEIRO	12
3	METODOLOGIA	16
3.1	DESCRIÇÃO DOS DADOS	16
3.2	PRÉ-PROCESSAMENTO DOS DADOS	18
3.3	DEFINIÇÃO DA ARQUITETURA DA REDE <i>LSTM</i>	19
3.4	MÉTRICAS DE DESEMPENHO	20
4	RESULTADOS E DISCUSSÕES	22
5	CONSIDERAÇÕES FINAIS	28
	REFERÊNCIAS	30
	APÊNDICE A – Curvas de Loss	39
	APÊNDICE B – Previsões com dados de treinamento	41
	APÊNDICE C – Previsões com dados de teste	43
	APÊNDICE D – Testes Diebold-Mariano	45
	APÊNDICE E – Previsões realizadas no mês de Novembro .	46

1 INTRODUÇÃO

O mercado de ações desempenha um papel crucial no funcionamento das principais economias capitalistas do mundo (CAMPOS; HANOUSEK; FILER, 1999). A clássica teoria da eficiência dos mercados proposta por Fama (1970) afirma que em razão da racionalidade dos investidores, a variação no preço das ações é totalmente aleatória e imprevisível. No entanto, evidências sugerem que determinados vieses cognitivos dos indivíduos que operam na bolsa produzem padrões de comportamento incompatíveis com essa teoria (BRAV; HEATON, 2002), tornando possível identificar, por meio de previsões, comportamentos cíclicos do mercado para obter ganhos financeiros acima da média (LO, 2004).

O crescente desenvolvimento das tecnologias de informação, combinado a um regime global de acumulação baseado na valorização financeira, e o avanço de métodos e técnicas estatísticas para analisar grandes conjuntos de dados, viabilizaram a adoção de ferramentas capazes de amplificar o ganho dos investidores no mercado financeiro (PARANÁ, 2018). Diversos estudos demonstraram que estratégias de investimento baseadas no uso de técnicas de *Machine Learning* como *SVM (Support Vector Machine)*, *RF (Random Forest)* e *ANN (Artificial Neural Networks)* para previsão de preços de ativos listados em bolsa, tiveram desempenho satisfatório (GARRUTI *et al.*, 2022; GU; KELLY; XIU, 2018). Budiharto (2021) e Yufeng Chen, Jinwang Wu e Zhongrui Wu (2022) também demonstram a efetividade de modelos semelhantes, desta vez voltadas especificamente para o setor bancário e utilizando um tipo especial de rede neural, as redes de tipo *LSTM (Long Short-Term Memory)*.

O objetivo deste estudo, portanto, é realizar previsões a respeito do preço de fechamento (*Close*) das ações de cinco dos principais bancos que atuam no mercado brasileiro: Banco do Brasil, Bradesco, BTG Pactual, Itaú e Santander. Para isso, foram desenvolvidos dois modelos distintos utilizando redes neurais de *LSTM*, utilizando dados relativos ao histórico de negociação em bolsa dos ativos selecionados, e considerando a influência de fatores externos como dados macroeconômicos e índices característicos da bolsa brasileira, a B3, bem como alguns dos principais indicadores CAMELS, modelo utilizado para avaliar a performance de instituições financeiras.

Este trabalho se justifica na medida em que: se propõe a avaliar modelos de previsão utilizando redes neurais, buscando características e elementos que os tornem mais precisos e adequados aos interesses dos investidores; se situa em meio ao debate sobre a eficiência dos mercados, trazendo evidências que se somam a outros exemplos disponíveis da literatura; e está inserido no contexto da denominada Finança Digitalizada (PARANÁ, 2016), uma vez que demonstra como aplicações baseadas em redes neurais artificiais podem ser utilizadas para obter ganhos no mercado financeiro.

Os resultados demonstram que, em geral, previsões que utilizam os modelos LSTM

foram incapazes de superar o modelo teórico do *RW* (*Random Walk*), o que impede afirmações categóricas a respeito da ineficiência do mercado brasileiro, pelo menos em relação aos ativos analisados neste estudo. No entanto, nos primeiros dias de previsão, a rede apresentou métricas de erro menores, e pelo menos um dos ativos superou o *RW* nesse cenário. Por isso, sugere-se algumas melhorias para trabalhos futuros, como uso de análise de *clusters* (CHEN, Y.; WU, J.; WU, Z., 2022) otimização dos hiper-parâmetros da rede (LIU; SUZUKI; DU, 2023) e ampliação das janelas e intervalos de previsão, explorando o uso de técnicas como Janela Rolante (SANTOS, G. C. *et al.*, 2021).

Além da introdução, já apresentada, a organização deste trabalho segue com: Literatura Relacionada, em que são listados os principais conceitos e trabalhos que dão amparo teórico para realização dos experimentos realizados; Metodologia, seção na qual as ferramentas e técnicas utilizadas nos experimentos são detalhadas; na sequência os Resultados e Discussões relacionados a eles; e, por fim, as Considerações Finais.

2 LITERATURA RELACIONADA

2.1 SETOR BANCÁRIO: CARACTERÍSTICAS E DETERMINANTES

Os bancos são intermediários financeiros que tem como atividade fundamental oferecer um mecanismo para que a alocação de crédito seja direcionada para as oportunidades mais produtivas disponíveis no mercado, ocupando, por isso, um papel central no funcionamento da economia (STIGLITZ; WEISS, 1988), (FIELDS; FRASER; WILKINS, 2004), (CASU; GIRARDONE; MOLYNEUX, 2006). Esse comportamento pode ser observado a partir de dados disponibilizados pelo Banco Central do Brasil, por exemplo. De acordo com a instituição, o volume total de empréstimos no Sistema Financeiro Nacional alcançou, em 2021, a marca de R\$4,7 trilhões valor que, na ocasião, representava 53,9% do PIB brasileiro

Assim como em outros países do mundo, o setor bancário brasileiro é altamente concentrado. Em geral, os 5 maiores bancos de cada país controlam cerca de 78% do total dos ativos no mercado. No Brasil, esse índice alcança a marca de 85%, quase o dobro que o índice de concentração bancária nos Estados Unidos, que é de 45% (JOAQUIM; DOORNIK; ORNELAS, 2019). Esse fator tem implicações graves sobre o funcionamento da economia nacional, como aumento da taxa de juros (ZEIDAN, 2020), redução do volume de crédito e de empregos disponíveis e redução dos salários (JOAQUIM; DOORNIK; ORNELAS, 2019).

Os bancos possuem características contábeis e estruturais que os diferenciam de outras empresas, particularmente se comparadas àquelas que não fazem parte do setor financeiro (WERNER, 2014). Dentre algumas dessas particularidades, destacam-se: maior índice de alavancagem (DEANGELO; STULZ, 2015); presença de conselhos de administração maiores, com participação reduzida de *insiders* (KROSZNER; STRAHAN, 2001); maior grau de incerteza na operação, em razão do alto grau de complexidade na gestão de grandes portfólios de produtos financeiros (AUTORE; BILLINGSLEY; SCHNELLER, 2009); e forte submissão a agências governamentais que determinam normas acerca de suas atividades (LOBO, 2017). Além disso, existem técnicas e indicadores de desempenho financeiro que se aplicam exclusivamente aos bancos, como é o caso do sistema de classificação *CAMELS* (WIRNKAR; TANKO, 2008).

O modelo, usado pela alta administração dos bancos de vários países, incluindo o Brasil (DAL MAGRO; MICHELS; SILVA, 2017), é um acrônimo que faz referência a 6 dimensões distintas de análise de desempenho, sendo elas: *Capital adequacy* (C), que indica a capacidade do banco de absorver riscos à partir do capital disponível; *Asset quality* (A), que indica a produtividade dos empréstimos cedidos pelo banco; *Management efficiency* (M), fator que aponta a qualidade dos administradores para gerenciar os riscos da atividade da empresa; *Earning quality* (E), que indica o quão eficiente e eficaz é o uso do capital por parte do banco para gerar receita; *Liquidity* (L), que demonstra a

capacidade do banco de lidar com suas obrigações financeiras; e, por fim *Sensitivity to Market Ratio* (S), que indica o quão sensível o banco está ao comportamento do mercado e a variação no preço de outros ativos (QUOC TRUNG, 2021).

Consideradas as evidências de que fatores internos e externos possuem influência sobre o preço dos ativos listados em bolsa (HAMILTON; LIN, G., 1996), bem como as particularidades estruturais e contábeis dos bancos, faz-se mister destacar também os determinantes que incidem sobre o preço de suas ações.

O pioneiro estudo de Collins (1957) estabelece um método pelo qual é possível estimar o preço das ações bancárias por meio de quatro variáveis independentes: lucro operacional, lucro líquido, dividendos e valor patrimonial. Utilizando dados referentes a bancos da Índia e Paquistão, respectivamente, Paresh Narayan, Seema Narayan e Singh (2014) e Shahzad *et al.* (2017) identificaram que os indicadores de atividade econômica (índice de mercado e índice de produção industrial) possuem maior impacto sobre o preço das ações se comparados, por exemplo, a taxa de juros ou à taxa de câmbio, que também foram avaliadas nos estudos.

Outros trabalhos também avaliaram a influência de alguns dos indicadores do modelo CAMELS sobre o preço das ações das empresas. Medyawati e Yunanto (2023), avaliaram índices como *ROA* (*Return On Assets*), *ROE* (*Return On Equity*), *PER* (*Prices Earning Ratio*) e *EPS* (*Earnings Per Share*), e demonstram que ROA e EPS possuem impacto positivo e significativo sobre o preço das ações, enquanto o ROE possui efeito negativo. Nugroho, HALIK e Arif (2020) demonstraram que algumas das variáveis do modelo CAMELS (CAR, NPL, NPM, ROA, e LDR) avaliadas em conjunto possuem um impacto significativo e positivo sobre os preços das ações de bancos estatais da Indonésia.

Os resultados da pesquisa de Rjoub, Civcir e Resatoglu (2017), que levou em consideração a influência de variáveis micro e macroeconômicas sobre os preços das ações de bancos turcos, indicam que variáveis relativas ao tamanho do banco, sua capacidade de gerar receita e a oferta monetária influenciam positivamente a variação no preço das ações dos bancos. Por outro lado, as variáveis relativas à taxa de juros e momentos de crise econômica possuem influência negativa sobre o preço dos papéis dos bancos. Vale destacar também que, ao contrário de outros estudos, não foram encontradas correlações estatisticamente significativas entre os índices de produção industrial, taxa de câmbio e o preço das ações. O mesmo vale para a taxa de inflação.

2.2 MERCADO EFICIENTE VERSUS MERCADO ADAPTATIVO

Postulada originalmente por Fama (1970), a HME (Hipótese dos Mercados Eficientes) trata do preço dos ativos disponíveis no mercado e sua capacidade de refletir em si toda a informação disponível sobre ele. Ou seja, em um mercado eficiente, em que todos os investidores operam sobre a lógica da racionalidade ilimitada, toda a dinâmica de oferta e compra de ativos protagonizada por milhares de indivíduos se baseia na totalidade de

informações disponíveis sobre esses títulos e, determina, lenta ou rapidamente, a variação do preço das ações e bens negociados (MUSSA *et al.*, 2010). Sendo assim, nenhum investidor pode obter ganhos acima do nível normal do mercado, uma vez que a dinâmica de variação dos preços é completamente imprevisível e aleatória.

No entanto, a partir da observação de determinadas anomalias de mercado, e por meio da incorporação de conceitos da sociologia e psicologia, surge a HMA (Hipótese dos Mercados Adaptativos) (MILANEZ, 2003). Essa teoria propõe que os indivíduos nem sempre tomarão as decisões mais racionais, por limitações de ordem psicológica e/ou emocional, por exemplo, provocando perturbações no mercado, manifestadas como padrões sazonais, o que atesta contra a hipótese dos mercados eficientes (BLACK, 1986; BRAV; HEATON, 2002).

Seguindo os pressupostos desta nova teoria, seria possível estudar e analisar os comportamentos cíclicos do mercado financeiro, identificando determinados eventos de forma antecipada, que indicariam o caráter previsível do movimento dos mercados financeiros (LO, 2004). Algumas técnicas de *Machine Learning* foram empregadas para preencher essa lacuna. É o caso das redes neurais (PATEL; YALAMALLE, 2014; PAULI; KLEINA; BONAT, 2020).

2.3 REDES NEURAI E SUAS APLICAÇÕES NO SETOR FINANCEIRO

De acordo com Samuel (2000), o conceito de *Machine Learning* diz respeito à capacidade de um computador aprender e executar tarefas específicas, com pouca ou nenhuma intervenção humana - desde que devidamente programado e configurado com parâmetros e características sobre um determinado contexto. É atribuir a uma máquina, a capacidade de extrair padrões e tomar decisões a partir de uma coleção de dados brutos (GOODFELLOW; BENGIO; COURVILLE, 2016).

As técnicas de *Machine Learning* têm sido amplamente empregadas em diversos contextos como visão computacional, engenharia espacial, biologia computacional, medicina, e finanças, (EL NAQA; MURPHY, 2015). Nesse sentido, as aplicações que utilizam tais técnicas são bastante amplas e variadas, dentre elas: uso de algoritmos como *RF* (*Random Forest*) para previsão de falências (BARBOZA; KIMURA; ALTMAN, 2017); emprego de *RF* e *SVM* (*Support Vector Machine*) para elaboração de um sistema de alerta de previsão de crises e distúrbios bancários no Brasil (BARBOZA *et al.*, 2023); e, sistemas de previsão de preços e negociação automatizada (*AT* (*Algorithmic Trading*)) de ativos no mercado financeiro (HANSEN, 2020).

Atualmente, mais de 40% das operações de compra e venda na bolsa brasileira são processadas por robôs investidores, que utilizam alguma forma de negociação algorítmica (PARANÁ, 2018). O funcionamento de alguns desses sistemas se baseiam em variações das denominadas RNA (Redes Neurais Artificiais), ou *ANN* (*Artificial Neural Networks*) (ARÉVALO *et al.*, 2017). Os primeiros estudos explorando o uso dessas técnicas para

previsão de preços datam da década de 1990 (OH; KIM, J., 2002), e trabalhos recentes também demonstram a superioridade de estratégias de investimento baseadas em redes neurais se comparada a estratégias convencionais, como *buy-and-hold*, por exemplo (GU; KELLY; XIU, 2018).

As RNAs se constituem a partir de um arranjo combinatório massivo de unidades de processamento (perceptrons), que são organizadas por meio de arquiteturas que definem as características da rede e seu funcionamento (FIESLER, 1994). Cada um desses perceptrons funciona como unidades computacionais, que a partir de valores numéricos apresentados como sinais de entrada (*inputs*), calculam de forma dinâmica um valor numérico de saída, por meio de uma soma ponderada que leva em conta pesos (*weights*) e vieses (*bias*) que, de modo geral, indicam a influência de uma determinada variável sobre a saída desejada do modelo, conforme a especificação do problema matemático para o qual a rede se destina. Antes de ser apresentado à saída do perceptron, o valor calculado é submetido a uma função de ativação, que introduz o componente não-linear ao modelo (HAYKIN, 1998).

O arranjo massivo que caracteriza o modelo, também conhecido como *multilayer perceptron* (LABOISSIERE; FERNANDES; LAGE, 2015), pode ser expresso através de uma abstração na qual as unidades de processamento são organizadas em camadas interconectadas de entrada, intermediárias (ocultas) e de saída. Através destas camadas, valores numéricos são transmitidos por todos os *perceptrons* da rede (da entrada a saída), em um processo conhecido como *feedforward* (GOODFELLOW; BENGIO; COURVILLE, 2016). Todas essas propriedades permitem que as RNAs possam ser utilizadas para modelar sistemas dinâmicos, encontrando padrões, irregularidades, e conexões não-lineares entre os dados de um conjunto (DASE; PAWAR, 2010).

As limitações presentes nas RNAs motivaram o desenvolvimento de uma nova arquitetura, as Redes Neurais Recorrentes, ou RNRs. Diferentemente das redes neurais artificiais tradicionais, as RNR computam os dados por meio de um processo de *feedback*, em que a camada de entrada se comunica com a camada de saída da rede, funcionando como um tipo implícito de memória interna. Desse modo, a rede é capaz de encontrar correlações entre eventos separados por um determinado intervalo de tempo, sendo relativamente mais eficiente para lidar com dados de curto prazo (CARDOT, 2011).

Mesmo apresentando evoluções significativas em relação a modelos predecessores, as RNRs ainda apresentam problemas, especialmente ao lidar com dependências de longo prazo. O modelo apresenta deficiências significativas para encontrar correlações entre eventos que estejam muito afastados temporalmente um do outro. Essa dificuldade está relacionada a dois fenômenos, denominados *Vanishing Gradient* e *Exploding Gradient*, amplamente documentados e abordados pela literatura (PASCANU; MIKOLOV; BENGIO, 2013).

Com o objetivo de resolver algumas das limitações presentes nas RNRs, Hochreiter e Schmidhuber (1997) desenvolveram as chamadas redes de tipo *LSTM* (*Long Short-Term*

Memory) como uma extensão do modelo de redes neurais recorrentes.

A chave para o seu funcionamento são as células de memória (Figura 1). Elas possuem a capacidade de determinar quais informações influenciarão o estado da célula durante o tempo de processamento da rede, por meio de estruturas denominadas portões. Por meio deles a rede *LSTM* é capaz de regular os fluxos de erros durante o processo de treinamento, minimizando o impacto dos problemas dos gradientes, e as limitações em relação à manipulação de dados de longo prazo.

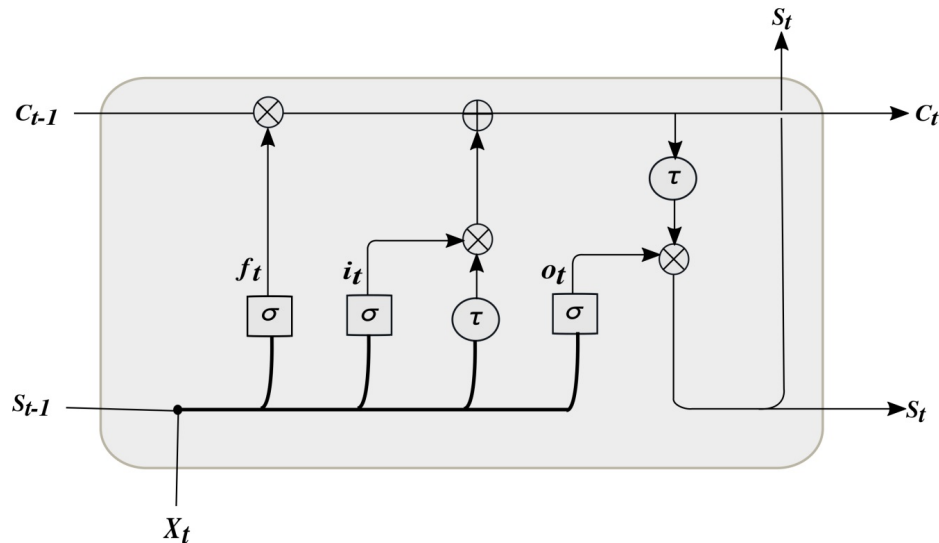


Figura 1 – Célula *LSTM*. Reproduzido de (SAGHEER; KOTB, 2018)

Conforme apresentado na Figura 1, os elementos que constituem a célula de memória da rede *LSTM* são:

- t , que representa o tempo;
- S_{t-1} , a saída da camada anterior, no tempo $t - 1$, apresentada a estado como *input*;
- C_{t-1} , o estado da célula no tempo anterior;
- C_t , o estado da célula no tempo t ;
- X_t , que representa a amostra da sequência, o dado de entrada no tempo t ;
- f_t , o portão do esquecimento, que decide quais informações a respeito dos *inputs* apresentados devem ser descartadas;
- i_t , o *input gate*, que decide quais informações novas devem ser adicionadas no estado atual da célula;
- o_t , o *output gate*, que então filtra as informações que serão apresentadas a saída do modelo
- S_t , a saída da célula no tempo t ;

As características das redes *LSTM* permitem que elas sejam relativamente mais adequadas para trabalhar com análises de séries temporais, como é o caso dos problemas envolvendo previsões no mercado financeiro, por exemplo.

O uso de desses modelos têm demonstrado resultados consideravelmente satisfatórios, com análises voltadas a diversos mercados e setores da economia, tais como: previsão de tendências dos preços de etanol no mercado brasileiro (SANTOS, G. C. *et al.*, 2021), previsão de preços de carvão no mercado internacional (ALAMEER *et al.*, 2020), e previsão de preços de empresas listadas na bolsa indiana NSE e na bolsa de Nova York *NYSE* (HIRANSHA *et al.*, 2018). Devido a especificidade de cada um dos mercados e ativos presentes nos estudos mencionados, estes trabalhos também abordam como a modificação de características destes modelos como quantidade e composição das camadas ocultas, número de amostras de treino e teste, tamanho da janela temporal e período de previsão podem produzir previsões mais precisas.

As redes *LSTM* também têm sido utilizadas para realizar previsões sobre empresas do setor bancário. Utilizando dados do Banco Central da Ásia e do Banco Mandiri da Indonésia, Budiharto (2021) demonstrou bons resultados na previsão dos preços diários de OHLC – Abertura (*Open*), Máximo (*High*), Mínimo (*Low*) e Fechamento (*Close*) – utilizando 1 ano de dados históricos, e 100 épocas de treinamento. Yufeng Chen, Jinwang Wu e Zhongrui Wu (2022) usou uma abordagem baseada em *K-means* e *DTW* para criar *clusters* e realizar previsões sobre *Close* de 16 bancos comerciais chineses para intervalos de 5 e 22 dias. Os resultados indicaram melhor performance se comparados a modelos tradicionais, que não consideram completamente a correlação entre os dados das empresas analisadas. Por fim, Hansun e Young (2021) desenvolveram uma arquitetura mais simples, utilizando apenas três camadas de células *LSTM* para realizar também previsões sobre os preços de *Close* de seis bancos listados no índice LQ45 da bolsa de valores da Indonésia *IDX*. O modelo apresentou boa performance, em particular para dois dos ativos analisados.

3 METODOLOGIA

3.1 DESCRIÇÃO DOS DADOS

Este trabalho apresenta-se como um estudo exploratório de caráter quantitativo, uma vez que tem por objetivo analisar e avaliar o desempenho de um modelo de *Machine Learning* baseado em redes neurais do tipo *LSTM* para realizar a previsão dos preços diários de *Close* de empresas do setor bancário negociadas na bolsa brasileira, a B3.

Todo o desenvolvimento do trabalho foi viabilizado através da ferramenta Colab, do Google, por meio da qual é possível processar e armazenar dados em uma máquina virtual hospedada em uma nuvem pública. A linguagem de programação escolhida foi o Python, na versão 3.10.12.

Os indicadores de mercado, atividade econômica e setor são fatores que possuem influência sobre o desempenho das empresas, e outros estudos envolvendo a previsão de preços de ações já utilizaram estes dados na construção dos modelos (SANTOS, G. C. *et al.*, 2021), (GARRUTI *et al.*, 2022), (NARAYAN, P.; NARAYAN, S.; SINGH, 2014). Por isso foram selecionados aqueles de maior representatividade dentro do contexto do setor bancário e da bolsa brasileira - IBOV (principal indicador de desempenho das ações negociadas na B3), IFNC (indicador do desempenho médio das cotações dos ativos do setor financeiro) e ISE (indicador que mede o desempenho médio das empresas comprometidas com a pauta da sustentabilidade, e que tem alguns dos principais bancos do mercado brasileiro em sua composição) (B3, 2023).

As cinco empresas selecionadas para análise foram Banco do Brasil (BBAS3), Bradesco (BBDC4), BTG Pactual (BPAC11), Itaú Unibanco (ITUB4) e Santander (SANB11), alguns dos principais bancos que operam no mercado brasileiro. Juntas, essas empresas representam aproximadamente 16% da composição do índice Bovespa, e 60% da composição do índice IFNC (B3, 2023). Algumas dessas empresas já foram analisadas em outros estudos disponíveis na literatura (BALDUÍNO *et al.*, 2023), (SOUZA; SANTOS, P. H.; MOTA, 2019).

O período avaliado para coleta dos dados foi fixado entre as datas de 01/01/2020 a 31/07/2023. Esse intervalo de tempo compreende todo o início da Pandemia de Covid-19, que teve amplo impacto sobre o desempenho dos mercados financeiros (BUDIHARTO, 2021). A coleta de dados se encerra em 31/07/2023 devido a indisponibilidade de dados fundamentalistas mais recentes no portal BACEN, o que inviabilizaria o cálculo dos indicadores *CAMELS*.

Ao contrário das evidências presentes no estudo de Budiharto (2021), de modo geral, os modelos apresentaram métricas de desempenho melhores ao utilizar dados históricos de 3 anos para o treinamento da rede, conforme Tabela 1. Os modelos *LSTM* A e B foram os algoritmos avaliados neste trabalho. Os detalhes de como esses modelos foram construídos são explorados na seção “Pré-processamento dos dados” mais a frente.

Tabela 1 – *MAPE* verificado ao variar o intervalo de dados usado como base de treinamento.
Fonte: dados da pesquisa

Ativo	Modelo	MAPE	
		1 ano	3 anos
Banco do Brasil (BBAS3)	LSTM A	8.69	3.68
	LSTM B	8.83	6.89
Bradesco (BBDC4)	LSTM A	4.92	16.94
	LSTM B	7.06	19.51
BTG Pactual (BPAC11)	LSTM A	9.66	3.94
	LSTM B	17.76	10.49
Itaú (ITUB4)	LSTM A	3.56	3.53
	LSTM B	3.78	3.38
Santander (SANB11)	LSTM A	6.87	4.41
	LSTM B	2.58	5.12

Os dados diários referentes ao histórico de negociação dos ativos das empresas selecionadas (que incluem valores de *Open*, *High*, *Low*, *Close*, *Adj. Close* e *Volume*) bem como a taxa de câmbio, e o índice IBOV foram coletados através da biblioteca *Yahoo Finance*. A Figura 2 mostra a série de preços para os ativos pesquisados.




Figura 2 – Série histórica do preço de Close dos bancos selecionados no estudo. Fonte: Yahoo Finance

Com relação aos Balancetes e Balanços Patrimoniais mensais dos bancos, foram coletados junto ao portal do BANCO CENTRAL DO BRASIL (2023) e utilizados para calcular os indicadores do modelo *CAMELS*, conforme (BARBOZA *et al.*, 2023). Por fim,

variáveis como a taxa de juros SELIC, e os indicadores específicos da bolsa de valores brasileira IFNC e ISE foram coletados com as bibliotecas *python-bcb* e *tvDatafeed*.

Em razão da diferença de granularidade entre os dados dos preços diários das ações dos bancos e dos índices *CAMELS* calculados com dados fundamentalistas mensais, foi preciso replicar os indicadores *CAMELS* em todos os dias do mês correspondente.

Ao todo, dado o período definido e a adaptação feita em razão da diferença de granularidade de dados mensais e diários, 889 amostras de dados referente aos ativos foram coletados em um *dataframe* de 37 colunas, contendo cada um dos indicadores e variáveis mencionados anteriormente. Devido a indisponibilidade de dados fundamentalistas mais recentes sobre os bancos, não foi possível estimar os índices *CAMELS* após o período de julho de 2023.

3.2 PRÉ-PROCESSAMENTO DOS DADOS

Todos os dados coletados passaram por um rigoroso processo de avaliação, em que observações faltantes e outras anomalias foram devidamente tratadas. Depois, as informações referentes ao histórico de negociação dos ativos, as variáveis do modelo *CAMELS*, e os demais indicadores foram agrupados em um único conjunto de dados específico para cada uma das empresas selecionadas.

Em seguida foram definidas as janelas temporais e os períodos de previsão dos modelos, ou seja, a quantidade de dias anteriores que serão utilizados para prever uma quantia de dias à frente. Para os objetivos deste estudo, foram criados dois modelos para cada um dos ativos, que realizam previsões a respeito do preço de *Close* para o dia seguinte. O modelo A utiliza uma janela de 5 dias anteriores para fazer a predição diária, enquanto o modelo B utiliza uma janela de 21 dias. Esses valores correspondem a quantidade dias úteis decorridas durante uma semana e um mês de pregão na bolsa, respectivamente.

Os dados então foram separados linearmente em bases de treino e teste, sendo 80% destinados à primeira, compreendendo o período de 02/01/2020 a 19/10/2022, e 20% para o restante, que corresponde ao intervalo entre as datas de 20/10/2022 a 28/07/2023 (BUDIARTO, 2021). Por fim, foi necessário escalonar os dados para que eles pudessem ser inseridos no modelo da arquitetura *LSTM*, utilizando o método o método *Standard Scaler* (1) da biblioteca *Scikit Learn*. Ele é utilizado para reescalonar a distribuição dos valores. de modo que a média observada dos valores seja 0 e o desvio padrão, 1. O cálculo de redimensionamento dos dados realizado no processo de padronização é dado por (1), tal que z é o valor padronizado, x é o valor original da *feature*, μ é a média das amostras da *feature*, σ é o desvio padrão das amostras da *feature*.

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

O escalonamento é fundamental para reduzir a imprecisão das previsões, e o *Stan-*

Standard Scaler é amplamente utilizado em diversos modelos de *Machine Learning* (AHSAN *et al.*, 2021).

3.3 DEFINIÇÃO DA ARQUITETURA DA REDE *LSTM*

Para criar ambos os modelos avaliados neste trabalho, foi utilizada a *API Keras*, da biblioteca do *TensorFlow*, que permite criar e treinar modelos de aprendizado profundo (TENSORFLOW, 2020). Ambos os modelos também utilizaram o método *Sequential* da *API (Application Programming Interface)* do Keras, que define uma arquitetura baseada no empilhamento de camadas.

A arquitetura proposta para este estudo, conforme *snippet* de código na Listagem 3.1 possui 3 camadas: camada *LSTM*, com 128 unidades de células de memória, utilizando a função de ativação de Unidade Linear Retificada (ReLU) (2); uma camada de *Dropout*, com taxa fixada em 0.2, como forma de evitar cenários de *overfitting*; e, por fim, devido a natureza do problema (regressão e previsão de uma única variável, o preço) a camada de saída *Dense*, contendo um único neurônio, de ativação linear. A escolha por essa arquitetura se baseou no estudo de Hansun e Young (2021), que encontrou evidências de que modelos de deep learning mais simples, com menos camadas escondidas (*hidden layers*) também podem produzir resultados satisfatórios. A opção da função ReLU (Eq. (2)) foi motivada pela ampla aceitação que ela tem na comunidade científica (RAMACHANDRAN; ZOPH; LE, 2017), ainda que outras funções de ativação sejam mais comumente utilizadas no treinamento de redes LSTM, caso das funções de tangente hiperbólica, por exemplo (FARZAD; MASHAYEKHI; HASSANPOUR, 2019).

A taxa de aprendizagem (0,01), número de épocas (100), e *batch size* (64) também foram fixados para ambos os modelos. Para a otimização do modelo foi utilizado o algoritmo de estimativa de momento adaptativo ADAM (KINGMA; BA, 2014) e a função de perda *MSE* (vide Eq. (3)).

Listagem 3.1 – Definição da arquitetura da rede LSTM com a API Keras do TensorFlow

```
1 random.seed(seed=1234)
2 model = Sequential()
3 model.add(InputLayer((window_size, 37)))
4 model.add(LSTM(128, activation='relu'))
5 model.add(Dropout(0.2))
6 model.add(Dense(1, 'linear'))
7 model.summary()
8
9 model.compile(loss=MeanSquaredError(), optimizer=Adam(
    learning_rate=0.01), metrics=[RootMeanSquaredError()])
10
```

```

11 history = model.fit(input_train, output_train, batch_size=64,
    epochs=100, validation_data=(input_test, output_test))

```

$$\text{ReLU}(x) = \max(0, x) \quad (2)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

A variação em alguns desses parâmetros pode provocar alterações no comportamento dos modelos, como a velocidade do tempo de treinamento (GOODFELLOW; BENGIO; COURVILLE, 2016)

3.4 MÉTRICAS DE DESEMPENHO

As métricas para avaliação das previsões da rede foram: *MAE* (*Mean absolute error*), ou erro médio absoluto; *MAPE* (*Mean absolute percentage error*), ou o erro percentual médio; e *RMSE* (*Root mean square error*), ou raiz do erro quadrático médio.

A tabela 2 apresenta as respectivas fórmulas para calcular as métricas de erro utilizadas, bem como algumas de suas características.

Tabela 2 – Métricas de performance para avaliar os modelos

Métrica	Fórmula	Descrição (Referência)
MAE	$\frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	Aponta o quão distante está a previsão do valor real. Quanto mais próximo de 0, melhor (CHEN, Y.; WU, J.; WU, Z., 2022).
MAPE	$\frac{100}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{ y_i }$	Semelhante ao MAE, mas apresenta os valores em termos percentuais (SAMARAWICKRAMA; FERNANDO, 2017; HANSUN; YOUNG, 2021).
RMSE	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	Avalia o desvio médio das previsões em relação ao valor alvo. É mais sensível a valores extremos. Quanto menor, melhor (WEN; LIN, P.; NIE, 2020; BUDIHARTO, 2021).

Os resultados verificados pelos modelos relativos a essas métricas foram comparados com o tradicional modelo teórico do *Random Walk*, considerado o melhor resultado num mercado eficiente (FAMA, 1995), e definido pela equação equação (4), apresentada a seguir:

$$Y_t = Y_{t-1} + e \quad (4)$$

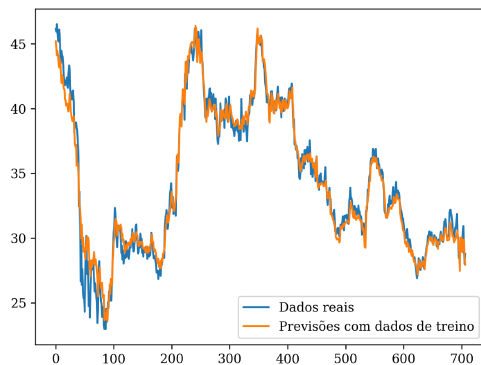
De modo geral, esse modelo considera que a melhor previsão para o preço de amanhã é o preço de hoje.

4 RESULTADOS E DISCUSSÕES

O comportamento dos modelos, verificados a partir dos gráficos que ilustram o decréscimo das curvas de *loss* durante o processo de treinamento, demonstram que, apesar da adição da camada de Dropout, todos os modelos apresentaram *overfitting* (sobreajuste) (Apêndice A), cenário no qual o modelo é sensivelmente mais preciso na fase de treinamento, mas não é capaz de generalizar as novas informações que são apresentadas na fase de teste (GOODFELLOW; BENGIO; COURVILLE, 2016).

Em partes, esse problema pode ser explicado pela diferença de granularidade de alguns dos dados que compõem o *dataframe* utilizado por ambos os modelos, caso das variáveis do sistema *CAMELS*, de frequência mensal, que tiveram de ser adaptadas para compor o *dataset* de preços diários. A redundância nos dados que surgiu em razão dessa adaptação é um fator de risco que aumenta as chances de ocorrência de comportamentos de sobreajuste em modelos de redes neurais (AYINDE; INANC; ZURADA, 2019).

Os problemas de *overfitting* verificados na fase de treinamento também tiveram influência significativa sobre a precisão dos modelos, o que pode ser conferido por meio dos gráficos que ilustram as previsões realizadas na fase de treino (Apêndice A) e na fase de teste (Apêndice B). Os gráficos da Figura R3 apresentam a diferença entre as previsões realizadas na fase de treino e teste para o modelo A, utilizando dados do ativo SANB11.



(a) Modelo A (Treino) - SANB11



(b) Modelo A (Teste) - SANB11

Figura 3 – Comparação entre as previsões de treino e teste geradas pelo modelo A para o ativo SANB11

Ainda que haja evidências demonstrando a influência de algumas dos indicadores do sistema *CAMELS* sobre o preço das ações dos bancos (NUGROHO; HALIK; ARIF, 2020), os resultados gerais referentes às métricas de erro das previsões, bem como o comportamento de *overfitting* verificado na fase de treino dos dois modelos, parecem indicar que essas variáveis podem não ser as mais adequadas para realizar previsões de preços diários. Soma-se a isso o fato de boa parte dos sistemas de *trading* automatizado não se basear em dados fundamentalistas, como é o caso do modelo *CAMELS* (ARAÚJO;

CASTRO, 2010). Ademais, boa parte dos exemplos disponíveis na literatura envolvendo o uso de variáveis do modelo *CAMELS* em conjunto com técnicas de *Machine Learning* concentram seus esforços em análises relativas a performance, liquidez e solidez financeira dos bancos (BARBOZA *et al.*, 2023), (GUERRA; CASTELLI, 2021), (BOYACIOGLU; KARA; BAYKAN, 2009).

Vale destacar também que o estudo correlato de Tavelin e Brito (2021) obteve bons resultados ao avaliar e prever as tendências de alta e baixa de ações do setor bancário brasileiro utilizando tanto dados de mercado como as variáveis do sistema *CAMELS* e dados fundamentalistas em modelos baseados em RF e SVM. As previsões foram feitas para um período futuro de 90 dias e obtiveram uma taxa média de acerto de 67%. Esse resultado, combinado às características das variáveis *CAMELS* e sua granularidade, sugerem que melhores previsões de preços podem ser alcançadas ampliando o intervalo de previsão, de modo a considerar a influência das variáveis *CAMELS* sobre o preço em períodos de tempo mais longos.

Uma possível abordagem para identificar a real influência e adequação das variáveis *CAMELS* sobre o preço das ações dos bancos e evitar cenários de *overfitting* é utilizar técnicas de *feature selection*, que são capazes de reduzir a dimensionalidade do *dataset* utilizado na fase de treinamento de modelos de redes neurais, removendo variáveis desnecessárias e melhorando a performance geral do modelo (CHEN, S.; ZHOU, 2021), (KIM, G.-H.; KIM, S.-H., 2019).

Os resultados gerais referentes às métricas analisadas e a comparação com o modelo teórico *Random Walk* são apresentados na Tabela 3, a seguir.

Tabela 3 – Resultados gerais dos modelos *LSTM* com janela de 5 dias (*LSTM A*) e 21 dias (*LSTM B*), comparados com o modelo teórico *RW*. Fonte: dados da pesquisa.

Ativo	Modelo	Close		
		MAE	MAPE	RMSE
Banco do Brasil (BBAS3)	LSTM A	1.52	3.68	1.87
	LSTM B	3.04	6.89	3.88
	RW	0.56	1.39	0.72
Bradesco (BBDC4)	LSTM A	2.42	16.94	2.70
	LSTM B	2.75	19.51	3.28
	RW	0.22	1.54	0.29
BTG Pactual (BPAC11)	LSTM A	0.99	3.94	1.24
	LSTM B	2.67	10.49	3.58
	RW	0.50	2.11	0.62
Itaú (ITUB4)	LSTM A	0.90	3.53	1.03
	LSTM B	0.86	3.38	1.05
	RW	0.34	1.32	0.44
Santander (SANB11)	LSTM A	1.23	4.41	1.48
	LSTM B	1.43	5.12	1.70
	RW	0.36	1.26	0.46

Considerando a performance geral dos modelos, nota-se que nenhum deles foi capaz de produzir previsões melhores do que o modelo teórico do *Random Walk* para qualquer um dos cinco ativos avaliados neste estudo. Essa constatação contraria evidências relativas a outros mercados encontradas em Garruti *et al.* (2022), Laboissiere, Fernandes e Lage (2015), e Balduino *et al.* (2023) no setor bancário.

A fim de confirmar essa hipótese, as métricas *MAE*, *MAPE* e *RMSE* de cada um dos modelos foram comparadas às métricas do modelo RW via Teste de Diebold-Mariano (DIEBOLD; MARIANO, 2002), (HARVEY; LEYBOURNE; NEWBOLD, 1997). Os resultados dessa comparação indicaram alta significância estatística* (Apêndice D), indicando que há potenciais elementos que atestam a favor da eficiência do mercado de ações brasileiro, pelo menos no que diz respeito aos 5 ativos analisados.

Ao observar os resultados, nota-se também que nenhum dos modelos *LSTM* conseguiu superar a performance média ideal de previsões diárias para qualquer uma das três métricas analisadas conforme Barboza, Nunes Silva e Augusto Fiorucci (2023). No entanto, alguns ativos em particular apresentaram um desempenho um pouco melhor, especialmente para o modelo A. É o caso dos ativos BBAS3, BPAC11 e ITUB4.

Ao contrário de evidências encontradas em Hiransha *et al.* (2018), a ampliação das janelas temporais para um mesmo período de previsão fixo não resultou em melhores métricas, exceto no caso do banco Itaú, que também manteve métricas de erro relativamente próximas em ambos os modelos.

Ainda que os resultados gerais apresentados pelos modelos não tenham sido suficientes para indicar a ineficiência do mercado brasileiro, uma análise mais minuciosa a respeito das previsões realizadas revela padrões interessantes. Em primeiro lugar, é possível observar que as previsões de todos os modelos são particularmente mais precisas nos primeiros dias, em especial no período estipulado entre 16/11/2022 e 30/11/2022, totalizando 11 dias de pregão em bolsa (Apêndice E). A Tabela 4 apresentadas a seguir, demonstra a diferença entre o erro percentual (*MAPE*) dos modelos em todo o período de previsão em comparação a segunda metade do mês de novembro.

A melhoria considerável da performance apresentada nos primeiros 11 dias de previsões, que decai consideravelmente nos dias e meses posteriores, indica que um futuro estudo pode ser desenvolvido utilizando a abordagem de Janela Rolante (*Rolling window*). Esse procedimento consiste em projetar a janela e o intervalo de previsão à frente, percorrendo todo o comprimento de dados disponíveis (KRISTJANPOLLER *et al.*, 2021), (SANTOS, G. C. *et al.*, 2021).

O comportamento verificado no mês de novembro também pode indicar a influência de fatores exógenos sobre o preço das ações dos bancos, neste caso específico, o segundo turno das Eleições Presidenciais do Brasil, que foram realizadas no dia 30 de outubro. O estudo de Souza, Pedro Henrique Santos e Mota (2019) demonstrou que investidores de ativos como Banco do Brasil, Bradesco, Itaú e Santander tiveram condições de auferir

Tabela 4 – Comparação entre as métricas das previsões realizadas no mês de novembro e o resultado geral. Fonte: dados da pesquisa.

Ativo	Modelo	MAPE	
		Novembro	Res. Geral
Banco do Brasil (BBAS3)	LSTM A	1.38	3.68
	LSTM B	1.44	6.89
Bradesco (BBDC4)	LSTM A	2.58	16.94
	LSTM B	3.81	19.51
BTG Pactual (BPAC11)	LSTM A	3.39	3.94
	LSTM B	2.92	10.49
Itaú (ITUB4)	LSTM A	1.97	3.53
	LSTM B	2.92	3.38
Santander (SANB11)	LSTM A	1.23	4.41
	LSTM B	1.51	5.12

ganhos acima do esperado em períodos anteriores e posteriores a data das eleições nos anos de 2006 a 2014.

Observando as métricas de erro dos modelos *LSTM* do mesmo período por meio da Tabela 5, e comparando-as com o *Random Walk*, nota-se também que a rede *LSTM* foi capaz de produzir previsões melhores do que o modelo teórico, em particular para o ativo BBAS3, que foi superior nas três métricas avaliadas, tanto no modelo A quanto no modelo B.

Tabela 5 – Resultados das métricas de erro geradas no mês de novembro (11 primeiros dias de previsão). Fonte: dados da pesquisa.

Ativo	Modelo	Close		
		MAE	MAPE	RMSE
Banco do Brasil (BBAS3)	LSTM A	0.48	1.38	0.58
	LSTM B	0.50	1.44	0.56
	RW	0.62	1.79	0.71

A seguir, na Figura 4, são apresentadas as previsões realizadas pelos modelos A e B durante o mês de novembro para o ativo BBAS3.

O Banco do Brasil é a única empresa controlada pelo Estado entre os ativos avaliados, e foi um dos ativos mais impactados pelos resultados da eleição de 2014 (CARVALHO; RIBEIRO; ZILBERMAN, 2017). Os resultados superiores que os dois modelos baseados em *LSTM* apresentaram em relação ao modelo teórico do *Random Walk* podem indicar maior sensibilidade deste ativo em relação a eventos políticos de grande magnitude.

Outro caso que merece consideração especial é o Banco Bradesco, que foi o que apresentou as piores taxas de erro. Na Figura 5 é possível perceber que, entre os períodos de janeiro e maio, os preços previstos pelos modelos A e B se tornam ainda mais distante dos

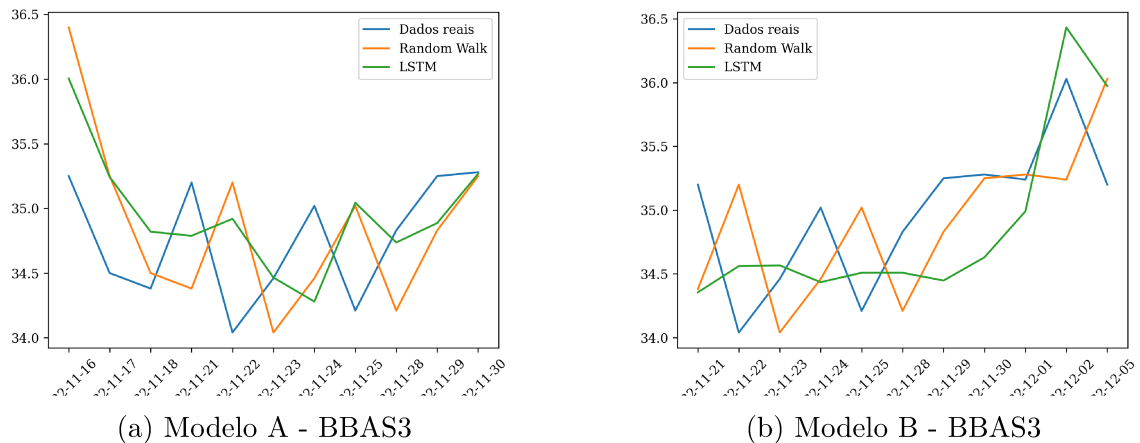


Figura 4 – Comparação entre as previsões modelos A e B geradas no mês de novembro (11 primeiros dias de previsão)

preços reais, com uma taxa de erro percentual médio (*MAPE*) de 21% nos dois modelos.

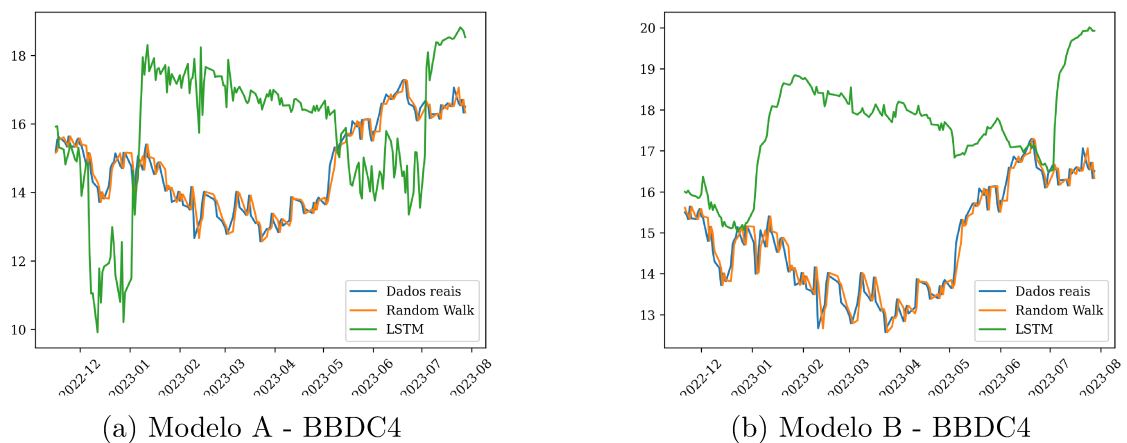


Figura 5 – Previsões realizadas pelos modelos A e B para o ativo BBDC4

Coincidentemente, é no mês de janeiro, mais especificamente no dia 11, que a companhia Lojas Americanas S.A. (AMER3) apresenta o Fato Relevante referente a inconsistências contábeis de mais de R\$20 bilhões em seus balanços (AMERICANAS SA, 2023). A notícia abalou o mercado e os papéis da empresa caíram em aproximadamente 80% imediatamente após o anúncio (G1, 2023). Vários dos principais bancos brasileiros estão diretamente envolvidos. O Bradesco figura entre os principais credores, sendo o banco mais exposto a crise das Lojas Americanas, com mais de R\$ 4 bilhões em valores à receber da empresa (FOLHA DE SÃO PAULO, 2023).

A queda acentuada no valor das ações das Lojas Americanas causada pelo escândalo contábil parece ter influenciado o comportamento do índice IBOVESPA e o preço das ações do Bradesco, que também registrou queda entre janeiro e início de maio (Figura 7).

Portanto, é razoável supor que o erro acentuado apresentado pelas previsões entre

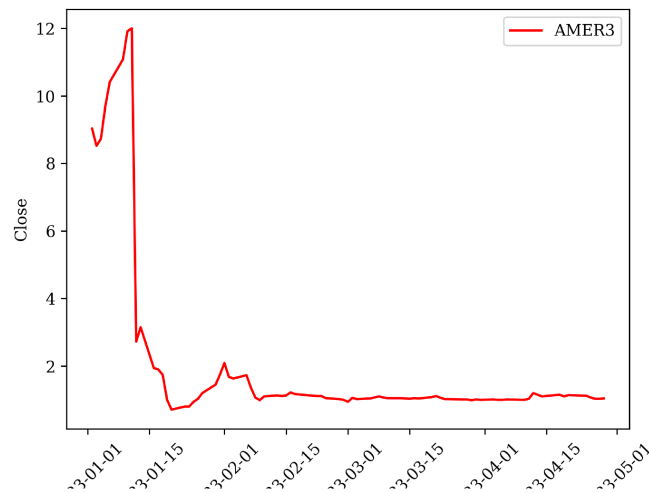


Figura 6 – Preço das ações das Lojas Americanas (AME3) entre 01/2023 e 05/2023




Figura 7 – Pontuação do índice IBOV entre 01/2023 e 05/2023. Fonte: Yahoo Finance

janeiro e maio de 2023 em comparação aos dados reais (particularmente para o banco Bradesco) pode ser atribuído a diversos fatores, dentre os quais: a construção dos modelos e a forma como foram treinados; ruídos causados por dados redundantes; e, principalmente, a incapacidade dos modelos (dadas as suas características) de incorporarem o comportamento dos investidores e do mercado diante de um escândalo contábil e administrativo da magnitude do caso Lojas Americanas. Esse comportamento dos modelos é evidenciado e demonstrado também pelas métricas de erro gerais apresentadas na Tabela 3, bem como pelos testes de significância estatística Diebold-Mariano, que mostraram que os modelos apresentados neste estudo não puderam atestar em favor da Hipótese dos Mercados Adaptativos de Lo (2004).

5 CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi realizar a previsão diária do preço de fechamento de cinco das principais empresas do setor bancário brasileiro, avaliando a influência de fatores externos e indicadores de atividade e performance do modelo *CAMELS* sobre o preço dessas ações. Foram desenvolvidos dois modelos com base em redes neurais *LSTM*, com janelas temporais diferentes (5 e 21 dias) para cada um deles. Ambos foram configurados com uma arquitetura simples de três camadas e tiveram sua performance comparadas ao modelo teórico do *Random Walk*. Além disso, foram realizados testes de Diebold-Mariano para verificar a significância estatística na comparação das métricas dos modelos.

A adição de uma camada de *Dropout* não foi capaz de evitar cenários de *overfitting* Goodfellow, Bengio e Courville (2016) em ambos os modelos. De modo geral, foi perceptível que os modelos propostos não foram capazes de produzir previsões superiores às do modelo teórico *RW*. Esse resultado pode estar relacionado aos dados selecionados para compor o *dataset* do modelo de previsão, bem como o problema da redundância de dados do modelo *CAMELS* que ampliou o risco de *overfitting* (AYINDE; INANC; ZURADA, 2019).

Diante desse cenário, a arquitetura mais simples, com menos camadas escondidas (HANSUN; YOUNG, 2021), não foi capaz de se adequar ao conjunto de dados proposto e produzir boas previsões. A ampliação das janelas temporais também não produziu melhores previsões, ao contrário dos resultados encontrados em Hiransha *et al.* (2018). Ao ampliar a janela de previsão, o ruído dos dados redundantes presentes no *dataset* provavelmente ampliou o efeito do ruído sobre as previsões, tornando-as menos precisas.

Os problemas verificados na composição do conjunto de dados tiveram impactos sobre as previsões realizadas pelos modelos. A partir dos testes de Diebold-Mariano, verificou-se uma desvantagem estatisticamente significativa entre os resultados das previsões baseadas em redes neurais quando comparados ao modelo teórico de *Random Walk* para todos os ativos analisados no estudo. Portanto, diante dos resultados apontados pelos modelos propostos, não foi possível comprovar que os ativos do setor bancário analisados se comportem de forma contrária ao que afirma a Hipótese dos Mercados Eficientes de Fama (1970).

No entanto, uma análise mais minuciosa dos dados revelou que as métricas de erro são sensivelmente mais baixas nos primeiros dias de previsão. Essa análise demonstrou ainda que pelo menos um dos ativos, o BBAS3 apresentou melhores métricas do que o modelo teórico do *Random Walk* no mês de Novembro, período imediatamente posterior as Eleições Presidenciais no Brasil. Essas descobertas abrem margem para estudos futuros explorando técnicas como Janela Rolante (KRISTJANPOLLER *et al.*, 2021), e/ou a possibilidade de estudos focados em ativos mais sensíveis a períodos eleitorais, a fim de verificar a eficiência dos mercados nesses cenários (CARVALHO; RIBEIRO; ZILBERMAN, 2017).

Em razão dos resultados obtidos neste estudo e suas implicações, melhorias e modificações podem ser implementadas para corrigir algumas das dificuldades e fragilidades dos modelos descritos neste estudo. Algumas das possibilidades são: adição de mais camadas ao modelo, modificando a estrutura da arquitetura tal como (ALAMEER *et al.*, 2020) e (BALDUÍNO *et al.*, 2023); otimização de hiper-parâmetros da rede (LIU; SUZUKI; DU, 2023); explorar técnicas mais avançadas para tratar o problema de diferentes granularidades temporais na base de treinamento (WIEDERHOLD; JAJODIA; LITWIN, 1991); avaliar o uso de abordagens híbridas, com o uso de análise de *clusters*, por exemplo (CHEN, Y.; WU, J.; WU, Z., 2022), explorando as correlações entre os dados dos ativos; e ampliar a janela e período de previsão, a fim de verificar o efeito da variável *CAMELS* a longo prazo (TAVELIN; BRITO, 2021).

REFERÊNCIAS

- AHSAN, Md Manjurul; MAHMUD, M. A. Parvez; SAHA, Pritom Kumar; GUPTA, Kishor Datta; SIDDIQUE, Zahed. Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance. **Technologies**, v. 9, n. 3, 2021.
- ALAMEER, Zakaria; FATHALLA, Ahmed; LI, Kenli; YE, Haiwang; JIANHUA, Zhang. Multistep-ahead forecasting of coal prices using a hybrid deep learning model. **Resources Policy**, v. 65, p. 101588, 2020.
- AMERICANAS SA. **Comunicados e Fatos Relevantes**. São Paulo-SP: [s.n.], 2023. Disponível em: <https://ri.americanas.io/informacoes-aos-investidores/comunicados-e-fatos-relevantes/>. Acesso em: 25 nov. 2023/.
- ARAÚJO, Carlos Henrique Dejavite; CASTRO, Paulo André Lima de. Towards Automated Trading Based on Fundamentalist and Technical Data. *In*: ROCHA COSTA, Antônio Carlos da; VICARI, Rosa Maria; TONIDANDEL, Flavio (Ed.). **Advances in Artificial Intelligence – SBIA 2010**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. P. 112–121.
- ARÉVALO, Andrés; NIÑO, Jaime; HERNANDEZ, German; SANDOVAL, Javier; LEÓN, Diego; ARAGÓN, Arbey. Algorithmic Trading Using Deep Neural Networks on High Frequency Data. *In*: APPLIED Computer Sciences in Engineering. Cham: Springer International Publishing, 2017. P. 144–155.
- AUTORE, Don; BILLINGSLEY, Randall; SCHNELLER, Meir. Information Uncertainty and Auditor Reputation. **Journal of Banking & Finance**, v. 33, p. 183–192, 2009.
- AYINDE, Babajide; INANC, Tamer; ZURADA, Jacek. Redundant feature pruning for accelerated inference in deep neural networks. **Neural Networks**, v. 118, 2019.
- B3. **Ibovespa B3 | B3**. [S.l.: s.n.], 2023. Disponível em: www.b3.com.br. Acesso em: 18 jun. 2023.
- BALDUÍNO, Vinícios Antônio Passos; GARRUTI, Daniel Vitor Tartari; BARBOZA, Flavio; LEMES, Leandro Cruvinel; ALÉSSIO, Osmar. Análise de Ativos Financeiros Por Meio de Rede Neural Recorrente do Tipo LSTM. *In*: ENCONTRO DE GESTÃO E NEGÓCIOS. *Anais....* Uberlândia: UFU/FAGEN, 2023.

BANCO CENTRAL DO BRASIL. **Balancetes e Balanços Patrimoniais**. [S.l.: s.n.], 2023. Disponível em: www.bcb.gov.br. Acesso em: 20 nov. 2023/.

BARBOZA, Flavio; BARBOSA, Jorge Henrique de Frias; KIMURA, Herbert; SANTOS, Gustavo Carvalho; CORTEZ, Paulo. Early warning system for preventing bank distress in Brazil. **International Journal of Business and Systems Research**, v. 17, p. 326, 2023.

BARBOZA, Flavio; KIMURA, Herbert; ALTMAN, Edward. Machine Learning Models and Bankruptcy Prediction. **Expert Systems with Applications**, v. 83, 2017.

BARBOZA, Flavio; NUNES SILVA, Geraldo; AUGUSTO FIORUCCI, José. A review of artificial intelligence quality in forecasting asset prices. **Journal of Forecasting**, v. 47, n. 7, 2023.

BLACK, Fischer. Noise. **Journal of Finance**, v. 41, n. 3, p. 529–43, 1986.

BOYACIOGLU, Melek Acar; KARA, Yakup; BAYKAN, Ömer Kaan. Predicting bank financial failures using neural networks, support vector machines and multivariate statistical methods: A comparative analysis in the sample of savings deposit insurance fund (SDIF) transferred banks in Turkey. **Expert Systems with Applications**, v. 36, 2, Part 2, p. 3355–3366, 2009.

BRAV, Alon; HEATON, J. B. Competing Theories of Financial Anomalies. **The Review of Financial Studies**, v. 15, n. 2, p. 575–606, 2002.

BUDIHARTO, Widodo. Data science approach to stock prices forecasting in Indonesia during Covid-19 using Long Short-Term Memory (LSTM). **Journal of Big Data**, v. 8, 2021.

CAMPOS, Nauro F.; HANOUSEK, Jan; FILER, Randall K. Do Stock Markets Promote Economic Growth? **The Center for Economic Research and Graduate Education - Economics Institute, Working Papers**, wp151, 1999. Disponível em: <https://ideas.repec.org/p/cer/papers/wp151.html>. Acesso em: 14 nov. 2023.

CARDOT, Hubert. **Recurrent Neural Networks for Temporal Data Processing**. Londres: InTech, 2011.

CARVALHO, Carlos; RIBEIRO, Ruy; ZILBERMAN, Eduardo. Sentiment, Electoral Uncertainty and Stock Returns. **SSRN**, 2017. Disponível em: <http://dx.doi.org/10.2139/ssrn.2930564>. Acesso em: 16 nov. 2023.

CASU, B.; GIRARDONE, C.; MOLYNEUX, P. **Introduction to Banking**. 3a. ed. Londres: Pearson, 2006.

CHEN, Shile; ZHOU, Changjun. Stock Prediction Based on Genetic Algorithm Feature Selection and Long Short-Term Memory Neural Network. **IEEE Access**, v. 9, p. 9066–9072, 2021.

CHEN, Yufeng; WU, Jinwang; WU, Zhongrui. China's commercial bank stock price prediction using a novel K-means-LSTM hybrid approach. **Expert Systems with Applications**, v. 202, p. 117370, 2022.

COLLINS, John. How to study the behavior of bank stocks. **Financial Analysts Journal**, v. 13, n. 2, p. 109–113, 1957.

DAL MAGRO, Cristian Bau; MICHELS, Andressa; SILVA, Tarcísio Pedro da. Análise da eficiência no desempenho financeiro das cooperativas de crédito brasileiras. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 13, n. 2, 2017.

DASE, R.K.; PAWAR, D.D. Application of Artificial Neural Network for stock market predictions: A review of literature. **International Journal of Machine Intelligence**, v. 2, 2010.

DEANGELO, Harry; STULZ, René. Liquid-claim production, risk management, and bank capital structure: Why high leverage is optimal for banks. **Journal of Financial Economics**, v. 116, n. 2, p. 219–236, 2015.

DIEBOLD, Francis X; MARIANO, Robert S. Comparing predictive accuracy. **Journal of Business & economic statistics**, v. 20, n. 1, p. 134–144, 2002.

EL NAQA, Issam; MURPHY, Martin. What Is Machine Learning? *In: MACHINE Learning in Radiation Oncology*. Cham: Springer, 2015. P. 3–11.

FAMA, Eugene F. Efficient Capital Markets: A Review of Theory and Empirical Work. **The Journal of Finance**, v. 25, n. 2, p. 383–417, 1970.

- FAMA, Eugene F. Random Walks in Stock Market Prices. **Financial Analysts Journal**, v. 51, n. 1, p. 75–80, 1995.
- FARZAD, Amir; MASHAYEKHI, Hoda; HASSANPOUR, Hamid. A comparative performance analysis of different activation functions in LSTM networks for classification. **Neural Computing and Applications**, v. 31, p. 2507–2521, 2019.
- FIELDS, L. Paige; FRASER, Donald R.; WILKINS, Michael S. An investigation of the pricing of audit services for financial institutions. **Journal of Accounting and Public Policy**, v. 23, n. 1, p. 53–77, 2004.
- FIESLER, Emile. Neural network classification and formalization. **Computer Standards & Interfaces**, v. 16, n. 3, p. 231–239, 1994.
- FOLHA DE SÃO PAULO. **Bradesco e Americanas entram em acordo sobre dívida para acelerar recuperação judicial**. São Paulo-SP: [s.n.], 2023. Disponível em: <https://www1.folha.uol.com.br/mercado/2023/09/bradesco-e-americanas-entram-em-acordo-sobre-divida-para-acelerar-recuperacao-judicial.shtml>.
- G1. **Americanas desaba na bolsa após descoberta de rombo de R\$ 20 bilhões; entenda o caso**. [S.l.: s.n.], 2023. Disponível em: <https://g1.globo.com/economia/noticia/2023/01/12/americanas-desaba-na-bolsa-apos-descoberta-de-rombo-de-r-20-bilhoes-entenda-o-caso.ghtml>. Acesso em: 25 nov. 2023.
- GARRUTI, Daniel; BARBOZA, Flavio; SILVEIRA, Lucas; NETO, Gumercindo. Qualidade de previsões dos preços máximos e mínimos: uma análise aplicada a ações do setor elétrico. In: SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO, XXIX. *Anais...* Bauru: Unesp/FEB, 2022.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016.
- GU, Shihao; KELLY, Bryan T.; XIU, Dacheng. Empirical Asset Pricing Via Machine Learning. **SSRN**, 2018.
- GUERRA, Pedro; CASTELLI, Mauro. Machine Learning Applied to Banking Supervision a Literature Review. **Risks**, v. 9, n. 7, 2021.

- HAMILTON, James D; LIN, Gang. Stock market volatility and the business cycle. **Journal of applied econometrics**, v. 11, n. 5, p. 573–593, 1996.
- HANSEN, Kristian Bando. The virtue of simplicity: On machine learning models in algorithmic trading. **Big Data & Society**, v. 7, n. 1, p. 2053951720926558, 2020.
- HANSUN, Seng; YOUNG, Julio. Predicting LQ45 financial sector indices using RNN-LSTM. **Journal of Big Data**, v. 8, p. 104, 2021.
- HARVEY, David; LEYBOURNE, Stephen; NEWBOLD, Paul. Testing the equality of prediction mean squared errors. **International Journal of forecasting**, v. 13, n. 2, p. 281–291, 1997.
- HAYKIN, Simon. **Neural networks: a comprehensive foundation**. Londres: Prentice Hall PTR, 1998.
- HIRANSHA, M; GOPALAKRISHNAN, E A; MENON, V. K.; SOMAN, K. P. NSE Stock Market Prediction Using Deep-Learning Models. **Procedia Computer Science**, v. 132, p. 1351–1362, 2018.
- HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-term Memory. **Neural computation**, v. 9, p. 1735–80, 1997.
- JOAQUIM, Gustavo; DOORNIK, Bernardus Van; ORNELAS, José Renato. **Bank Competition, Cost of Credit and Economic Activity: evidence from Brazil**. Brasília, 2019. Disponível em: <https://ideas.repec.org/p/bcb/wpaper/508.html>. Acesso em: 10 nov. 2023.
- KIM, Gang-Hoo; KIM, Sung-Ho. Variable Selection for Artificial Neural Networks with Applications for Stock Price Prediction. **Applied Artificial Intelligence**, v. 33, n. 1, p. 54–67, 2019.
- KINGMA, Diederik; BA, Jimmy. Adam: A Method for Stochastic Optimization. **arXiv preprint arXiv:1412.6980**, 2014.
- KRISTJANPOLLER, Werner; MICHELL, Kevin; MINUTOLO, Marcel C.; DHEERIYA, Prakash. Trading support system for portfolio construction using wisdom of artificial crowds and evolutionary computation. **Expert Systems with Applications**, v. 177, p. 114943, 2021.

- KROSZNER, Randall; STRAHAN, Philip. Bankers on Boards. **Journal of Financial Economics**, v. 62, p. 415–452, 2001.
- LABOISSIERE, Leonel A.; FERNANDES, Ricardo Augusto Souza; LAGE, Guilherme 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.
- LIU, Wei; SUZUKI, Yoshihisa; DU, Shuyi. Forecasting the Stock Price of Listed Innovative SMEs Using Machine Learning Methods Based on Bayesian optimization: Evidence from China. **Computational Economics**, 2023.
- LO, Andrew. The Adaptive Markets Hypothesis: Market Efficiency from an Evolutionary Perspective. v. 30, p. 15–129, 2004.
- LOBO, Gerald. Accounting research in banking – A review. **China Journal of Accounting Research**, v. 10, p. 1–7, 2017.
- MEDYAWATI, Henny; YUNANTO, Muhammad. Determinants of Banking Sector Stock Prices in Indonesia. **Journal of Economics, Finance and Accounting Studies**, v. 5, p. 40–51, 2023.
- MILANEZ, Daniel Yabe. **Finanças comportamentais no Brasil**. 2003. Dissertação (Mestrado em Economia das Instituições e do Desenvolvimento) – Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo.
- MUSSA, Adriano; EDWARD, YANG; TROVÃO, Ricardo; RUBENS, FAMÁ. Hipótese de mercados eficientes e finanças comportamentais: as discussões persistem. **FACEF Pesquisa-Desenvolvimento e Gestão**, v. 11, n. 1, 2010.
- NARAYAN, Paresh; NARAYAN, Seema; SINGH, Harminder. The Determinants of Stock Prices: New Evidence from the Indian Banking Sector. **Emerging Markets Finance and Trade**, v. 50, p. 5–15, 2014.
- NUGROHO, Mulyanto; HALIK, Abdul; ARIF, Donny. Effect of CAMELS Ratio on Indonesia Banking Share Prices. **The Journal of Asian Finance, Economics and Business**, v. 7, p. 101–106, 2020.

OH, Kyong Joo; KIM, Jay. Analyzing stock market tick data using piecewise nonlinear model. **Expert Systems with Applications**, v. 22, p. 249–255, 2002.

PARANÁ, Edemilson. **A digitalização do mercado de capitais no Brasil: Tendências recentes**. Brasília, 2018. Disponível em: <http://hdl.handle.net/10419/177586>.

PARANÁ, Edemilson. **A finança digitalizada: capitalismo financeiro e revolução informacional**. Florianópolis: Editora Insular, 2016.

PASCANU, Razvan; MIKOLOV, Tomas; BENGIO, Yoshua. On the difficulty of training recurrent neural networks. *In*: DASGUPTA, Sanjoy; MCALLESTER, David (Ed.), 3. **Proceedings of the 30th International Conference on Machine Learning**. Atlanta: PMLR, 2013. v. 28, p. 1310–1318.

PATEL, Mayankkumar B; YALAMALLE, Sunil R. Stock price prediction using artificial neural network. **International Journal of Innovative Research in Science, Engineering and Technology**, v. 3, n. 6, p. 13755–13762, 2014.

PAULI, Suellen Teixeira Zavadzki de; KLEINA, Mariana; BONAT, Wagner Hugo. Comparing Artificial Neural Network Architectures for Brazilian Stock Market Prediction. **Annals of Data Science**, v. 7, n. 4, p. 613–628, 2020.

QUOC TRUNG, Nguyen Kim. Determinants of bank performance in Vietnamese commercial banks: an application of the camels model. **Cogent Business & Management**, v. 8, n. 1, p. 1979443, 2021.

RAMACHANDRAN, Prajit; ZOPH, Barret; LE, Quoc V. Searching for activation functions. **arXiv preprint arXiv:1710.05941**, 2017.

RJOUB, Husam; CIVCIR, Irfan; RESATOGLU, Nil. Micro and macroeconomic determinants of stock prices: The case of Turkish banking sector. **Romanian journal of economic forecasting**, v. 20, p. 17, 2017.

SAGHEER, Alaa; KOTB, Mostafa. Time Series Forecasting of Petroleum Production using Deep LSTM Recurrent Networks. **Neurocomputing**, v. 323, 2018.

SAMARAWICKRAMA, Jayanath; FERNANDO, T.G.I. A Recurrent Neural Network Approach in Predicting Daily Stock Prices: An Application to the Sri Lankan Stock


- Market. *In*: IEEE. INTERNATIONAL Conference on Industrial and Information Systems (ICIIS). Peradeniya: IEEE, 2017.
- SAMUEL, Arthur L. Some studies in machine learning using the game of checkers. **IBM Journal of research and development**, v. 44, n. 1.2, p. 206–226, 2000.
- SANTOS, Gustavo Carvalho; BARBOZA, Flavio; VEIGA, Antônio Cláudio Paschoarelli; SILVA, Mateus Ferreira. Forecasting Brazilian Ethanol Spot Prices Using LSTM. **Energies**, v. 14, n. 23, p. 7987, 2021.
- SHAHZAD, Jawad; AHMAD, Tanveer; ALI, Sajid; ISHAQ, Adeeba. The Determinants of Bank Stock Prices: A Panel Approach. **South Asian Journal of Management Sciences**, v. 11, p. 32–43, 2017.
- SOUZA, João Carlos Félix; SANTOS, Pedro Henrique; MOTA, Patrick Laun Tatagiba. Um estudo de eventos sobre a influência das eleições presidenciais de 2006, 2010 e 2014 sobre as ações dos quatro principais bancos comerciais Brasileiros. **Brazilian Journal Of Business**, v. 1, n. 2, p. 640–658, 2019.
- STIGLITZ, Joseph; WEISS, Andrew. **Banks as Social Accountants and Screening Devices for the Allocation of Credit**. Cambridge, 1988.
- TAVELIN, Gabriel Marques; BRITO, Rafael de Freitas. Análise de Investimentos: Previsão do Preço de 5 Ações do Setor Bancário Brasileiro Utilizando Machine Learning. *In*: ENCONTRO DE GESTÃO E NEGÓCIOS. *Anais...* Uberlândia: UFU/FAGEN, 2021.
- TENSORFLOW. **Keras | TensorFlow Core – tensorflow.org**. [*S.l.*: *s.n.*], 2020. Disponível em: <https://www.tensorflow.org/guide/keras?hl=pt-br>. Acesso em: 27 out. 2023.
- WEN, Yulian; LIN, Peiguang; NIE, Xiushan. Research of Stock Price Prediction Based on PCA-LSTM Model. **IOP Conference Series: Materials Science and Engineering**, v. 790, p. 012109, 2020.
- WERNER, Richard. How do banks create money, and why can other firms not do the same? An explanation for the coexistence of lending and deposit-taking. **International Review of Financial Analysis**, v. 36, p. 71–77, 2014.

WIEDERHOLD, Gio; JAJODIA, Sushil; LITWIN, Witold. Dealing with granularity of time in temporal databases. *In*: ANDERSEN, Rudolf; BUBENKO, Janis A.; SØLVBERG, Arne (Ed.). **Advanced Information Systems Engineering**. Berlin: Springer, 1991. P. 124–140.


WIRNKAR, Alphonsius; TANKO, Muhammad. CAMELs and Banks Performance Evaluation: The Way Forward. **SSRN**, 2008. Disponível em: <http://dx.doi.org/10.2139/ssrn.1150968>. Acesso em: 12 nov. 2023.

ZEIDAN, Rodrigo. Why is bank credit in Brazil the most expensive in the world? **Brazilian Review of Finance**, v. 18, p. 1–22, 2020.


APÊNDICE A – Curvas de Loss




(a) Modelo A (5 dias) - BBAS3




(b) Modelo B (21 dias) - BBAS3




(c) Modelo A (5 dias) - BBDC4




(d) Modelo B (21 dias) - BBDC4




(e) Modelo A (5 dias) - BPAC11




(f) Modelo A (21 dias) - BPAC11




(g) Modelo A (5 dias) - ITUB4



(h) Modelo A (21 dias) - ITUB4



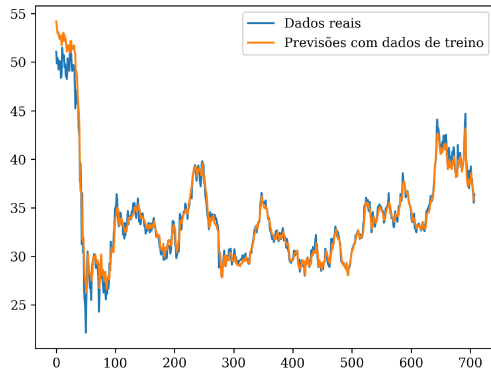
(i) Modelo A (5 dias) - SANB11



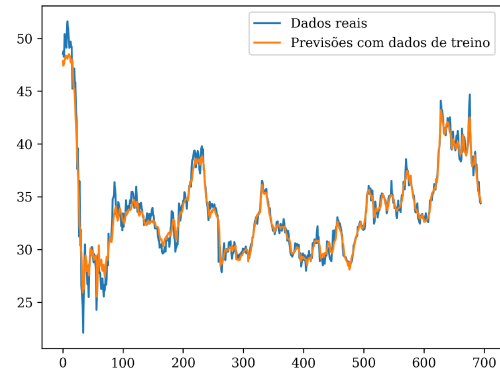
(j) Modelo A (21 dias) - SANB11

Figura A.1 – Conjunto de Figuras

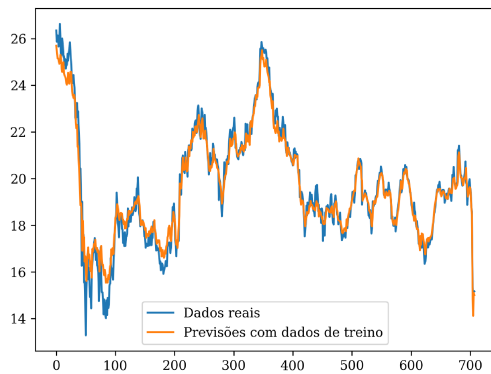
APÊNDICE B – Previsões com dados de treinamento




(a) Modelo A (5 dias) - BBAS3




(b) Modelo B (21 dias) - BBAS3




(c) Modelo A (5 dias) - BBDC4



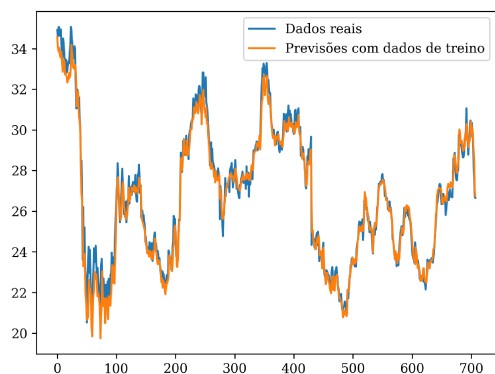
(d) Modelo B (21 dias) - BBDC4




(e) Modelo A (5 dias) - BPAC11



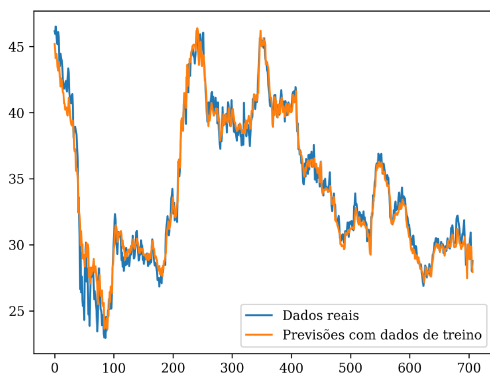
(f) Modelo A (21 dias) - BPAC11




(g) Modelo A (5 dias) - ITUB4



(h) Modelo A (21 dias) - ITUB4




(i) Modelo A (5 dias) - SANB11




(j) Modelo A (21 dias) - SANB11

Figura B.1 – Conjunto de Figuras

APÊNDICE C – Previsões com dados de teste



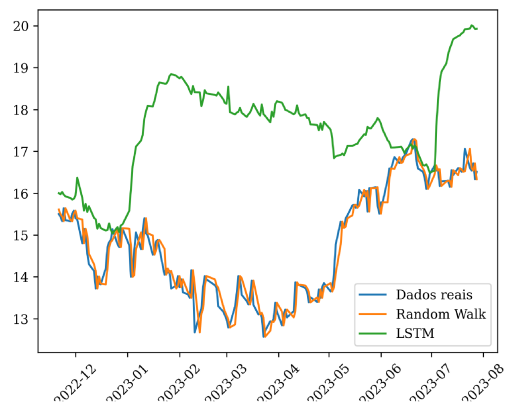
(a) Modelo A (5 dias) - BBAS3



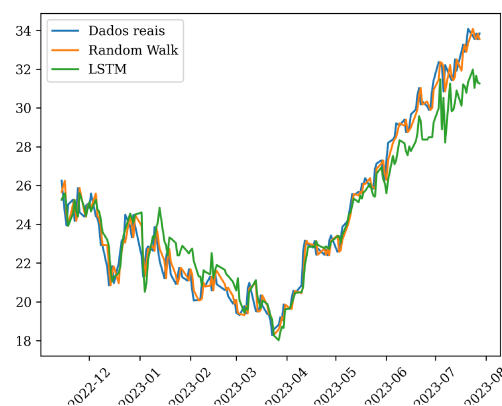
(b) Modelo B (21 dias) - BBAS3




(c) Modelo A (5 dias) - BBDC4




(d) Modelo B (21 dias) - BBDC4




(e) Modelo A (5 dias) - BPAC11



(f) Modelo B (21 dias) - BPAC11




(g) Modelo A (5 dias) - ITUB4



(h) Modelo B (21 dias) - ITUB4



(i) Modelo A (5 dias) - SANB11




(j) Modelo B (21 dias) - SANB11

Figura C.1 – Conjunto de Figuras


APÊNDICE D – Testes Diebold-Mariano

Ativo	Modelo	Diebold-Mariano Test					
		MAE		MAPE		RMSE	
		Estatística	p-valor	Estatística	p-valor	Estatística	p-valor
Banco do Brasil (BBAS3)	LSTM A	-11.06	6.29	-11.09	5.37	-9.09	2.09
	LSTM B	-13.6	4.36	-14.08	1.9	-8.81	1.3
Bradesco (BBDC4)	LSTM A	-24.29	5.97	-22.6	8.32	-16.7	4.52
	LSTM B	-18.62	4.33	-18.88	8.68	-14.31	4.05
BTG Pactual (BPAC11)	LSTM A	-8.69	2.46	-8.76	1.63	-7.18	1.82
	LSTM B	-12.00	1.66	-10.07	4.55	-8.29	3.09
Itaú (ITUB4)	LSTM A	-13.14	6.94	-12.73	1	-11.24	2.03
	LSTM B	-9.93	1.17	-9.7	5.06	-8.86	9.45
Santander (SANB11)	LSTM A	-13.53	5.15	-13.48	7.14	-11.02	8.58
	LSTM B	-14.84	1.28	-14.21	7.84	-11.63	1.88


APÊNDICE E – Previsões realizadas no mês de Novembro




(a) Modelo A (5 dias) - BBAS3




(b) Modelo B (21 dias) - BBAS3




(c) Modelo A (5 dias) - BBDC4




(d) Modelo B (21 dias) - BBDC4




(e) Modelo A (5 dias) - BPAC11




(f) Modelo B (21 dias) - BPAC11




(g) Modelo A (5 dias) - ITUB4



(h) Modelo B (21 dias) - ITUB4



(i) Modelo A (5 dias) - SANB11



(j) Modelo B (21 dias) - SANB11

Figura E.1 – Conjunto de Figuras