

AVALIAÇÃO COMPARATIVA DE MODELOS DE PREVISÃO ETS, ARIMA E LSTM COM PRÉ-PROCESSAMENTO: APLICAÇÃO EM SÉRIES DO IBOVESPA

"COMPARATIVE EVALUATION OF FORECASTING MODELS ETS, ARIMA, AND LSTM WITH PREPROCESSING: APPLICATION TO IBOVESPA TIME SERIES

Nathalia Najla Costa Borges

Bacharel em Ciências Econômicas pelo Instituto de Ensino e Pesquisa (Insper). Mestranda em Pesquisa Operacional pelo Instituto Tecnológico de Aeronáutica (ITA) e pela Universidade Federal de São Paulo (UNIFESP).

nathalia.borges.101588@ga.ita.br

 <https://orcid.org/0009-0009-9759-2420>

Mauri Aparecido de Oliveira

Bacharel em Engenharia Mecânica com ênfase em Mecatrônica pela Universidade de São Paulo (USP). Especialista em Engenharia Automobilística pela Faculdade de Engenharia Industrial (FEI). MBA em Finanças pelo IBMEC/SP. Mestre e Doutor em Administração pela Universidade de São Paulo (USP). Pós-doutor em Estatística Aplicada pela Universidade de São Paulo (USP). Professor do Departamento de Gestão e Apoio à Decisão da Divisão de Engenharia Mecânica do Instituto Tecnológico de Aeronáutica (ITA).

mauri@ita.br

 <https://orcid.org/0000-0001-7172-9518>

DOI: <https://doi.org/10.36942/reni.v11i2.1638>

RESUMO

Este estudo investiga os efeitos de técnicas de suavização no desempenho de modelos estatísticos e de *deep learning* aplicados à previsão de séries financeiras. Foram analisadas as seis ações de maior participação no índice IBOVESPA no período de janeiro de 2023 a

outubro de 2025. Os modelos ARIMA, ETS e Long Short-Term Memory (LSTM) foram avaliados sob três condições de pré-processamento: série original, filtro Savitzky–Golay e Média Móvel. O desempenho foi mensurado por meio das métricas RMSE, MAE, MAPE, sMAPE e da estatística direcional dStat. Os resultados indicaram que o modelo LSTM combinado com a Média Móvel apresentou o melhor desempenho geral, obtendo os menores valores de erro para todas as ações analisadas e redução média de aproximadamente 38% no sMAPE em relação aos modelos estatísticos. Em contrapartida, ARIMA e ETS demonstraram maior robustez à utilização de séries sem pré-processamento. Os resultados sugerem que os benefícios da suavização dependem do paradigma de modelagem adotado, sendo particularmente relevantes para modelos de *deep learning*.

Palavras-chave: Previsão financeira. Séries temporais. LSTM. ARIMA. Savitzky–Golay.

ABSTRACT

This study investigates the effects of smoothing techniques on the performance of statistical and deep learning models applied to financial time series forecasting. The six largest stocks by weight in the IBOVESPA index were analyzed from January 2023 to October 2025. ARIMA, ETS, and Long Short-Term Memory (LSTM) models were evaluated under three preprocessing conditions: original series, Savitzky–Golay filtering, and Moving Average smoothing. Performance was assessed using RMSE, MAE, MAPE, sMAPE, and the directional accuracy metric (dStat). Results showed that the LSTM model combined with Moving Average preprocessing achieved the best overall performance, obtaining the lowest forecasting errors for all analyzed stocks and reducing sMAPE by approximately 38% compared with statistical models. In contrast, ARIMA and ETS demonstrated greater robustness when applied to non-preprocessed data. The findings suggest that the benefits of smoothing techniques depend on the forecasting paradigm and are particularly relevant for deep learning approaches.

Keywords: Financial forecasting. Time series. LSTM. ARIMA. Savitzky–Golay.

JEL Classification: C22 Time-Series Models; C45 Neural Networks; G17= Financial Forecasting and Trading.

1 INTRODUÇÃO

A previsão de séries temporais financeiras permanece como uma tarefa desafiadora devido à elevada volatilidade, não estacionariedade e presença de ruído nos mercados financeiros, características que dificultam a identificação de padrões consistentes e comprometem o desempenho de modelos preditivos, especialmente em horizontes de curto prazo (Giantsidi; Tarantola, 2025; Paiva et al., 2019; Jiang, 2022). Por esse motivo, a previsão de preços de ativos continua sendo um tema amplamente investigado na literatura de forecasting financeiro.

Embora a Hipótese de Mercado Eficiente (Efficient Market Hypothesis – EMH) proponha que os preços dos ativos incorporam rapidamente as informações disponíveis (Fama, 1970), evidências empíricas sugerem a existência de períodos de ineficiência que possibilitam a identificação de padrões exploráveis por modelos preditivos. Essa perspectiva foi ampliada pela Hipótese dos Mercados Adaptativos (Adaptive Market Hypothesis – AMH), segundo a qual os mercados alternam entre estados de maior e menor eficiência em resposta às condições econômicas e ao comportamento dos agentes. Estudos recentes têm encontrado evidências favoráveis à AMH, indicando que a eficiência dos mercados varia ao longo do tempo em função de crises e fatores exógenos (Noreen et al., 2022; Cruz-Hernández; Mora-Valencia, 2024; Santos et al., 2024).

Nesse contexto, modelos estatísticos e técnicas de inteligência artificial têm sido amplamente empregados para previsão financeira. Entre as abordagens de *deep learning*, as redes Long Short-Term Memory (LSTM) destacam-se pela capacidade de modelar relações não lineares e dependências temporais complexas (Pai; Ilango, 2020). Entretanto, o desempenho desses modelos é fortemente influenciado pela qualidade do sinal de entrada, tornando o pré-processamento uma etapa relevante do processo preditivo (Giantsidi; Tarantola, 2025).

Dentre as técnicas de pré-processamento, o filtro Savitzky–Golay (SG) tem recebido crescente atenção em aplicações de aprendizado de máquina voltadas para séries temporais (Bi et al., 2024; Wang et al., 2024). Diferentemente de abordagens mais simples, como a média móvel, o filtro SG realiza ajustes polinomiais locais que permitem suavizar ruídos preservando características importantes do sinal, o que pode favorecer o desempenho preditivo. Evidências recentes sugerem ainda que os benefícios do pré-processamento não se

restringem a modelos neurais, podendo também impactar modelos estatísticos tradicionais (Bi et al., 2024).

Apesar desse interesse crescente, grande parte dos estudos concentra-se na comparação entre arquiteturas de *machine learning* e *deep learning*, frequentemente utilizando modelos ingênuos ou variantes da própria arquitetura como benchmark. Consequentemente, permanece pouco explorado o efeito de técnicas de suavização sobre diferentes paradigmas de previsão, particularmente na comparação entre modelos estatísticos e redes neurais. Considerando que esses métodos utilizam mecanismos distintos para modelagem temporal, é plausível que o pré-processamento produza impactos diferentes em cada abordagem.

Diante dessa lacuna, este estudo investiga os efeitos do filtro Savitzky–Golay e da Média Móvel sobre o desempenho de modelos estatísticos e de *deep learning* aplicados à previsão financeira. Para isso, são comparados os modelos ARIMA, ETS e LSTM na previsão das seis ações de maior participação no índice IBOVESPA, considerando horizonte de cinco dias no período de 2023 a 2025. A relevância da análise reside na possibilidade de compreender como diferentes técnicas de suavização afetam paradigmas distintos de modelagem temporal, fornecendo evidências sobre os benefícios e limitações do pré-processamento em séries financeiras. Além da comparação em termos de acurácia preditiva, busca-se analisar como o tratamento dos dados influencia o comportamento dos modelos diante de séries caracterizadas por ruído, volatilidade e não estacionariedade.

2 REFERENCIAL TEÓRICO

2.1 Previsão financeira e técnicas de suavização

Além da escolha do modelo preditivo, estudos recentes indicam que o desempenho em séries financeiras depende fortemente da qualidade do sinal utilizado como entrada. Em função da elevada presença de ruídos de alta frequência, técnicas de pré-processamento e suavização têm sido amplamente empregadas para melhorar a capacidade preditiva de modelos de *forecasting*.

Diversas abordagens vêm sendo utilizadas para redução de ruído em séries temporais, incluindo o filtro Savitzky–Golay (SG), o estimador de Local de Huber e métodos baseados em

decomposição de sinais, como Wavelet Decomposition, Empirical Mode Decomposition (EMD) e Variational Mode Decomposition (VMD) (Bi et al., 2024; Chaweewanchon; Chaysiri, 2022; Durairai; Mohan, 2022; Wan; Qiu; Li, 2018; Büyükşahin; Ertekin, 2019; Guo et al., 2022; Saikia; Goswami; Kakaty, 2025; Zhang et al., 2024; Rubio et al., 2023; Wang; Lou, 2019; Al Wadi et al., 2011). Entre essas técnicas, o filtro Savitzky–Golay tem recebido crescente atenção por sua capacidade de reduzir ruídos preservando características locais da série, como tendência e curvatura, apresentando resultados promissores em aplicações envolvendo aprendizado de máquina e previsão financeira (Bi et al., 2024; Wang et al., 2024).

Paralelamente, o avanço das técnicas de *machine learning* e *deep learning* impulsionou o desenvolvimento de modelos voltados à previsão de preços de ativos. Estudos envolvendo Support Vector Regression (SVR), Long Short-Term Memory (LSTM), Bidirectional LSTM (BiLSTM), Extreme Learning Machine (ELM) e Redes Neurais Convolucionais (CNN) têm reportado resultados competitivos em diferentes mercados e horizontes de previsão (Paiva et al., 2019; Jiang, 2022; Esa et al., 2024). Apesar disso, ainda não existe consenso acerca de um modelo superior para previsão financeira, o que tem estimulado o desenvolvimento de abordagens híbridas que combinam técnicas de pré-processamento e modelos preditivos (Giantsidi; Tarantola, 2025).

Grande parte desses estudos concentra-se na avaliação de arquiteturas neurais, frequentemente utilizando modelos ingênuos ou variantes da própria arquitetura como benchmark. Wang et al. (2024), por exemplo, combinaram o filtro Savitzky–Golay com uma arquitetura LSTM otimizada por Sparrow Search Algorithm, enquanto Chaweewanchon e Chaysiri (2022) propuseram uma arquitetura CNN-BiLSTM associada ao estimador de Local de Huber. Em ambos os casos, a comparação foi restrita a modelos neurais correlatos, dificultando a avaliação do impacto do pré-processamento em paradigmas distintos de modelagem temporal.

Embora modelos de *deep learning* tenham recebido crescente atenção na literatura, evidências empíricas indicam que métodos estatísticos clássicos permanecem competitivos em diversos cenários de previsão. As competições M3 e M4 demonstraram que modelos como ARIMA e ETS podem apresentar desempenho comparável ou superior ao de abordagens mais complexas, especialmente em horizontes curtos e contextos de menor disponibilidade de dados (Makridakis et al., 2018; 2020; 2022).

Dessa forma, observa-se uma lacuna relacionada à compreensão dos efeitos que

técnicas de suavização exercem sobre diferentes paradigmas de previsão. Enquanto modelos estatísticos dependem explicitamente da estrutura autocorrelacionada da série, arquiteturas neurais aprendem representações diretamente dos dados observados, o que sugere que o pré-processamento pode afetar cada abordagem de maneira distinta. Apesar do crescente uso de técnicas de suavização em modelos neurais, ainda são escassos os estudos que investigam seus impactos comparativamente em modelos estatísticos e de *deep learning* aplicados à previsão financeira.

2.2 Filtro Savitzky-Golay (SG)

O filtro Savitzky–Golay (SG), proposto por Savitzky e Golay (1964), é uma técnica de suavização baseada no ajuste local de polinômios por mínimos quadrados. Diferentemente da Média Móvel Simples, o método busca reduzir ruídos preservando características locais da série, como tendência e curvatura, o que tem motivado sua aplicação em problemas de previsão financeira (BI et al., 2024; WANG et al., 2024).

Matematicamente, o filtro substitui cada observação pelo valor estimado de um polinômio ajustado localmente, conforme apresentado na Equação 01.

$$Y_j^* = \frac{1}{N} \sum_{i=-m}^m C_i Y_{j+i} \quad (01).$$

O desempenho do método depende principalmente da ordem polinomial e do tamanho da janela utilizados no processo de suavização (John; Sadasivan; Seelamantula, 2021).

2.3 Modelos de previsão

2.3.1 ARIMA/SARIMA

O modelo Autorregressivo Integrado de Médias Móveis (ARIMA) combina componentes autorregressivos, diferenciação e médias móveis para modelar dependências temporais em séries não estacionárias (Box; Jenkins, 2016). Sua formulação geral é apresentada na Equação 02.

$$\phi(B)(1-B)^d z_t = \theta(B)a_t \quad (02).$$

Em que $\phi(B)$ representa o polinômio autorregressivo, $\theta(B)$ o polinômio de médias

móveis, $(1 - B)^d$ o operador de diferenciação de ordem d e a_t o termo de erro aleatório.

Quando a série apresenta comportamento sazonal, utiliza-se a extensão SARIMA, representada por $ARIMA(p,d,q)(P,D,Q)_s$, que incorpora componentes específicos para modelar esse comportamento. A adequação do ajuste pode ser avaliada por meio da análise residual e de testes de autocorrelação, como o teste de Ljung–Box.

Neste estudo, o ARIMA é particularmente relevante por depender diretamente da estrutura autocorrelacionada da série temporal. Dessa forma, alterações promovidas por técnicas de suavização podem influenciar os padrões utilizados pelo modelo durante o processo de previsão.

2.3.2 ETS (Erro, Tendência, Sazonalidade)

Os modelos ETS (Error, Trend, Seasonal) constituem uma classe de métodos de suavização exponencial formulados em espaço de estados, nos quais a série temporal é representada por componentes de nível, tendência e sazonalidade (Hyndman; Athanasopoulos, 2018). Dependendo das características da série, cada componente pode assumir estrutura aditiva (A), multiplicativa (M) ou estar ausente (N). Em sua forma aditiva simplificada, o modelo pode ser representado pela Equação 03.

$$y_t = l_{t-1} + b_{t-1} + s_{t-m} + \varepsilon_t \quad (03).$$

Em que l_t , b_t e s_t representam, respectivamente, os componentes de nível, tendência e sazonalidade, enquanto ε_t corresponde ao termo de erro aleatório.

Diferentemente dos modelos ARIMA, os modelos ETS incorporam mecanismos internos de suavização durante o processo de estimação, permitindo sua aplicação em séries não estacionárias sem a necessidade de diferenciação prévia. Dessa forma, a aplicação de filtros externos pode influenciar os componentes estimados e, conseqüentemente, o desempenho preditivo do modelo.

2.3.3 LSTM (Long Short-Term Memory)

A arquitetura Long Short-Term Memory (LSTM) consiste em uma variante das Redes Neurais Recorrentes (Recurrent Neural Networks – RNN) desenvolvida para modelar dependências temporais em dados sequenciais (Hochreiter; Schmidhuber, 1997). Diferentemente das RNN tradicionais, as LSTM incorporam mecanismos de memória capazes de mitigar problemas de desaparecimento e explosão do gradiente, favorecendo a

aprendizagem de dependências de longo prazo.

As arquiteturas LSTM têm sido amplamente empregadas em problemas de previsão financeira devido à sua capacidade de modelar relações não lineares e padrões temporais complexos presentes nos dados (Pai; Ilango, 2020). Entretanto, o desempenho dessas redes depende fortemente da qualidade do sinal de entrada, tornando o pré-processamento uma etapa relevante do processo de modelagem. Nesse contexto, técnicas de suavização podem contribuir para a redução de ruídos e para a melhoria da relação sinal-ruído dos dados, favorecendo a identificação de padrões temporais relevantes para a previsão.

3 METODOLOGIA

A abordagem metodológica deste estudo seguiu um fluxo de trabalho estruturado em quatro etapas principais: coleta de dados; pré-processamento; modelagem; avaliação de desempenho.

3.1 Coleta e seleção de dados

A base de dados compreende os preços de fechamento diário das seis ações com maior peso no índice IBOVESPA: PETR4, VALE3, ITUB4, PETR3, BBDC4, SBSP3 por meio da plataforma Yahoo Finance. O período de análise abrange de 01/01/2023 a 30/10/2025. A escolha destes ativos justifica-se por sua alta liquidez e representatividade no mercado financeiro brasileiro.

Tabela 01 – Estatísticas descritivas dos retornos logarítmicos

Ativo	Média	Volatilidade	Assimetria	Curtose	Mínimo	Máximo
BBDC4	0,0001	0,3075	-0,4517	5,1486	-0,0854	0,0510
ITUB4	0,0007	0,2438	0,6017	5,6049	-0,0395	0,0794
PETR3	0,0032	0,3343	-0,0002	3,3499	-0,0579	0,0680
PETR4	0,0036	0,3255	-0,0619	3,1143	-0,0533	0,0597
SBSP3	0,0007	0,2841	0,3986	4,0077	-0,0422	0,0701
VALE3	-0,0015	0,2745	0,3011	3,6808	-0,0473	0,0569

Fonte: Elaboração própria com base em dados do Yahoo Finance.

A Tabela 01 apresenta as estatísticas descritivas dos retornos logarítmicos das ações analisadas. Observa-se heterogeneidade entre os ativos em termos de retorno, volatilidade, assimetria e curtose, evidenciando diferentes perfis de risco e distribuição dos retornos. Além disso, os valores de assimetria e curtose indicam a presença de distribuições não normais e

ocorrência de eventos extremos em diferentes intensidades ao longo da amostra. Destacam-se as ações da Petrobras (PETR3 e PETR4) apresentaram os maiores retornos médios e também os maiores níveis de volatilidade, enquanto ITUB4 registrou a menor volatilidade entre os ativos analisados.

3.2 Delineamento experimental

As séries foram avaliadas em três condições: sem pré-processamento, com aplicação do filtro Savitzky–Golay (SG) e com aplicação da Média Móvel (MA).

A modelagem foi realizada por meio dos modelos ARIMA/SARIMA, ETS e LSTM. Para os modelos estatísticos, as séries foram transformadas para escala logarítmica e submetidas aos procedimentos de estacionarização quando necessário. Para o LSTM, utilizou-se normalização Min-Max e janelas deslizantes de cinco observações para previsão do próximo valor.

O desempenho dos modelos foi avaliado por métricas de erro e eficácia direcional, permitindo analisar simultaneamente os efeitos do pré-processamento e da abordagem de modelagem sobre a qualidade das previsões.

3.3 Configuração dos modelos

Para os modelos ARIMA e SARIMA, a seleção das ordens foi realizada por busca exaustiva, considerando simultaneamente a minimização do Critério de Informação de Akaike (AIC), a significância estatística dos parâmetros e a adequação dos resíduos. As combinações avaliadas são apresentadas na Tabela 02.

Tabela 02 – Ordens dos modelos ARIMA e SARIMA

Modelo	Parâmetro p	Parâmetro d	Parâmetro q	Ordem Sazonal (P,D,Q) s
ARIMA	{0,1,2,3}	1	{0,1,2,3}	N/A
SARIMA	{0,1,2}	1	{0,1,2}	(1,0,1)

Fonte: Elaboração própria.

A estrutura ETS foi selecionada automaticamente por meio da função *ets()* do pacote *forecast*, adotando-se a especificação com menor valor de AIC.

Para o modelo LSTM, foi utilizada uma arquitetura composta por duas camadas recorrentes, conforme Wang et al. (2024). As combinações de hiperparâmetros avaliadas são apresentadas na Tabela 03.

Tabela 03 – Configurações de hiperparâmetros do LSTM

Configuração	Camada 1 (h1)	Camada 2 (h2)	Dropout (dr)	Batch Size (bs)
C1	64	32	0,1	16
C2	80	50	0,05	8
C3	100	70	0,01	4
C4	107	79	0.001	3

Fonte: Elaboração própria.

Para o filtro Savitzky–Golay foram avaliadas duas configurações. A primeira utilizou janela de cinco observações e polinômio de segunda ordem, seguindo Wang et al. (2024). A segunda utilizou janela de três observações e polinômio de primeiro grau. Nessa configuração específica, o filtro torna-se equivalente à Média Móvel Simples quando o ponto central da janela é utilizado como referência, permitindo uma comparação direta entre as duas abordagens de suavização.

3.4 Critérios de avaliação e pontuação

O desempenho foi mensurado por um conjunto de métricas de erro e eficácia direcional. Para análise de erro utilizaram-se as métricas Raiz do Erro Quadrático Médio, Erro Médio Absoluto, Erro Percentual Absoluto Médio e Erro Percentual Absoluto Médio Simétrico. Enquanto a eficácia direcional foi calculada através da métrica dStat calculada pela porcentagem de acertos do sentido de variação do preço de ativo.

Para a avaliação da eficácia direcional (dStat) no horizonte de previsão de cinco dias, o procedimento considerou os pares de variação entre os períodos consecutivos da janela ($t + 1$ a $t + 5$). Dessa forma, para cada janela de dados, a métrica computou o percentual de acertos da direção do movimento do preço com base em 4 observações efetivas por horizonte de previsão. Esse procedimento justifica a variação dos valores obtidos em incrementos de 25%, permitindo dimensionar a proporção de acertos direcionais calculada para cada ativo.

4 RESULTADOS

Nesta seção são apresentados e discutidos os resultados obtidos pelos modelos de previsão aplicados aos ativos de maior participação no IBOVESPA, com foco nos efeitos das técnicas de suavização e no desempenho relativo das abordagens ARIMA, ETS e LSTM.

Iniciando à análise, a Tabela 04 apresenta os resultados da métrica dStat para os

modelos ARIMA, ETS e LSTM sob diferentes condições de pré-processamento. A comparação permite avaliar o impacto dos filtros Savitzky–Golay e Média Móvel sobre a capacidade dos modelos em prever corretamente a direção de variação dos preços dos ativos analisados.

Tabela 04 – Comparação da métrica dStat entre modelos e técnicas de pré-processamento

Modelo	Método	BBDC4	ITUB4	PETR3	PETR4	SBSP3	VALE3
ARIMA	MA	0%	0%	25%	50%	75%	25%
	Original	50%	50%	25%	25%	25%	50%
	SG	50%	0%	75%	75%	100%	25%
ETS	MA	0%	75%	50%	50%	25%	50%
	Original	50%	100%	50%	25%	25%	75%
	SG	0%	75%	50%	50%	25%	50%
LSTM	MA	75%	75%	25%	50%	50%	50%
	Original	100%	75%	25%	0%	50%	75%
	SG	75%	75%	25%	50%	50%	50%

Fonte: Elaboração própria com base em dados do Yahoo Finance

As Tabelas 05, 06 e 07 apresentam os modelos de melhor desempenho para cada abordagem analisada, possibilitando avaliar individualmente os efeitos das técnicas de pré-processamento sobre os ativos estudados.

Conforme apresentado na Tabela 05, três das seis ações analisadas obtiveram melhor desempenho com modelos ARIMA associados a técnicas de pré-processamento, sendo duas delas relacionadas à aplicação da Média Móvel.

Tabela 05 – Desempenho dos melhores modelos ARIMA por ativo

Ativo	Método	Ordem	RMSE	MAE	MAPE	sMAPE	dStat
BBDC4	Original	ARIMA(1,1,1)	0,5333	0,4519	2,5581	2,6039	50%
ITUB4	SG	ARIMA(0,1,3)	0,4824	0,3470	0,9830	0,9910	0%
PETR3	MA	ARIMA(0,1,2)	0,1047	0,0956	0,3123	0,3124	25%
PETR4	MA	ARIMA(0,1,2)(1,0,1)[5]	0,1303	0,0866	0,3010	0,3017	50%
SBSP3	Original	ARIMA(0,1,0)	0,2705	0,2153	0,8599	0,8658	25%
VALE3	Original	ARIMA(0,1,0)(1,0,1)[5]	0,7277	0,4801	0,8041	0,8111	50%

Fonte: Elaboração própria com base em dados do Yahoo Finance

Entretanto, ao considerar a métrica de direcionalidade (dStat), apresentada na Tabela 04, a aplicação da Média Móvel não produziu o melhor resultado em nenhuma das ações analisadas. Nesse critério, o filtro Savitzky–Golay destacou-se ao apresentar os maiores valores de dStat em quatro dos seis ativos. A série original também apresentou desempenho competitivo, alcançando os melhores resultados em três ações, empatando com o filtro SG em uma delas.

Apesar dos ganhos observados em determinados ativos, não foi possível identificar um padrão consistente entre o desempenho do pré-processamento e as características estatísticas das séries. Embora a série original tenha apresentado melhores resultados para três ativos, as diferenças observadas em termos de volatilidade, assimetria e curtose sugerem que o impacto da suavização depende da estrutura específica de cada série, dificultando a identificação de um comportamento generalizável.

A Tabela 06 apresenta os melhores resultados obtidos pelo modelo ETS. Observa-se que, com exceção de ITUB4, em que as versões com Savitzky–Golay e Média Móvel apresentaram desempenho semelhante, a série original sem pré-processamento obteve os melhores resultados para todos os demais ativos analisados. Esse comportamento também é observado na Tabela 04, que evidencia a competitividade da série original tanto nas métricas de erro quanto na medida dStat. Os resultados sugerem que técnicas adicionais de suavização não produzem ganhos consistentes para o ETS, possivelmente porque o modelo já incorpora mecanismos próprios de suavização durante a estimação.

Tabela 06 – Desempenho dos melhores modelos ETS por ativo

Ativo	Método	Ordem	RMSE	MAE	MAPE	sMAPE	dStat
BBDC4	Original	ETS(A,N,N)	0,5524	0,4735	2,6349	2,6823	50%
ITUB4	MA	ETS(A,Ad,N)	0,5154	0,3345	0,9358	0,9462	75%
ITUB4	SG	ETS(M,N,N)	0,6345	0,4422	0,7415	0,7466	75%
PETR3	Original	ETS(M,A,N)	0,1274	0,1108	0,3572	0,3579	50%
PETR4	Original	ETS(A,N,N)	0,1974	0,1660	0,5692	0,5715	25%
SBSP3	Original	ETS(M,A,N)	1,5688	1,3268	1,0531	1,0609	25%
VALE3	Original	ETS(A,Ad,N)	0,5154	0,3345	0,9358	0,9462	75%

Fonte: Elaboração própria com base em dados do Yahoo Finance

Por fim, os resultados do modelo LSTM são apresentados na Tabela 07. Observa-se que a aplicação da Média Móvel produziu os melhores resultados para todas as ações analisadas e em todas as métricas de erro consideradas, evidenciando o impacto positivo do pré-processamento sobre o desempenho preditivo da rede neural.

Tabela 07 – Desempenho dos melhores modelos LSTM por ativo

Ativo	Método	RMSE	MAE	MAPE	sMAPE	dStat
BBDC4	MA	0,2757	0,2574	1,4467	1,4588	75%
ITUB4	MA	0,2160	0,1986	0,5638	0,5651	75%
PETR3	MA	0,0989	0,0824	0,2660	0,2655	25%
PETR4	MA	0,0701	0,0598	0,2057	0,2056	50%
SBSP3	MA	1,2855	1,0514	0,8386	0,8439	50%
VALE3	MA	0,2078	0,1692	0,2871	0,2873	50%

Fonte: Elaboração própria com base em dados do Yahoo Finance

Entretanto, quando analisada a métrica de direcionalidade (dStat), apresentada na Tabela 04, a superioridade da Média Móvel torna-se menos evidente. Em alguns ativos, a série original apresentou desempenho equivalente ou superior, enquanto nos demais casos observou-se empate entre as abordagens. Esses resultados indicam que o impacto da suavização sobre a capacidade de previsão direcional depende da estrutura específica de cada ativo, não sendo possível identificar um padrão consistente associado às características estatísticas das séries. Ainda assim, o LSTM apresentou taxas de acerto superiores a 50% em cinco das seis ações analisadas, sendo PETR3 a única exceção.

Tabela 08 – Medidas de performance para os melhores modelos de cada ação

Ativo	Método	RMSE	MAE	MAPE	sMAPE	dStat	Total Pontos
BBDC4	LSTM MA	0,2757	0,2574	1,4467	1,4588	75%	5
ITUB4	LSTM MA	0,2160	0,1986	0,5638	0,5651	75%	5
PETR3	LSTM MA	0,0989	0,0824	0,2660	0,2655	25%	4
PETR4	LSTM MA	0,0701	0,0598	0,2057	0,2056	50%	5
SBSP3	LSTM MA	1,2855	1,0514	0,8386	0,8439	50%	3
VALE3	LSTM MA	0,2078	0,1692	0,2871	0,2873	50%	4

Fonte: Elaboração própria com base em dados do Yahoo Finance

A Tabela 08 consolida os modelos de melhor desempenho para cada ativo analisado. Observa-se que o LSTM combinado com a Média Móvel (LSTM+MA) apresentou o melhor desempenho geral, obtendo as melhores métricas em todas as ações analisadas. Em três delas, essa abordagem alcançou a pontuação máxima, enquanto nos três casos restantes a perda de desempenho ocorreu na métrica dStat para a ação PETR3 e VALE3, e nas métricas RMSE e MAE para a ação SBSP3, em que modelos ARIMA apresentaram resultados superiores.


Cabe ressaltar, contudo, que a superioridade observada para a combinação LSTM+MA vincula-se estritamente às métricas de magnitude do erro (RMSE, MAE, MAPE e sMAPE), em que a suavização do sinal favoreceu a convergência da rede neural. No que tange à eficácia direcional (dStat), os resultados não sustentam a dominância de qualquer uma das abordagens testadas.

Ao analisar especificamente a capacidade de identificação da tendência, representada pela Tabela 04, verifica-se que nenhuma abordagem atingiu desempenho consistentemente superior. Os casos em que o dStat alcançou 100% distribuíram-se entre diferentes modelos e estratégias de pré-processamento, indicando que a capacidade de previsão direcional depende fortemente das características individuais de cada série. Esses resultados sugerem que não existe uma relação clara de superioridade entre métodos quando considerada exclusivamente a métrica dStat.

Por outro lado, quando analisadas as métricas de erro, observa-se uma superioridade consistente do LSTM associado à Média Móvel. Conforme ilustrado na Figura 01, essa abordagem apresentou os menores valores de sMAPE para todos os ativos, alcançando uma redução média de aproximadamente 38% em relação aos modelos estatísticos. Em contraste, os melhores resultados obtidos por ARIMA e ETS mostraram desempenho semelhante entre si.

BBDC4 apresentou os maiores valores de sMAPE entre os ativos analisados. Esse resultado pode estar associado à presença de movimentos extremos na série, evidenciada pela elevada curtose e pela ocorrência da maior desvalorização diária observada no período. Ainda assim, o LSTM+MA manteve desempenho superior, alcançando dStat de 75%, frente aos 50% obtidos pelos modelos ARIMA e ETS, sugerindo maior robustez da abordagem em cenários mais adversos.

Figura 01 – sMAPE para os modelos vencedores de cada método



Fonte: Elaboração própria com base em dados do Yahoo Finance.

A Tabela 09 permite avaliar o impacto das técnicas de suavização sobre cada família de modelos.

Tabela 09 – Impacto das técnicas de pré-processamento sobre o sMAPE

Modelo	Método	BBDC4	ITUB4	PETR3	PETR4	SBSP3	VALE3
ARIMA	MA	3.1635	1.0028	0.3124	0.3017	1.3415	1.0273
	Original	2.6039	1.0219	0.4857	0.4768	0.8658	0.8111
	SG	2.9608	0.9910	0.4825	0.6936	1.1115	1.1723
ETS	MA	4.0095	0.9462	0.3955	0.7090	1.2758	1.7864
	Original	2.6823	0.9911	0.3579	0.5715	1.0609	0.7466
	SG	4.0094	0.9462	0.3955	0.7090	1.2758	1.7864
LSTM	MA	1.4588	0.5651	0.2655	0.2056	0.8439	0.2873
	Original	5.0318	1.0339	0.5121	0.6500	1.8550	0.9761
	SG	3.0379	0.6257	0.3127	0.4430	1.1987	0.6884

Fonte: Elaboração própria com base em dados do Yahoo Finance.

Observa-se que a Média Móvel proporcionou os menores valores de sMAPE para o

LSTM em todas as ações analisadas. Em contrapartida, a série original apresentou os melhores resultados na maior parte dos casos para ARIMA e ETS, enquanto os filtros Savitzky–Golay e Média Móvel produziram efeitos semelhantes nesses modelos. Esses resultados indicam que o desempenho do LSTM é mais sensível ao pré-processamento, ao passo que ARIMA e ETS apresentaram maior estabilidade frente aos diferentes tratamentos dos dados.

5 CONCLUSÃO E TRABALHOS FUTUROS

A presente pesquisa teve como objetivo comparar, em condições similares, modelos estatísticos clássicos e de *deep learning* para previsão de séries financeiras. Os resultados evidenciaram desempenho superior do modelo LSTM quando combinado com o filtro de Média Móvel (MA), apresentando redução média de aproximadamente 38% no sMAPE em relação aos melhores resultados obtidos pelos modelos estatísticos.

Entretanto, observou-se uma forte dependência do modelo de *deep learning* em relação às técnicas de suavização, uma vez que a versão sem pré-processamento apresentou o pior desempenho em sMAPE para quatro das seis ações analisadas quando comparado a todos os métodos e modelos. Em contrapartida, os modelos ARIMA e ETS demonstraram maior resiliência à utilização de dados não tratados. Esse comportamento sugere que, por modelarem explicitamente a estrutura temporal e parte do ruído presente na série, a remoção prévia de componentes do sinal pode reduzir informações relevantes para o processo de previsão.

No que se refere à previsão de direcionalidade (dStat), não foi identificada uma relação clara entre o desempenho dos modelos e a capacidade de prever movimentos de alta ou baixa dos ativos. Nenhuma das abordagens apresentou dominância consistente nesse critério. Ainda assim, o LSTM associado à Média Móvel demonstrou maior robustez em cenários adversos, como observado para o ativo BBDC4.

Como continuidade desta pesquisa, sugere-se expandir a análise para a totalidade das ações componentes do índice IBOVESPA e avaliar horizontes de previsão mais longos, bem como comparar outras abordagens de *machine learning*. Adicionalmente, a otimização dos parâmetros do filtro Savitzky–Golay, conforme proposto por John, Sadasivan e Seelamantula (2021), pode contribuir para a obtenção de resultados superiores. Por fim, recomenda-se

investigar a integração das previsões com modelos de otimização de portfólio, comparando abordagens de Média-Variância e Média-CVaR, de modo a avaliar o valor econômico das previsões em ambientes reais de investimento e verificar possíveis diferenças de sinergia entre métodos estatísticos e modelos de *machine learning*.

6 REFERÊNCIAS

- AL WADI, S.; ISMAIL, Mohd Tahir; ALKHAHAZALEH, M. H.; KARIM, Samsul Ariffin Abdul. Selecting Wavelet Transforms Model in Forecasting Financial Time Series Data Based on ARIMA Model. **Applied Mathematical Sciences**, v. 5, n. 7, p. 315-326, 2011.
- BI, Jing et al. ARIMA-Based and Multiapplication Workload Prediction With Wavelet Decomposition and Savitzky–Golay Filter in Clouds. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, 2024.
- BROWNLEE, Jason. Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python. Ed. v1.4. [S.l.]: [s.n.], 2018.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time series analysis: forecasting and control**. 5. ed. Hoboken: John Wiley & Sons, 2016.
- BÜYÜKŞAHİN, Ümit Çavuş; ERTEKİN, Şeyda. Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition. **Neurocomputing**, v. 361, 2019.
- CHAWEEWANCHON, Apichat; CHAYSIRI, Rujira. Markowitz Mean-Variance Portfolio Optimization with Predictive Stock Selection Using Machine Learning. **International Journal of Financial Studies**, v. 10, n. 3, art. 64, 2022.
- CRUZ-HERNÁNDEZ, Andrés R.; MORA-VALENCIA, Andrés. Adaptive Market Hypothesis and Predictability: Evidence in Latin American Stock Indices. *Latin American Research Review*, v. 59, p. 292-314, 2024.
- DURAIRAJ, M.; MOHAN, B. H. Krishna. A convolutional neural network based approach to financial time series prediction. **Neural Computing and Applications**, v. 34, p. 13319–13337, mar. 2022.
- ESA, Hammed; RAHMAN, Mohammad Anisur; MOZUMDER, Md Abu Sufian; GURUNG, Nisha; MIAH, Mohammed Nazmul Islam; SWEET, Md Murshid Reja; SHARIF, Mohammad Kawsur; ISLAM, Md Rasibul; NASIRUDDIN, Md; SABUI, Md Sanowar Hossain. Transformative Impact of Deep Learning in Stock Market Decision-Making: A Comparative Study of Convolutional Neural Networks. **Journal of Business and Management Studies**, v. 6, n. 3, p. 28-34, maio 2024.
- FAMA, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. **The Journal of Finance**, v. 25, n. 2, p. 383-417, 1970.
- GIANTSIDI, Sofia; TARANTOLA, Claudia. Deep learning for financial forecasting: A review of recent trends. **International Review of Economics and Finance**, v. 104, p. 104719, 2025.
- GUO, Wei; LIU, Qingfu; LUO, Zhidan; TSE, Yiuman. Forecasts for international financial series

with VMD algorithms. **Journal of Asian Economics**, v. 80, p. 101458, 2022

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural Computation**, v. 9, n. 8, p. 1735-1780, 1997

HYNDMAN, R. J.; ATHANASOPOULOS, G. Forecasting: Principles and Practice. 2ª ed. Monash University, Austrália: OTexts, 2018.

HYNDMAN, Rob J.; KOEHLER, Anne B.; ORD, J. Keith; SNYDER, Ralph D. Forecasting with Exponential Smoothing: The State Space Approach. New York: Springer, 2008.

JIANG, Y. Application and Comparison of Multiple Machine Learning Models in Finance. **Scientific Programming**, v. 2022, 2022.

JOHN, Arlene; SADASIVAN, Jishnu; SEELAMANTULA, Chandra Sekhar. Adaptive Savitzky-Golay Filtering in Non-Gaussian Noise. **IEEE Transactions on Signal Processing**, v.69, 2021.

LIMA, L. A. de O. Auge e declínio da hipótese dos mercados eficientes. **Brazilian Journal of Political Economy**, v. 23, n. 4, p. 531-546, out./dez. 2003.

LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, n. 2, p. 297-303, ago. 1978.

LO, Andrew W. The Adaptive Markets Hypothesis: market efficiency from an evolutionary perspective. **The Journal of Portfolio Management**, Edição Especial (30th Anniversary Issue), p. 15-29, 2004.

MAKRIDAKIS, S., SPILIOTIS, E., ASSIMAKOPOULOS, V. Statistical and Machine Learning forecasting methods: Concerns and ways forward. **PLOS ONE**, v. 13, n. 3, e0194889, 2018.

MAKRIDAKIS, S.; SPILIOTIS, E.; ASSIMAKOPOULOS, V. The M4 Competition: 100,000 time series and 61 forecasting methods. **International Journal of Forecasting**, v. 36, p. 54–74, 2020.

MAKRIDAKIS, S.; SPILIOTIS, E.; ASSIMAKOPOULOS, V.; SEMENOGLU, A.-A.; MULDER, G.; NIKOLOPOULOS, K. Statistical, machine learning and deep learning forecasting methods: Comparisons and ways forward. **Journal of the Operational Research Society**, v. 73, n. 9, 2022.

MORETTIN, P. A.; TOLOI, C. M. de C. Análise de séries temporais. 2ª ed. São Paulo: Edgar Blücher, 2006.

NOREEN, Umara; SHAFIQUE, Attayah; AYUB, Usman; SAEED, Syed Kashif. Does the Adaptive Market Hypothesis Reconcile the Behavioral Finance and the Efficient Market Hypothesis?. **Risks**, v. 10, n. 9, p. 168, 2022.

PAI, N.; ILANGO, V. A Comparative Study on Machine Learning Techniques in Assessment of Financial Portfolios. In: INTERNATIONAL CONFERENCE ON COMMUNICATION AND ELECTRONICS SYSTEMS (ICCES), 5., 2020, Coimbatore. Proceedings [...]. IEEE, 2020. p. 876 882. ISBN 978-1-7281-5371-1.

PAIVA, F. D.; CARDOSO, R. T. N.; HANAOKA, G. P.; DUARTE, W. M. Decision Making for Financial Trading: A Fusion Approach of Machine Learning and Portfolio Selection. **Expert Systems with Applications**, v. 115, p. 635-655, 2019.

PRAKHAR, Kumar; SOUNTHARRAJAN, S.; KUMAR, B. Sathis; SUGANYA, E.; KARTHIGA, M. Effective Stock Price Prediction using Time Series Forecasting. In: INTERNATIONAL CONFERENCE ON TRENDS IN ELECTRONICS AND INFORMATICS (ICOEI 2022), 6., 2022, Sehore, Índia. Anais [...]. IEEE, 2022.

RUBIO, Lihki; PALACIO PINEDO, Adriana; MEJÍA CASTAÑO, Adriana; RAMOS, Filipe. Forecasting volatility by using wavelet transform, ARIMA and GARCH models. **Eurasian Economic Review**, v. 13, p. 803-830, 2023.

SAIKIA, Junmoni; GOSWAMI, Kuldeep; KAKATY, Sarat C. Wavelet-SARIMA-Transformer: A Hybrid Model for Rainfall Forecasting. **Department of Statistics, Dibrugarh University**, Assam, India, 2025.

SANTOS, Marco Aurélio dos; FÁVERO, Luiz Paulo Lopes; BRUGNI, Talles Vianna; SERRA, Ricardo Goulart. Adaptive markets hypothesis and economic-institutional environment: a cross-country analysis. **Revista de Gestão**, v. 31, n. 2, p. 215-236, 2024.

SARVESWARARAO, V.; RAVI, V.; VIVEK, Y. ATM cash demand forecasting in an Indian bank with chaos and hybrid deep learning networks. **Expert Systems With Applications**, v. 211, p. 118645, 2023.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and differentiation of data by simplified least squares procedures. **Analytical Chemistry**, v. 36, n. 8, p. 1627–1639, jul. 1964.

SHUMWAY, R. H.; STOFFER, D. S. Time Series Analysis and Its Applications: With R Examples. 2ª ed. New York: Springer, 2006.

ZHANG, Junting; LIU, Haifei; BAI, Wei; LI, Xiaojing. A hybrid approach of wavelet transform, ARIMA and LSTM model for the share price index futures forecasting. **North American Journal of Economics and Finance**, v. 69, p. 102022, 2024.

WANG, C-H.; ZENG, Y.; YUAN, J. Two-Stage Stock Portfolio Optimization Based on AI-Powered Price Prediction and Mean-CVaR Models. **Expert Systems with Applications**, v. 255, p. 124555, 2024.

WANG, Zheng; LOU, Yuansheng. Hydrological time series forecast model based on wavelet de-noising and ARIMA-LSTM. In: **IEEE INFORMATION TECHNOLOGY, NETWORKING, ELECTRONIC AND AUTOMATION CONTROL CONFERENCE (ITNEC)**, 3., 2019.

WANG, Zhi-Yu; QIU, Jun; LI, Fang-Fang. Hybrid Models Combining EMD/EEMD and ARIMA for Long-Term Streamflow Forecasting. **Water**, v. 10, n. 7, p. 853, 2018.