



II CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

Modelos de Séries Temporais para Ouro Futuro: Comparação entre ARIMAX e LSTM

Luan Cizeski de Lorenzi

Programa de Pós Graduação em Engenharia de Produção e Sistemas - UTFPR Pato Branco

Matheus Henrique Dal Molin Ribeiro

Departamento de Matemática (DAMAT) - UTFPR Pato Branco

José Donizetti de Lima

Departamento de Matemática (DAMAT) - UTFPR Pato Branco

Resumo: Este estudo compara a eficácia dos modelos ARIMAX e LSTM na previsão dos preços do ouro futuro, incorporando o Índice de Risco Geopolítico (Geopolitical Risk Index – GPR) como variável exógena. Utilizando dados mensais entre janeiro de 2005 a junho de 2025, esse trabalho analisa a influência de eventos geopolíticos relevantes sobre a dinâmica do mercado de compra e venda de ouro. O modelo ARIMAX tem capacidade de capturar padrões lineares e efeitos de curto prazo com elevada interpretação estatística, enquanto o LSTM, baseado em redes neurais recorrentes, é eficaz na identificação de relações não lineares e dependências de longo prazo, típicas de mercados financeiros voláteis. Os resultados indicam desempenho superior do ARIMAX, com menores erros preditivos (RMSE e MAE), R^2 mais elevado e projeções de 3.383,49; 3.442,05 e 3.500,28 USD/oz para junho, julho e agosto de 2025. Em contraste, o LSTM apresentou previsões mais conservadoras e estáveis, estimando 2.899,57; 2.926,22 e 2.921,04 USD/oz nos mesmos meses, com maior robustez em relação a oscilações abruptas, embora com menor aderência ao comportamento histórico recente. A escolha do modelo ideal depende do perfil de risco do analista e do horizonte de previsão desejado, recomendando a adoção de modelos híbridos que combinem a capacidade explicativa dos métodos estatísticos com a flexibilidade dos algoritmos de aprendizado profundo, além da incorporação de variáveis macroeconômicas adicionais, a fim de ampliar a acurácia e a robustez das previsões.

Palavras-chave: Ouro, Séries temporais, *Geopolitical Risk Index*, ARIMAX, LSTM.

Time Series Models for Gold Futures: A Comparison between ARIMAX and LSTM

Abstract: This study compares the effectiveness of ARIMAX and LSTM models in forecasting gold futures prices, incorporating the Geopolitical Risk Index (GPR) as an exogenous variable. Using monthly data from January 2005 to June 2025, this work analyzes the influence of major geopolitical events on the dynamics of the gold market. The ARIMAX model demonstrates the ability to capture linear patterns and short-term effects with high statistical interpretability, while the LSTM model, based on recurrent neural networks, proves effective in identifying nonlinear relationships and long-term dependencies, which are typical of volatile financial markets. The results indicate superior performance of ARIMAX, with lower predictive errors (RMSE and MAE), higher R^2 values, and forecasts of 3,383.49; 3,442.05; and 3,500.28 USD/oz for June, July, and August 2025. In contrast, the LSTM presented more conservative and stable predictions, estimating 2,899.57; 2,926.22 and 2,921.04 USD/oz in the same months, with greater robustness in relation to abrupt oscillations, although with lower adherence to recent historical behavior. The choice of the ideal model depends on the analyst's risk profile and the desired forecast horizon, recommending the adoption of hybrid models that combine the explanatory capacity of statistical methods with the flexibility of deep learning algorithms, in addition to the incorporation of additional macroeconomic variables, in order to expand the accuracy and robustness of the predictions.

August 2025. In contrast, LSTM produced more conservative and stable predictions, estimating 2,899.57; 2,926.22; and 2,921.04 USD/oz for the same months, showing greater robustness to abrupt fluctuations, although with lower adherence to recent historical behavior. The choice of the most suitable model depends on the analyst's risk profile and the desired forecasting horizon. Hybrid approaches are recommended, combining the explanatory power of statistical methods with the flexibility of deep learning algorithms, along with the inclusion of additional macroeconomic variables, to improve both accuracy and robustness in complex and uncertain environments..

Keywords: Gold, Time series, Geopolitical Risk Index, ARIMAX, LSTM.

1. Introdução

O mercado de Ouro tem conceito global, tendo sua reserva utilizada por nações como demonstração de poder. Como refletem Areal, Oliveira e Sampaio (2013), onde indicam: o ouro é um minério que já foi muito explorado, a expectativa ao longo dos anos é de que haja crescimento de seu valor de mercado, pela redução da sua oferta global e, consequentemente, sua exploração será realizada em reservas de cada vez menor teor. Segundo dados do World Gold Council (2024), o ouro registrou preço médio acima de 1.900 USD/oz, consolidando-se como o terceiro ativo mais negociado em derivativos globais, atrás apenas do petróleo e do câmbio dólar/euro, reforçando sua relevância como ativo de proteção em contextos de incerteza.

O presente trabalho apresenta uma análise de séries temporais aplicadas no mercado de ouros futuros, utilizando os modelos estatísticos ARIMAX e os modelos de aprendizado profundo LSTM para previsão do seu valor em um forecasting de 3 meses.

O modelo ARIMAX foi escolhido por sua capacidade de incorporar variáveis exógenas (externas), neste caso, o índice de risco geopolítico (do inglês Geopolitical Risk – GPR) permitindo capturar além dos componentes internos da série de preços do ouro, como tendência e sazonalidade, mas também os efeitos externos que influenciam o comportamento do mercado (Li. et al., 2023).

Já o modelo LSTM, como mostram (Feng, Yang e He, 2022), é capaz de identificar padrões temporais complexos e não lineares em séries temporais multivariadas. Sua estrutura recorrente possibilita o aprendizado de longas dependências temporais e a modelagem conjunta de múltiplas variáveis, o que o torna especialmente adequado para mercados financeiros sujeitos a alta volatilidade e múltiplos fatores influenciadores.

A utilização de ambos modelos permite comparar abordagens tradicionais baseadas em estatística (ARIMAX) com metodologias baseadas em inteligência artificial (LSTM), oferecendo uma visão ampla das possibilidades de previsão do comportamento do ouro frente ao cenário geopolítico internacional. Embora existam estudos que utilizam métodos estatísticos ou de aprendizado profundo isoladamente, ainda são escassas as pesquisas que realizam comparações diretas entre essas abordagens ao incorporar o GPR como variável exógena, o que constitui a principal lacuna que este trabalho busca preencher.

O restante deste artigo está organizado da seguinte forma: a Seção 2 apresenta os trabalhos relacionados; a Seção 3 descreve o material e métodos utilizados; a Seção 4 detalha a metodologia de implementação; a Seção 5 discute os resultados obtidos; e, por fim, a Seção 6 apresenta as conclusões.

2. Trabalhos Relacionados

Diversos estudos exploram o uso de modelos estatísticos e de aprendizado profundo na previsão do preço do ouro, em especial quando combinados com variáveis exógenas

como o Índice de Risco Geopolítico (GPR). Taneva-Angelova et al. (2025) propõem uma estrutura que integra métodos clássicos e inteligência artificial, destacando a relevância da fusão entre dados financeiros, econômicos e de sentimento, abordagem que se relaciona diretamente com o presente estudo. De forma complementar, Feng et al. (2022) aplicam um modelo híbrido *CEEMDAN-BiLSTM* (modelo híbrido que combina um método de decomposição de sinais (CEEMDAN) com um algoritmo de aprendizado profundo (BiLSTM)) e demonstram a eficácia de técnicas profundas para lidar com padrões não lineares e séries com forte componente de ruído.

No que diz respeito ao impacto do GPR, Li et al. (2023) evidenciam a relação direta entre esse índice e a volatilidade do ouro, sugerindo que períodos de maior instabilidade global provocam movimentos de valorização no preço do metal. Zhou e Liang (2025) avançam nessa perspectiva ao discutir a formação de bolhas nos preços do ouro motivadas por tensões geopolíticas, ressaltando a necessidade de modelos sensíveis a rupturas estruturais e efeitos defasados, como o ARIMAX.

A função do ouro como ativo de proteção em cenários de incerteza também é amplamente discutida na literatura. Reboredo et al. (2020) reforçam seu papel de hedge, enquanto Salisu e Vo (2020) destacam a relevância de variáveis baseadas em sentimento, como o GPR, na previsão de retornos. Esses trabalhos fundamentam a escolha metodológica deste estudo, ao mesmo tempo em que ressaltam a importância de explorar a capacidade preditiva do risco geopolítico sobre o mercado do ouro.

Diante dessas contribuições, percebe-se que a literatura oferece avanços relevantes na previsão do ouro e na incorporação do risco geopolítico, mas ainda carece de análises comparativas que integrem abordagens estatísticas e de aprendizado profundo de forma sistemática. Nesse sentido, a próxima seção apresenta os dados e a metodologia adotada neste estudo, detalhando as estratégias de modelagem e os procedimentos utilizados para avaliar o desempenho dos modelos propostos.

3. Materiais e Métodos

Esta seção descreve o conjunto de dados e os métodos empregados na modelagem e previsão dos preços do ouro futuro. Inicialmente, apresenta-se a base de dados utilizada, incluindo a série temporal de preços e o Índice de Risco Geopolítico (GPR) como variável exógena. Em seguida, são detalhados o modelo ARIMAX e o modelo LSTM, destacando suas características fundamentais e justificativas de aplicação no contexto de mercados financeiros voláteis.

3.1 Conjunto de Dados

Os dados utilizados correspondem à série histórica mensal do ouro futuro, obtida no portal Investing.com, abrangendo o período de janeiro de 2005 a junho de 2025. Como variável exógena, foi incorporado o Índice de Risco Geopolítico (Geopolitical Risk Index – GPR), elaborado por Caldara e Iacoviello, amplamente utilizado em estudos sobre impactos de tensões políticas e conflitos sobre mercados financeiros.

A Tabela 1 apresenta eventos geopolíticos significativos entre 2005 e 2025, destacados para contextualizar os picos do índice GPR e sua potencial influência sobre o comportamento do ouro.

Tabela 1 – Eventos cronológicos que impactam o valor monetário potencial do ouro		
Período	Evento	Impacto Potencial no Ouro

2007–2008	Crise financeira global (subprime e falência do Lehman Brothers)	Forte valorização do ouro como ativo de segurança
2010–2012	Crise da dívida na zona do euro (Grécia, Portugal, etc.)	Aumento da aversão ao risco e valorização do ouro
2014	Anexação da Crimeia pela Rússia e início das sanções	Tensão geopolítica impulsionando o valor do ouro
2016	Votação do Brexit no Reino Unido	Incerteza nos mercados europeus
2018–2019	Escalada da guerra comercial EUA–China	Volatilidade nos mercados e valorização do ouro
2020–2021	Pandemia de COVID-19	Alta histórica do ouro pela incerteza global
2022	Início da guerra na Ucrânia (Rússia x Ucrânia)	Alta do ouro por risco geopolítico
2023–2025	Conflitos no Oriente Médio, tensões China-Taiwan, e inflação persistente	Ouro valorizado como hedge contra riscos e inflação

Fonte: Próprios Autores (2025)

No período de 2005 a 2025, foram calculadas as estatísticas descritivas para compreensão inicial das características dos dados utilizados, referentes às séries de preços do ouro e do índice GPR. A Tabela 2 apresenta os valores médios, desvios-padrão, mínimos e máximos, permitindo observar a variação histórica de cada variável e fornecendo subsídios para a etapa de modelagem.

Tabela 2 – Estatísticas descritivas do Ouro e do Índice de Risco Geopolítico (GPR), 2005–2025

Variável	Média	Desvio-padrão	Mínimo	Máximo
Ouro (USD/oz)	1.359,90	463,20	435,80	2.761,60
GPR (Índice)	99,81	28,94	58,42	318,95

Fonte: Elaboração própria a partir de Investing.com (ouro) e Caldara & Iacoviello (GPR)

Além da tabela, a Figura 1 mostra a evolução da série temporal do ouro no período analisado, indicando tendência crescente e momentos de alta volatilidade.

Figura 1 – Preço de fechamento da série do Ouro (2005 - 2025)



Fonte: Próprios Autores (2025)

3.2 Métodos

Considerando as características observadas nos dados do ouro e do Índice de Risco Geopolítico (GPR), descritas na seção anterior, optou-se pela aplicação de dois modelos distintos: o ARIMAX, representando a abordagem estatística tradicional, e a rede neural recorrente LSTM, como representante dos métodos de aprendizado profundo. Essa escolha permite avaliar o desempenho relativo entre técnicas lineares e não lineares, bem como a capacidade de incorporar variáveis exógenas em diferentes contextos de previsão.

3.2.1 ARIMAX

O modelo ARIMAX (*AutoRegressive Integrated Moving Average with eXogenous variables*) foi empregado com a função de capturar tanto a dependência temporal do preço do ouro quanto a influência do GPR e suas defasagens como variáveis externas. Para isso, a série temporal foi inicialmente avaliada quanto à estacionariedade por meio do teste de Dickey-Fuller aumentado (ADF) e transformada por diferenciação quando necessário. O modelo incorpora componentes autorregressivos (AR), de média móvel (MA) e de diferenciação (I), ajustando a estrutura (p, d, q) com base na análise dos gráficos ACF e PACF e no critério de informação de Akaike (AIC).

O GPR foi incluído como variável exógena para refletir o impacto de eventos políticos e econômicos globais na precificação do ouro. A principal vantagem do ARIMAX está em sua interpretabilidade e no controle estatístico das relações entre as variáveis, sendo amplamente utilizado em contextos financeiros, como mostra o estudo de Reboredo, Rivera-Castro e Zebende (2020). Além disso, a abordagem estatística é recomendada como base para comparação com modelos mais sofisticados, conforme sugerido por Li et al. (2023). Após o ajuste, o modelo foi utilizado para realizar previsões sequenciais de três passos à frente, considerando os meses de junho, julho e agosto de 2025.

3.2.2 LSTM

A segunda abordagem utiliza redes neurais recorrentes do tipo LSTM (*Long Short-Term Memory*), consideradas um dos modelos mais eficazes para previsão de séries temporais complexas e com longas dependências (Hochreiter & Schmidhuber, 1997). Diferentemente dos modelos lineares, o LSTM é capaz de capturar padrões não lineares e dinâmicas temporais complexas por meio de unidades de memória que retêm informações por longos períodos.

Essa característica é particularmente relevante para séries financeiras voláteis como a do ouro, em que choques externos e efeitos de longo prazo não são adequadamente tratados por modelos estatísticos. A aplicação segue o proposto por Feng, Yang e He (2022), com normalização dos dados via *MinMaxScaler*. O modelo LSTM foi alimentado com variáveis explicativas semelhantes ao ARIMAX, sendo o preço do ouro e defasagens do GPR, buscando minimizar o erro quadrático médio (MSE).

Conforme destacam Salisu e Vo (2020), o uso de variáveis baseadas em sentimento e risco geopolítico potencializa a performance de redes neurais profundas na previsão de retornos de ativos, dado que capturam mudanças abruptas de regime e comportamento dos mercados. Em comparação com os modelos estatísticos, o LSTM exige mais dados, maior poder computacional e menor interpretabilidade, mas apresenta maior flexibilidade para capturar relações complexas e não lineares. Esse equilíbrio entre robustez estatística e poder preditivo baseado em aprendizado profundo é reforçado por Taneva-Angelova, Raychev e Ilieva (2025), que propõem uma estrutura híbrida de previsão do preço do ouro combinando métodos clássicos e inteligência artificial.

4. Metodologia de Implementação

A implementação dos modelos de previsão seguiu uma sequência estruturada de etapas, abrangendo desde o pré-processamento das séries até a avaliação final do desempenho preditivo.

4.1 Pré-processamento dos Dados

O pré-processamento dos dados buscou assegurar que as séries estivessem adequadas aos pressupostos dos modelos utilizados. A série temporal do preço do ouro foi inicialmente submetida ao teste de Dickey-Fuller aumentado (ADF), com o objetivo de verificar a estacionariedade. Os resultados estão apresentados na Tabela 3 e indicam um valor estatístico de 2,3336 e p-valor de 0,9989, superiores aos valores críticos de 1%, 5% e 10%. Dessa forma, não se rejeita a hipótese nula de raiz unitária, concluindo-se que a série não é estacionária em nível e demandando a aplicação de diferenciação para adequação ao modelo ARIMAX.


Tabela 3 – Teste de Dickey-Fuller aumentado (ADF) para a série de preços do ouro

Estatística	p-valor	Valor crítico 1%	Valor crítico 5%	Valor crítico 10%	Conclusão
2.3336	0.9989	-3.4851	-2.8855	-2.5796	Série não estacionária

Fonte: Elaboração própria a partir dos dados de ouro (2005–2025)

Adicionalmente, foram analisados os gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF), apresentados na Figura 2, que auxiliaram na identificação dos parâmetros autorregressivos (p) e de média móvel (q) na construção do modelo ARIMAX.

Figura 2 – Gráficos de ACF e PACF da série de preços do ouro



Fonte: Próprios Autores (2025)

No caso do modelo LSTM, as variáveis foram normalizadas por meio do método *MinMaxScaler*, com o objetivo de garantir a convergência da rede neural e evitar problemas relacionados a escalas distintas entre o preço do ouro e o índice GPR.

4.2 Definição das Variáveis

A construção dos modelos exigiu a definição das variáveis de estudo a serem utilizadas. A série principal considerada foi o preço do ouro, expresso em dólares por onça *troy* (USD/oz), que constitui a variável dependente do estudo. Como variável exógena, foi incorporado o Índice de Risco Geopolítico (GPR), desenvolvido por Caldara e Iacoviello (2022), o qual mensura a intensidade de tensões políticas e conflitos internacionais por meio da análise de ocorrências em fontes de mídia. A inclusão do GPR buscou refletir o impacto de choques externos sobre o comportamento do mercado de ouro, permitindo que o modelo captasse efeitos não explicados apenas por seus componentes endógenos.

Além da série principal e da variável exógena em nível, também foram consideradas defasagens do GPR, de modo a capturar efeitos retardados que eventos geopolíticos podem exercer sobre a formação do preço do ouro. Essa abordagem é particularmente relevante em mercados financeiros, onde o impacto de choques não se manifesta de forma imediata, mas se distribui ao longo do tempo. Assim, a definição das variáveis permitiu estruturar os modelos de forma a considerar simultaneamente a dinâmica intrínseca da série temporal do ouro e as influências externas advindas do cenário internacional.

4.3 Configuração dos Modelos

O modelo ARIMAX foi configurado de acordo com a formulação clássica que incorpora termos autorregressivos (p), de diferenciação (d) e de média móvel (q). A seleção da ordem adequada considerou a análise dos gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF), complementada pelo Critério de Informação de Akaike (AIC), como é mostrado na Figura 2. O Índice de Risco Geopolítico (GPR) e as suas defasagens, foi definido como variável exógena, de modo a refletir o impacto de choques geopolíticos sobre a precificação do ouro.

No caso do LSTM, a arquitetura da rede neural foi estabelecida com base no procedimento descrito por Feng, Yang e He (2022). A rede foi estruturada com duas camadas LSTM de 50 unidades cada, seguidas de uma camada de saída. A função de ativação tangente hiperbólica foi utilizada nas células de memória, enquanto a camada de saída utilizou ativação linear, apropriada para problemas de regressão. O otimizador definido foi o Adam, e a função de perda escolhida foi o erro quadrático médio (do inglês *mean squared error*, MSE). A janela temporal foi fixada em 12 meses, garantindo que cada sequência de entrada representasse um ano completo de observações do preço do ouro e do índice GPR.

4.4 Procedimento de Treinamento e Validação

O treinamento do ARIMAX foi realizado após a diferenciação da série de preços do ouro, garantindo a estacionariedade identificada no teste de Dickey-Fuller aumentado. O modelo foi ajustado com base no conjunto de dados disponíveis até maio de 2025, sendo em seguida empregado para gerar previsões em uma sequência de três passos à frente, correspondentes aos meses de junho, julho e agosto de 2025. A validação consistiu na comparação entre valores previstos e observados, com base nas métricas de erro absoluto médio (MAE), raiz do erro quadrático médio (RMSE) e coeficiente de determinação (R^2).

Para o LSTM, os dados foram normalizados pelo método MinMaxScaler, aplicado separadamente às variáveis de entrada e à variável alvo. O conjunto de dados foi dividido em 80% para treinamento e 20% para teste, assegurando a avaliação em dados fora da amostra. O modelo foi treinado em 50 épocas, com batch size de 16, utilizando como entradas o preço do ouro e as defasagens do índice GPR. O desempenho foi acompanhado sobre o conjunto de validação (20% da amostra), e as métricas de


avaliação adotadas foram as mesmas utilizadas no ARIMAX, possibilitando a comparação direta entre os dois modelos.

4.5 Métricas de Avaliação

A análise comparativa entre os modelos foi conduzida de forma padronizada, utilizando as mesmas métricas de desempenho. Tanto o ARIMAX quanto o LSTM foram avaliados por meio do erro absoluto médio (MAE), da raiz do erro quadrático médio (RMSE) e do coeficiente de determinação (R^2). Essas métricas permitem quantificar a magnitude dos erros e a qualidade do ajuste, fornecendo critérios objetivos para comparar a acurácia preditiva de métodos estatísticos tradicionais e de redes neurais recorrentes.

Os resultados obtidos pelo ARIMAX apresentaram menores valores de erro (RMSE e MAE) e um R^2 mais elevado, sugerindo maior aderência ao comportamento recente da série de preços do ouro. Já o modelo LSTM apresentou erros mais elevados, refletindo menor acurácia estatística, mas revelou maior estabilidade em períodos de variação abrupta, característica associada à sua capacidade de capturar relações não lineares e dependências de longo prazo.

A Figura 3 apresenta os valores consolidados das métricas para cada modelo, permitindo a comparação direta de seus desempenhos.



Fonte: Próprios Autores (2025)


As Figuras 4 e 5 ilustram visualmente o desempenho dos modelos em relação aos dados históricos.



Fonte: Próprios Autores (2025)

Essa combinação de resultados estatísticos e gráficos oferece uma base consistente para a comparação entre as abordagens, destacando as diferenças entre a aderência mais próxima do ARIMAX e as previsões suavizadas do LSTM.

Figura 5 – Previsão de valores da Série do Ouro com LSTM



Fonte: Próprios Autores (2025)

Em continuidade, a seção seguinte apresenta os resultados detalhados das previsões geradas pelos dois modelos, permitindo uma análise mais aprofundada de seu comportamento diante do horizonte de previsão proposto.

5. Resultados

Os resultados obtidos evidenciam diferenças significativas entre o desempenho dos modelos ARIMAX e LSTM na previsão do preço do ouro futuro, considerando o Índice de Risco Geopolítico (GPR) como variável exógena.

O ARIMAX apresentou previsões mais aderentes ao comportamento histórico recente da série, resultando em valores de 3.383,49; 3.442,05 e 3.500,28 USD/oz para os meses de junho, julho e agosto de 2025, respectivamente. Esse desempenho se refletiu nas métricas estatísticas, com menores valores de RMSE e MAE e R² mais elevado, confirmando sua superioridade em termos de acurácia para o horizonte analisado.

Por outro lado, o LSTM forneceu previsões mais conservadoras e suavizadas, estimando 2.899,57; 2.926,22 e 2.921,04 USD/oz nos mesmos meses. Embora tenha apresentado métricas menos favoráveis, o modelo demonstrou maior robustez diante de oscilações abruptas, característica associada à sua capacidade de capturar padrões não lineares e dependências de longo prazo.

A Tabela 4 resume os resultados das métricas de avaliação, reforçando as diferenças entre os modelos.

Tabela 4 – comparativa com os valores previstos para cada horizonte de previsão

Mês/Ano	Horizonte	ARIMAX (USD/oz)	LSTM (USD/oz)
Jun/2025	t+1	3.383,49	2.899,57
Jul/2025	t+2	3.442,05	2.926,22
Ago/2025	t+3	3.500,28	2.921,04

Fonte: Próprios Autores (2025)

A Figura 6 apresenta a comparação entre os valores previstos e os observados, destacando a aderência do ARIMAX ao comportamento histórico e o perfil suavizado das previsões do LSTM.

Figura 6 – Comparativo de períodos de treino, validação, testes e futuro ARIMAX e LSTM



Fonte: Próprios Autores (2025)

Esses achados mostram a importância de comparar metodologias distintas em cenários financeiros complexos: enquanto o ARIMAX se mostra mais preciso para previsões de curto prazo, o LSTM revela potencial para capturar movimentos estruturais de mais longo alcance, ainda que com menor acurácia estatística imediata.

6. Considerações Finais

Este estudo comparou o desempenho dos modelos ARIMAX e LSTM na previsão do preço do ouro futuro, considerando o Índice de Risco Geopolítico (GPR) como variável exógena. Os resultados indicaram que o ARIMAX apresentou melhor aderência estatística, com menores valores de RMSE e MAE e R^2 mais elevado, confirmando sua eficiência para previsões de curto prazo e de caráter mais interpretável. Por outro lado, o LSTM forneceu previsões mais suavizadas, menos sensíveis a oscilações abruptas, mas com maior capacidade de capturar relações não lineares e dependências de longo prazo.

A comparação evidenciou que, embora o ARIMAX seja mais adequado para análises imediatas e de natureza explicativa, o LSTM se mostra promissor em cenários de maior complexidade, nos quais o comportamento do mercado é influenciado por múltiplos fatores externos, como é o caso do ouro futuro. Assim, a adoção de modelos híbridos pode representar um caminho interessante para pesquisas futuras, combinando a interpretabilidade estatística com a flexibilidade das redes neurais.

Como continuidade deste trabalho, sugere-se a ampliação do conjunto de variáveis exógenas, incluindo indicadores macroeconômicos e financeiros, além da aplicação de

técnicas avançadas de aprendizado profundo. Essa abordagem pode contribuir para aumentar a assertividade das previsões e oferecer subsídios mais robustos à tomada de decisão em mercados financeiros voláteis.

Referências

AREAL, Nelson; OLIVEIRA, Bruno; SAMPAIO, Rodrigo. When times get tough, gold is golden. *The European Journal of Finance*, v. 19, n. 9, p. 937–952, 2013. DOI: <https://doi.org/10.1080/1351847X.2011.636833>.

CALDARA, D.; IACOVIELLO, M. Geopolitical Risk Index – GPR. Disponível em: <https://www.matteoiacoviello.com/gpr.htm>. Acesso em: 25 set. 2025.

LI, Zhiyuan; ZHANG, Lei; WANG, Yanan. *Geopolitical risk and the volatility of gold futures markets*. *Resources Policy*, v. 82, p. 103471, 2023. DOI: <https://doi.org/10.1016/j.resourpol.2023.103471>.

FENG, Xiaolong; YANG, Yimin; HE, Zhiguang. *Gold price forecasting using CEEMDAN and BiLSTM hybrid model*. *Resources Policy*, v. 76, p. 102586, 2022. DOI: <https://doi.org/10.1016/j.resourpol.2022.102586>.

TANEVA-ANGELOVA, Gergana; RAYCHEV, Stefan; ILIEVA, Galina. A framework for gold price prediction combining classical and intelligent methods with financial, economic, and sentiment data fusion. *International Journal of Financial Studies*, v. 13, n. 2, art. 102, 2025. DOI: 10.3390/ijfs13020102.

ZHOU, Hao; LIANG, Jian. *Geopolitical risks, speculative bubbles, and gold prices*. *International Review of Financial Analysis*, v. 90, p. 102934, 2025. DOI: <https://doi.org/10.1016/j.irfa.2023.102934>.

REBOREDO, Juan C.; RIVERA-CASTRO, Miguel A.; ZEBENDE, Gilney F. Gold as hedge against inflation and stock market: Evidence for developed and emerging markets. *Energy Economics*, v. 84, p. 104564, 2020. DOI: <https://doi.org/10.1016/j.eneco.2019.104564>.

SALISU, Afees A.; VO, Xuan Vinh. *Predicting stock returns in the presence of geopolitical risks: The role of gold*. *International Review of Financial Analysis*, v. 71, p. 101509, 2020. DOI: <https://doi.org/10.1016/j.irfa.2020.101509>.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1997. DOI: 10.1162/neco.1997.9.8.1735.

WORLD GOLD COUNCIL. *Gold Demand Trends Full Year 2024*. London: World Gold Council, 2024. Disponível em: <https://www.gold.org/goldhub/research/gold-demand-trends/gold-demand-trends-full-year-2024>. Acesso em: 19 set. 2025.