

UNIVERSIDADE ESTADUAL DE MATO GROSSO DO SUL
UNIDADE UNIVERSITÁRIA DE AQUIDAUANA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA

Previsão de preços para a cadeia de lácteos no Brasil
utilizando aprendizado de máquina

Acadêmico: Marcelo Souto Roschel

Aquidauana – MS

Julho de 2025

UNIVERSIDADE ESTADUAL DE MATO GROSSO DO SUL
UNIDADE UNIVERSITÁRIA DE AQUIDAUANA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA

Previsão de preços para a cadeia de lácteos no Brasil
utilizando aprendizado de máquina

Acadêmico: Marcelo Souto Roschel

Orientador: Andre Rozemberg Peixoto Simões

“Dissertação apresentada ao Programa de Pós-graduação em Zootecnia, área de concentração em Produção Animal no Cerrado - Pantanal, da Universidade Estadual de Mato Grosso do Sul, como parte das exigências para a obtenção do título de Mestre em Zootecnia”

Aquidauana – MS

Julho de 2025

R716p Roschel, Marcelo Souto

Previsão de preços para a cadeia de lácteos no Brasil utilizando aprendizado de máquina / Marcelo Souto Roschel. – Aquidauana, MS: UEMS, 2025.
56 p.

Dissertação (Mestrado) – Mestrado em Zootecnia – Universidade Estadual de Mato Grosso do Sul, 2025.

Orientador: Prof. Dr. Andre Rozemberg Peixoto Simões.

1. Séries temporais. 2. Modelos preditivos. 3. Previsão de preços. I. Simões, Andre Rozemberg Peixoto. II. Título.

CDD 23. ed. - 636.2144

Ficha Catalográfica elaborada pela bibliotecária da Universidade Estadual de Mato Grosso do Sul (UEMS)

Susy dos Santos Pereira CRB1º1783

**UNIVERSIDADE ESTADUAL DE MATO GROSSO DO SUL
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
UNIDADE UNIVERSITÁRIA DE AQUIDAUANA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA
ÁREA DE CONCENTRAÇÃO EM PRODUÇÃO ANIMAL**

MARCELO SOUTO ROSCHEL

Dissertação submetida ao Programa de Pós-Graduação em Zootecnia, área de concentração em Produção Animal, como requisito para obtenção do grau de Mestre em Zootecnia.

DISSERTAÇÃO APROVADA EM 30/06/2025.

Documento assinado digitalmente
 **ANDRE ROZEMBERG PEIXOTO SIMÕES**
Data: 24/07/2025 10:00:09-0300
Verifique em <https://validar.itl.gov.br>

Dr. Andre Rozemberg Peixoto Simões (Orientador)

Dr. João Ricardo Rebouças Dórea, UW–Madison
(participação via videoconferência)

Dra. Vanessa Aparecida De Moraes Weber, UEMS
(participação via videoconferência)

AGRADECIMENTOS

À Deus, pela vida, pela saúde e por sempre iluminar a minha caminhada, principalmente nos momentos difíceis, me guiando e me protegendo de todos os males. A ele, minha gratidão por conceder força, sabedoria e perseverança ao longo dessa jornada acadêmica.

À Universidade Estadual de Mato Grosso do Sul (UEMS), pela oportunidade de realizar este curso e por todo o suporte institucional ao longo da minha formação. Ao Programa de Pós-Graduação em Zootecnia (PGZOO), pela estrutura acadêmica e científica oferecida, bem como pelo comprometimento com a excelência na formação de pesquisadores. Sou grato pela oportunidade de integrar este programa, que foi essencial para o desenvolvimento deste trabalho.

Ao Professor Dr. Andre Simões, pela orientação valiosa e pela inspiração proporcionada durante todo este período. A oportunidade de desenvolver este trabalho sob sua supervisão direta foi extremamente enriquecedora e contribuiu significativamente para o meu crescimento acadêmico e profissional. Sou imensamente grato por todo o apoio, incentivo e pela sabedoria compartilhada ao longo dessa trajetória.

À Professora Dra. Vanessa Weber, pelo apoio essencial durante o processamento dos dados e pela disponibilidade constante em compartilhar conhecimentos. Agradeço pelo tempo, esforço e atenção dedicados, que foram fundamentais para o desenvolvimento desta pesquisa.

Ao Professor Dr. João Dorea, pela orientação durante o intercâmbio na University of Wisconsin–Madison. Sua confiança em meu potencial e os conhecimentos compartilhados durante esse período foram determinantes para ampliar minha visão acadêmica e científica. A experiência proporcionada foi transformadora e continuará influenciando positivamente minha trajetória profissional.

Ao Programa Institucional de Bolsas aos Alunos de Pós-Graduação (PIBAP) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro por meio da concessão de bolsas de estudos, fundamentais para a viabilização desta pesquisa.

À Diretoria de Relações Internacionais (DRI), pela concessão da bolsa de intercâmbio e pela oportunidade ímpar de participar de um programa que contribuiu de forma significativa para minha qualificação acadêmica e pessoal.

Aos meus irmãos, Wilson e Gabriel, pela amizade, cumplicidade e pelos inúmeros momentos de apoio ao longo da minha caminhada. Saber que posso contar com vocês me dá segurança e motivação para seguir em frente, mesmo diante dos desafios.

À minha esposa, Lidiane, meu amor e companheira de todas as horas. Obrigado por estar ao meu lado em cada etapa desta jornada, compartilhando sonhos, enfrentando desafios e celebrando conquistas.

E, com todo amor do mundo, agradeço aos meus filhos, Agatha e Gael, que são a razão maior do meu esforço diário. Cada passo dado nesta jornada tem vocês como inspiração.

Por fim, mas com especial carinho e gratidão, agradeço aos meus pais, Maria Rita e Marcelo, pilares da minha vida. Obrigado por todo amor, apoio incondicional e pela fé depositada em mim mesmo nos momentos em que duvidei da minha própria capacidade. Vocês sempre foram minha base, minha força silenciosa e constante. Cada conquista que alcanço carrega em si o reflexo dos valores que me ensinaram: integridade, perseverança, brio e humildade. Este trabalho é também de vocês, pois sem o incentivo, os sacrifícios e o exemplo que me deram, eu não teria chegado até aqui. Que esta realização seja uma pequena retribuição por tudo o que sempre fizeram por mim.

Sumário

AGRADECIMENTOS	iii
LISTA DE FIGURAS.....	vi
LISTA DE TABELAS	vii
RESUMO.....	viii
ABSTRACT	ix
CAPÍTULO 1 - CONSIDERAÇÕES GERAIS.....	1
1.1 Introdução	1
1.2 Objetivo	2
1.3 Estrutura do trabalho	2
2. REVISÃO DE LITERATURA.....	3
2.1 Dinâmicas do setor lácteos e preços	3
2.2 Séries Temporais.....	5
2.3 Modelos de Séries Temporais	6
3. REFERÊNCIAS BIBLIOGRÁFICAS	9
CAPÍTULO 2 ARTIGO CIENTÍFICO:.....	13
INTRODUÇÃO	14
MATERIAIS E MÉTODOS.....	16
RESULTADOS	21
DISCUSSÃO	30
CONCLUSÃO	32
REFERÊNCIAS	33
CAPÍTULO 3 – ARTIGO TÉCNICO POPULAR (ATP).....	35
Introdução	35
Materiais e métodos	37
Resultados	38
Conclusão.....	41
Referências.....	42
CAPÍTULO 4 – CONSIDERAÇÕES FINAIS.....	43

LISTA DE FIGURAS

Figura 1. Divisão da série temporal do preço do leite UHT no Brasil durante o período de janeiro de 2005 a dezembro de 2023 nas seções de treino, teste e validação	17
Figura 2. Comparação entre valores reais do UHT e previsões do melhor modelo ETS, UCM, SARIMA e LSTM, durante a fase de treino	23
Figura 3. Evolução das correlações temporais entre o preço do leite UHT, preço pago ao produtor e preços da ração ao longo das defasagens	25
Figura 4. Comparação entre valores reais do UHT e previsões do melhor modelo com defasagens (SARIMA_Lag2, SARIMA_Lag6, LSTM_Lag2) durante a fase de treino	25
Figura 5. Comparação entre valores observados do UHT e previsões dos melhores modelos (SARIMA, LSTM, UCM, ETS) durante a fase de validação	26
Figura 6. Estratégia de Previsão com Janela Deslizante em Séries Temporais	27
Figura 7. Comparação entre valores reais do UHT e previsões do melhor modelo com uso de diferentes defasagens (SARIMA_Lag1, SARIMA_Lag4, LSTM_Lag1, LSTM_Lag4) durante a fase de validação.....	29
Figura 8. Divisão da série temporal do preço do leite UHT no Brasil durante o período de janeiro de 2005 a dezembro de 2023 nas seções de treino, teste e validação	38
Figura 9. Comparação entre valores reais do UHT e previsões do melhor modelo ETS, UCM, SARIMA e LSTM, durante a fase de treino	39
Figura 10. Comparação entre valores reais do UHT e previsões do melhor modelo com uso de diferentes defasagens (SARIMA_Lag1, SARIMA_Lag4, LSTM_Lag1, LSTM_Lag4) durante a fase de validação	41

LISTA DE TABELAS

Tabela 1. Equações das Métricas de Erro para Avaliação de Modelos Preditivos em Séries Temporais.....	18
Tabela 2. Parâmetros otimizados dos modelos avaliados nos conjuntos de treino e validação da série temporal do preço do leite UHT no Brasil	21
Tabela 3. Métricas de desempenho dos modelos preditivos do preço do UHT na fase de treino.....	22
Tabela 4. Desempenho dos modelos preditivos em séries temporais: resultados das métricas de erro na fase de validação	28

RESUMO

A produção de leite no Brasil registrou crescimento expressivo nas últimas décadas, passando de 7 bilhões de litros em 1975 para quase 35 bilhões em 2022, acompanhada por ganhos de produtividade. No entanto, a volatilidade dos preços do leite UHT gera incertezas que impactam produtores, consumidores e a indústria, agravadas pela ausência de mecanismos formais de descoberta de preços. Este estudo comparou a capacidade preditiva de modelos econométricos tradicionais e de inteligência artificial (IA) para prever preços do leite UHT, testando a hipótese de que redes neurais recorrentes (LSTM) superam métodos tradicionais em precisão. Foram utilizadas séries temporais mensais do preço do leite UHT e do custo da ração (preço do milho e soja, combinados em uma média ponderada de 60% e 40%) como variável exógena. Quatro modelos foram avaliados: ETS (decomposição clássica), UCM (componentes não observados), SARIMA (sazonalidade integrada) e LSTM (rede neural recorrente), sendo que os dois últimos com e sem inclusão da variável exógena “ração”. A divisão dos dados seguiu períodos de treino, teste e validação, com métricas como MAPE e RMSPE para comparar desempenhos. Os hiperparâmetros foram otimizados por meio de 1.890 combinações diferentes, entre funções de ativação e otimizadores. Os resultados indicaram que o SARIMA obteve a melhor performance geral sem a variável exógena (MAPE:4,79%) na fase de treino e de validação (MAPE 7,39%), capturando sazonalidades e picos históricos com menor atraso. O UCM apresentou resultados intermediários (MAPE: 6,00%) na fase de treino e de validação (MAPE 8,56%), enquanto o ETS teve o pior ajuste (MAPE: 15,50%) na fase de treino e de validação (MAPE: 8,45%). O LSTM, embora promissor no treino (MAPE: 6,19%), mostrou limitações na validação (MAPE: 9,80%) devido à acumulação de erros em previsões *one-step ahead* e à alta sensibilidade a choques aleatórios. A inclusão da variável exógena defasada melhorou parcialmente o LSTM (MAPE: 6,98%), mas prejudicou o SARIMA, possivelmente por introduzir multicolinearidade e sobreparametrização. O estudo revelou que modelos tradicionais, como SARIMA, mantêm vantagem em cenários práticos pela simplicidade e estabilidade, enquanto o LSTM demanda ajustes estruturais (como janelas temporais mais robustas e técnicas de regularização) para mitigar a propagação de erros. Os resultados destacam desafios computacionais e metodológicos, mas também abrem caminho para políticas públicas e gestões empresariais mais informadas, reduzindo assimetrias e fortalecendo a cadeia produtiva.

PALAVRAS-CHAVE: Séries temporais, modelos preditivos, previsão de preços.

ABSTRACT

Milk production in Brazil has grown significantly over recent decades, increasing from 7 billion liters in 1975 to nearly 35 billion in 2022, accompanied by gains in productivity. However, the volatility of UHT milk prices creates uncertainties that affect producers, consumers, and the industry, which is further exacerbated by the lack of formal price discovery mechanisms. This study compared the predictive capacity of traditional econometric models and artificial intelligence (AI) to forecast UHT milk prices, testing the hypothesis that recurrent neural networks (LSTM) outperform traditional methods in terms of accuracy. Monthly time series were used for UHT milk prices (2005-2024) and feed costs (corn and soybeans, 2006-2024), deflated by the IGPM and normalized. Four models were evaluated: ETS (classical decomposition), UCM (unobserved components model), SARIMA (seasonal autoregressive integrated moving average), and LSTM (neural network), both with and without including the exogenous variable “feed.” Data was split into training (up to 2021), testing (2022-2023), and validation (2024) periods, with metrics such as MAPE and RMSPE used to compare performance. Hyperparameters were optimized, particularly in the LSTM, which tested 1,890 different combinations of activation functions and optimizers. The results indicated that SARIMA had the best overall performance without exogenous variables, with a MAPE of 4.79% (training) and 7.39% (validation), effectively capturing seasonality and historical peaks with minimal lag. The UCM model showed intermediate results, with an MAPE of 6.00% (training) and 8.56% (validation), while the ETS model had the poorest fit, with a MAPE of 15.50% (training) and 8.45% (validation). Despite being promising during training (MAPE: 6.19%), the LSTM showed limitations during validation (MAPE: 9.80%) due to error accumulation in one-step-ahead forecasts and high sensitivity to noise. Including the exogenous variable “feed” partially improved the LSTM (MAPE: 6.98% with lag 1), but negatively impacted the SARIMA model, possibly due to multicollinearity and overparameterization. This study revealed that traditional models such as SARIMA have an advantage in practical scenarios due to their simplicity and stability, while LSTM requires structural adjustments (for example, more robust time windows and regularization techniques) to mitigate error propagation. The findings highlight computational and methodological challenges but also pave the way for more informed public policies and business management, reducing asymmetries and strengthening the production chain.

KEYWORDS: Time series, predictive models, price forecasting.

CAPÍTULO 1 - CONSIDERAÇÕES GERAIS

1.1 Introdução

A produção de leite nacional configura-se como um setor complexo e heterogêneo, envolvendo desde pequenos produtores de baixa escala e dependentes de mão de obra familiar até grandes empreendimentos com alto nível de tecnificação. Essa diversidade estrutural, aliada às transformações contínuas nos padrões de produção e comercialização ao longo das últimas décadas, impulsionadas por inovações tecnológicas, reestruturações logísticas e mudanças nos hábitos de consumo, tornam a compreensão da dinâmica dos preços um desafio central para pesquisadores e formuladores de políticas públicas (Siqueira et al., 2010).

Como quarto maior produtor mundial de leite, o Brasil enfrenta uma interdependência multifacetada entre fatores locais e globais, que influenciam desde os custos de produção até o comportamento do consumidor, incluindo volatilidades cambiais e flutuações na demanda internacional por derivados lácteos (FAO, 2025). Historicamente marcado por intervenções governamentais, o setor passou por um processo de desregulamentação a partir de 1991, o que alterou radicalmente a dinâmica de produção, comercialização e formação de preços. Embora a liberalização tenha impulsionado ganhos tecnológicos e produtividade, gerou também volatilidade nos preços pagos ao produtor.

A compreensão da formação e transmissão espacial dos preços do leite é fundamental para políticas de estabilização de mercados, gestão de riscos e planejamento logístico, uma vez que a análise desses mecanismos revela padrões de volatilidade e subsidia modelos estratégicos de precificação. Tais modelos dependem da integração espacial dos mercados e da volatilidade histórica, fatores essenciais para criar instrumentos de proteção contra oscilações. Contudo, prever o comportamento dos preços exige ir além de análises superficiais baseadas em pesquisas pontuais ou flutuações diárias, já que o mercado é influenciado por múltiplas variáveis interconectadas, como tendências econômicas, cenários políticos, valorização de ativos e dinâmicas de capital, cuja complexidade limita a eficácia de projeções simplistas (Hayashi, 2017).

A literatura sobre análise de séries temporais é ampla e diversificada, com destaque para duas abordagens principais: a modelagem estatística e a de *machine learning* (aprendizado de máquina). A primeira abrange modelos clássicos, como o ETS (Erro, Tendência, Sazonalidade), que decompõe a série em componentes básicos para identificar padrões de variação, e o UCM (Unobserved Components Model), que busca capturar fatores latentes, como tendências estocásticas e ciclos não observáveis. Além desses, a modelagem estatística inclui técnicas amplamente consolidadas, como ARIMA (Autorregressivo Integrado de Médias Móveis) e SARIMA (Autorregressivo Integrado de Médias Móveis Sazonal), sendo este último adaptado para séries com sazonalidade conhecida (Brockwell et al., 2016).

Em contraponto aos métodos tradicionais, os métodos baseados em aprendizado de máquina (*machine learning*) se consolidaram com o aprimoramento de recursos computacionais, sobretudo por meio de redes neurais recorrentes (RNNs), que são arquiteturas projetadas para capturar dependências temporais. Dentre essas, destacam-se modelos como o Long Short-Term Memory (LSTM), que se sobressaem pela habilidade de reconhecer padrões não lineares em dados sequenciais, processar grandes volumes de informações e de adaptar-se a séries temporais com ruídos e ausência de sazonalidade definida (Sezer; Gudelek; Ozbayoglu, 2020). Essas características os tornam particularmente relevantes para a análise de mercados dinâmicos, como o leiteiro, no qual choques exógenos aleatórios e interações complexas desafiam modelos convencionais.

1.2 Objetivo

O objetivo deste estudo é realizar previsões do preço do leite em mercados competitivos, comparando a capacidade preditiva de modelos econométricos tradicionais e de *machine learning*.

1.3 Estrutura do trabalho

Esta dissertação é composta pelos seguintes capítulos: esta introdução, que faz uma descrição geral do tema em estudo, sua justificativa e objetivo geral, o segundo capítulo, que apresenta um artigo científico, e o terceiro, constitui as considerações finais, além das referências bibliográficas utilizadas.

2. REVISÃO DE LITERATURA

2.1 Dinâmicas do setor lácteos e preços

A produção de leite ocupa posição estratégica no agronegócio brasileiro, respondendo por 21,25% do Valor Bruto da Produção (VBP) da pecuária nacional em 2024 (CNA, 2025). Além de seu peso econômico, destaca-se por promover impactos sociais estruturantes, especialmente em regiões com limitada diversificação produtiva. A atividade sustenta redes de emprego locais, fixa mão de obra no meio rural e mitiga vulnerabilidades socioeconômicas, consolidando-se como alicerce para o desenvolvimento territorial.

Essa relevância, no entanto, convive com desafios históricos e estruturais. A desregulamentação do setor em 1991, por exemplo, marcou a transição para um modelo de mercado livre, abolindo o controle estatal de preços. Essa medida, embora ampliasse a competitividade, intensificou a volatilidade nas relações entre produtores e indústrias, expondo a cadeia a flutuações cíclicas (Siqueira et al., 2010). A essas pressões somam-se os efeitos da sazonalidade climática tropical, que alterna períodos de alta produtividade nas chuvas com quedas expressivas na estiagem, gerando volatilidade para o setor.

Apesar das adversidades, o setor experimentou avanços expressivos nas últimas décadas. Entre 1975 e 2014, a produção nacional de leite cresceu 5 vezes, passando de 7 bilhões para 35 bilhões de litros. Esse aumento na produção foi alcançado com praticamente o mesmo efetivo de vacas do período de 1975, refletindo um salto na produtividade do rebanho (IBGE, 2023). Apesar do panorama favorável na produção de leite, o pleno desenvolvimento tecnológico ainda não é realidade em grande parte do país, que opera com sistemas a base de conhecimento adquirido culturalmente, baixa especialização dos rebanhos e falta de controle da operacionalidade no campo (Ragazzi et al., 2021).

A sustentabilidade da atividade leiteira depende da modernização dos modelos produtivos, uma vez que a baixa adoção tecnológica limita ganhos de eficiência e compromete padrões de qualidade (Strassburger et al., 2019). Segundo a Embrapa (2020), essa realidade é agravada pela heterogeneidade na distribuição da produção: embora o setor apresente flutuações significativas

de volume, observa-se uma concentração geográfica e operacional em propriedades de maior escala.

Nesse contexto, a adoção de tecnologias inovadoras emerge como fator crítico para reduzir assimetrias competitivas. Ao concentrar a produção em um grupo reduzido de produtores, o setor amplia a necessidade de investimentos em ferramentas que otimizem processos, desde a gestão de rebanhos até a padronização do produto final, garantindo não apenas estabilidade produtiva, mas também resiliência frente a variações de preços do mercado (Nascimento, et al., 2024).

Em 2020 e 2021, a produção nacional de leite passou dos 36 bilhões de litros, contudo, em 2022, apresentou uma leve queda. Ainda assim, o Brasil se manteve como um expressivo produtor mundial de leite (FAO, 2024). Embora 2022 tenha registrado uma retração modesta no volume produzido, o país manteve-se entre os líderes globais, sustentando competitividade frente a outras potências do setor e garantindo receita significativa no mercado interno.

No entanto, o desequilíbrio entre oferta e demanda ressalta a necessidade de estratégias para harmonizar crescimento produtivo com as dinâmicas de consumo, assegurando não apenas posição no ranking global, mas também estabilidade econômica doméstica. A disparidade entre oferta e demanda expõe fragilidades na capacidade de planejamento do setor. Mesmo com volumes expressivos de produção, a incapacidade de acompanhar o ritmo do consumo revela desafios tanto na escala produtiva quanto na gestão eficiente de recursos.

Com isso, em 2024, o Brasil importou mais de 250 mil toneladas de lácteos e seus co-produtos, com o leite em pó representando mais de 60% desse volume; cerca de 95% dessas importações são provenientes da Argentina, Uruguai e Paraguai (Comex, 2025). Essa dependência de importações impacta o mercado interno, pressionando principalmente os preços domésticos devido à influência direta da oferta externa, o que exige, assim, mecanismos ágeis para prever variações de mercado e otimizar estratégias produtivas, reduzindo impactos negativos na balança comercial.

O setor enfrenta um cenário marcado por volatilidade de preços, que impacta toda a cadeia produtiva. Essa instabilidade gera transferências assimétricas de renda entre os elos da cadeia, uma vez que oscilações em um nível (como na produção) nem são integralmente repassadas a outros (como na indústria ou varejo), criando distorções econômicas. Além disso, a imprevisibilidade dificulta o planejamento estratégico de produtores e indústrias, afetando gestão de estoques, programação de vendas e equilíbrio entre oferta e demanda, com reflexos no curto, médio e longo prazo (Santos et al., 2014).

A carência de mecanismos estruturados para antecipar flutuações como a ausência de instrumentos consagrados em outros mercados amplifica a dependência de análises qualitativas e empíricas. Propriedades de grande escala, mesmo com investimento em tecnologia, enfrentam incertezas que limitam ganhos de eficiência (CNA, 2025). Para pequenos e médios produtores, a falta de previsibilidade intensifica riscos operacionais, como custos imprevistos e desalinhamentos entre produção e capacidade industrial. Assim, a integração de modelos preditivos às estratégias de gestão representa não apenas uma vantagem competitiva, mas um passo crítico para a sustentabilidade do setor, alinhando capacidade produtiva e resiliência econômica.

2.2 Séries Temporais

Uma série temporal consiste em um conjunto de observações sequenciais de uma variável, coletadas em intervalos regulares e ordenados cronologicamente, com o objetivo de inferir padrões, relações e comportamentos por meio de modelos matemáticos e estatísticos. Sua aplicação abrange diversas áreas do conhecimento, desde a economia até as ciências naturais, permitindo a análise de fenômenos dinâmicos ao longo do tempo. Conforme destacam Shumway e Stoffer (2017), a investigação inicial em séries temporais requer um exame minucioso dos dados, etapa crucial para definir metodologias e estatísticas adequadas à extração de informações relevantes.

A análise de estacionariedade é fundamental para se estudar uma série temporal. Uma série é considerada estacionária quando sua média, variância e autocorrelação permanecem constantes ao longo do tempo, condição essencial para a aplicação de modelos preditivos. Em contraste, séries não estacionárias

exibem tendências ou variâncias variáveis, demandando técnicas como diferenciação ou transformações para alcançar estacionariedade (Thiello, 2000).

As séries temporais são compostas por quatro elementos principais: tendência, sazonalidade, ciclos e erro aleatório. A tendência corresponde ao movimento de longo prazo da série, indicando crescimento, declínio ou estabilidade ao longo do tempo. A sazonalidade refere-se a flutuações periódicas e regulares que se repetem em intervalos fixos inferiores a um ano. Os ciclos representam oscilações de longo prazo em torno da tendência, sem periodicidade definida, como ciclos econômicos de recessão e expansão ou eventos climáticos recorrentes (e.g., El Niño), que podem persistir por anos ou décadas. Por fim, o erro aleatório engloba variações não explicadas pelos demais componentes, caracterizado por resíduos imprevisíveis e independentes, modelados como variáveis com média zero e variância constante (Duket, 2015). A decomposição desses elementos permite identificar e isolar padrões sistemáticos, facilitando a análise e modelagem adequada da série temporal.

2.3 Modelos de Séries Temporais

A análise de séries temporais é uma ferramenta essencial para desvendar padrões históricos e projetar comportamentos futuros, especialmente em áreas como economia, meteorologia e gestão de negócios. Nesse contexto, o modelo ETS (Error, Trend, Seasonal) destaca-se por decompor a série em três componentes fundamentais, erro, tendência e sazonalidade, que podem assumir estruturas aditivas ou multiplicativas. Cada combinação desses três elementos dá origem a uma configuração distinta e, considerando as variações de tendência (linear, amortecida ou ausente) e de sazonalidade (presente ou inexistente), obtém-se 15 modelos básicos. Ao levar em conta a natureza aditiva (A) ou multiplicativa (M) dos erros, bem como as formas amortecidas (Ad e Md), esse leque expande-se para até 30 modelos potenciais, sintetizados pela notação ETS (*, *, *), na qual o primeiro asterisco indica o tipo de erro, o segundo o formato da tendência e o terceiro a sazonalidade (Brockwell & Davis, 2002)

Por trás dessas formulações encontra-se a estrutura de espaço de estado, que atribui às componentes não observadas um papel probabilístico na geração dos dados observados. Para cada método de suavização exponencial existem duas versões do modelo de espaço de estado, uma com erros aditivos

e outra com erros multiplicativos, cujas previsões pontuais coincidem (sob os mesmos parâmetros), mas cujos intervalos de previsão diferem em virtude da forma de propagação da incerteza. A distinção entre erros aditivos e multiplicativos é feita justamente pela primeira letra na tripla ETS: por exemplo, ETS(A,A,N) corresponde ao método linear de Holt com erro aditivo, enquanto ETS(M,Md,M) caracteriza um modelo com erro multiplicativo, tendência multiplicativa amortecida e sazonalidade multiplicativa (Hyndman, 2008).

O modelo de Componentes Não Observados (UCM, na sigla em inglês), que faz parte da família dos modelos de Espaço de Estados (State Space Models), é uma formulação flexível que pode incluir componentes como tendência, sazonalidade, ciclos, variáveis exógenas e termos de distúrbio. Essa técnica é capaz de lidar com uma gama mais ampla de problemas do que a decomposição determinística das séries temporais (Durbin & Koopman, 2012). Os modelos UCM representam os componentes de tendência, sazonalidade e ciclos assumindo que eles seguem processos estocásticos (Harvey & Koopman, 2009).

Os modelos ARIMA (*Autoregressive Integrated Moving Average*) e SARIMA (*Seasonal Autoregressive Integrated Moving Average*) são técnicas estatísticas fundamentais para a análise e previsão de séries temporais, desenvolvidas por Box e Jenkins na década de 1976. Esses modelos partem do princípio de que séries temporais podem ser decompostas em componentes autorregressivos, de média móvel e diferenciação, permitindo modelar padrões complexos como tendências, ciclos e sazonalidade. O ARIMA, em sua forma básica, combina três elementos: o termo autorregressivo (AR), que relaciona a observação atual a valores passados da série; a integração (I), que utiliza diferenciação para eliminar não estacionariedade (como tendências); e o componente de média móvel (MA), que associa o valor atual a erros residuais passados. A estrutura geral do ARIMA é definida pelos parâmetros p, d, q , em que p indica a ordem do termo AR, d o número de diferenciações necessárias para estacionarizar a série e q a ordem do termo MA.

O SARIMA é uma extensão do ARIMA que incorpora a sazonalidade, um fenômeno comum em dados como temperaturas mensais ou vendas anuais. Esse modelo insere parâmetros adicionais $(p, d, q, P, D, Q) \times S$ e um período sazonal

(S), representando ciclos repetitivos. A estrutura multiplicativa do SARIMA permite que componentes não sazonais e sazonais interajam, capturando tanto flutuações de curto prazo quanto padrões cíclicos de longo prazo. A diferenciação sazonal (D) remove tendências periódicas, enquanto os termos autorregressivos (P) e de média móvel (Q) sazonais ajustam a dependência entre observações separadas pelo intervalo S .

A metodologia de construção desses modelos, conhecida como abordagem Box-Jenkins, envolve quatro etapas interligadas: identificação (análise gráfica e de correlação para selecionar ordens p, d, q, P, D, Q), estimação (ajuste de parâmetros via métodos como máxima verossimilhança), diagnóstico (validação por meio de análise de resíduos e critérios como AIC e BIC) e previsão (extrapolação da série com base no modelo validado).

As redes neurais artificiais (RNAs) são um tipo de sistema computacional que imita e simula a função do cérebro humano para analisar e processar dados complexos de forma adaptativa. Elas são capazes de realizar computações massivamente paralelas para mapeamento, aproximação de funções, classificação e reconhecimento de padrões, exigindo menos treinamento estatístico formal. Além disso, as RNAs têm a capacidade de identificar relacionamentos não lineares altamente complexos entre variáveis de resultado (dependentes) e preditoras (independentes), utilizando múltiplos algoritmos de treinamento (Okut, 2021).

As redes neurais artificiais (RNAs) são classificadas em duas categorias principais: feedforward (propagação direta) e recorrentes (RNNs), cada uma com subclasses específicas. Nas redes feedforward, amplamente utilizadas para classificação, reconhecimento de padrões e aproximação de funções, os neurônios de cada camada conectam-se exclusivamente aos da camada seguinte, sem retroalimentação, ou seja, o fluxo de informação é unidirecional. Já as redes neurais recorrentes (RNNs) processam dados sequenciais (como voz, texto e series temporais) por meio de laços na camada oculta, permitindo que informações passadas influenciem saídas futuras. Entretanto, RNNs profundas enfrentam problemas de gradientes que desaparecem ou explodem em sequências longas, limitando a captura de dependências temporais distantes e prejudicando a convergência do modelo (Okut et al., 2016).

Para resolver essas limitações, as redes Long Short-Term Memory (LSTM) introduzem células de memória e três portas reguladoras: entrada (armazena dados relevantes), esquecimento (descarta informações obsoletas) e saída (define a informação utilizada na predição). Esses componentes, governados por funções de ativação (sigmoid e tanh) e pesos ajustáveis, evitam problemas de gradientes e retêm contextos de longo prazo (Hochreiter & Schmidhuber, 1997; Houdt et al., 2020).

O treinamento de LSTMs utiliza Backpropagation Through Time (BPTT) com hiperparâmetros críticos, como taxa de aprendizado e configuração da porta de esquecimento (Greff et al., 2017), o que caracteriza sua natureza recorrente. Estudos como o de Greff et al. (2017) destacam que a taxa de aprendizado e a configuração da porta de esquecimento são hiperparâmetros críticos ao desempenho. Técnicas como *dropout* e normalização são empregadas para reduzir sobreajuste, enquanto métodos alternativos, como o Evolino (Schmidhuber et al., 2007) exploram otimização baseada em evolução de pesos. Na prática, as LSTMs destacam-se em aplicações como previsão financeira e análise de séries temporais.

3. REFERÊNCIAS BIBLIOGRÁFICAS

Box G.E.P; Jenkin G.M. Time series analysis, forecasting and control. Holden day, San Francisco, 1976.

Brockwell, P. J; Davis R. A. Introduction to Time Series and Forecasting, 2nd edition. New York: Springer, 2002.

CNA. Confederação da Agricultura e Pecuária do Brasil: Boletim VBP 2025, Disponível: <https://www.cnabrazil.org.br/publicacoes/vbp-da-agropecuaria-deve-crescer-11-4-em-2025>, 2025.

CNA. Confederação da Agricultura e Pecuária do Brasil: Grupo de Trabalho da CNA debate mercado futuro do leite, Disponível: https://cnabrazil.org.br/noticias/grupo-de-trabalho-da-cna-debate-mercado-futuro-do-leite?utm_source=chatgpt.com, 2024.

Duket, G. STD: A Seasonal-Trend-Dispersion Decomposition of Time Series, journal of latex class files, vol. 14, no. 8, 2015.

Durbin, J; Koopman, S. J. Time series analysis by state space methods. 2nd ed. Oxford Statistical Science Series. Oxford University Press, 2012.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. Technical Circular. Milk production chain in Brazil: primary production. Embrapa Gado de Leite, 2020. Available at: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/215880/1/CT-123.pdf>. Acesso em: 20 maio. 2025.

FAO, Food and Agriculture Organization of the United Nations. FAO STAT. Disponível em: <https://www.fao.org/home/en> , Acesso em: 20 de maio 2025, 2025.

Fischer, T., Krauss, C.: Deep learning with long short-term memory networks for financial market predictions. European Journal of Operational Research 270(2), 654 – 669, 2018.

Gers, F., Schmidhuber, J., Cummins, F.: Learning to forget: Continual prediction with lstm. Neural computation 12, 2451–71, 2000.

GOMES, A.L. “O comportamento do preço do leite recebido pelo produtor: uma abordagem de curto e longo prazo.” MS thesis, Universidade Federal de Viçosa, 2003.

Greff, K., Srivastava, R.K., Koutnik, J., Steunebrink, B.R., Schmidhuber, J.: LSTM: A Search Space Odyssey. IEEE Transactions on Neural Networks and Learning Systems 28(10), 2222–2232, 2017.

Harvey, A. C. *Forecasting, Structural Time Series Models and the Kalman Filter*. Cambridge University Press, 1991.

Harvey, A; Koopman, S. J. Unobserved components models in economics and finance. IEEE Control Systems Magazine 29:71-81. <https://doi.org/10.1109/MCS.2009.934465>, 2009.

HAYASHI, A. H. Processo para predição de preços das ações no mercado financeiro com uso de Big Data. 2017. 90 f. Dissertação (Mestrado) - Curso de Engenharia de Computação: Redes de Computadores, Instituto de Pesquisas Tecnológicas do Estado de São Paulo, São Paulo, 2017.

Hochreiter, S; Schmidhuber, J. Long short-term memory. *Neural computation* 9, 1735–80, 1997.

Houdt, G.V; Mosquera, C; Nápoles, G. A Review on the Long Short-Term Memory Model, Faculty of Business Economics, Hasselt University, Belgium, 2020.

Hyndman, R.J; Koehler, A.B

Hyndman, R.J; Koehler, A.B; Ord, J.K; Snyder, R.D. *Forecasting with Exponential Smoothing: The State Space Approach*. Berlin, Heidelberg: Springer Berlin / Heidelberg, 2008.

Hyndman, R.J; Koehler, A.B; Snyder, R.D; Grose, S. A State Space Framework for Automatic Forecasting Using Exponential Smoothing Methods. *International Journal of Forecasting*. 18, 439–454, 2002

IBGE. Pesquisa da pecuária municipal. 2023b. Disponível em: <https://sidra.ibge.gov.br/pesquisa/ppm/quadros/brasil/2022>. Acesso em: 5 dez. 2023.

Nascimento, M.P.S; Calvet, R. M; Lopes, J.B.A; Machado, F. C. F; Muratori, M. C. S. Prospecção da cadeia produtiva do leite no Brasil: panorama histórico, impactos e desafios, <https://doi.org/10.55905/oelv22n4-226> ,2024.

Okut, H. Bayesian Regularized Neural Networks for Small n Big p Data. 10.5772/63256, 2016.

Ragazzi, F. G; Holmström, T. C. N; Santos, D. A; Fragata, N. P; Modesto, E. C. Análise da variação estacional na produção de leite nas diferentes bacias leiteiras no Brasil. *Brazilian Journal of Animal and Environmental Research*, v. 4, n. 1, p. 976-988, 2021.

Sagheer, A., Kotb, M.: Time series forecasting of petroleum production using deep lstm recurrent networks. *Neurocomputing* 323, 203 – 213, 2019.

Santos, A.V.L; Rosado, P.L; Shiki, S.F.N; Carvalho; B.H.P. análise do comportamento dos preços recebidos pelos produtores de leite no Brasil. 10.13140/RG.2.1.1892.1682., 2014.

Schmidhuber, J. *Deep Learning in Neural Networks: An Overview*". *Neural Networks*, 2015.

Schmidhuber, J., Wierstra, D., Gagliolo, M., Gomez, F.: Training recurrent networks by evolution. *Neural computation* 19(3), 757–779, 2007.

Sezer, O. B; Gudelek, M. U; Ozbayoglu, A. M. Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. *Applied Soft Computing*, v. 90, p. 106181, 2020.

Siqueira, K. B; Kilmer, R. L; Campos, A. C. The dynamics of farm milk price formation in Brazil. *Revista de Economia e Sociologia Rural* 48:41-61. <https://doi.org/10.1590/S0103-20032010000100003>, 2010.

Siqueira, K. B; Kilmer, R. L; Campos, A. C. The dynamics of farm milk price formation in Brazil. *Journal of Rural Economics and Sociology*, v. 48, n. 1, p. 41-61, 2010.

Siqueira, K.A; Kilmer, R.L; Campos, A.C. The dynamics of farm milk price formation in Brazil, Piracicaba, SP, vol. 48, nº 01, p. 41-61, 2010.

Strassburger, A. H; Caye, V. A. H; Costella, M. F; Dalcanton, F. Análise da variação da qualidade microbiológica do leite cru refrigerado: uma revisão sistemática da literatura. *Revista do Instituto de Laticínios Cândido Tostes*, v. 74, n. 1, p. 60-72, 2019.

Thielo, M.R. A distinção entre séries estacionárias e não estacionárias, *Dissertação (Mestrado) – curso de ciência da computação*, Porto Alegre, 2000.

USDA. United States Department of Agriculture: Foreign Agricultural Service, Disponível: <https://apps.fas.usda.gov/psdonline/app/index.html#/app/home> , 2025.

Este artigo está elaborado nas normas da revista: Computers and electronics in agriculture.

CAPÍTULO 2 ARTIGO CIENTÍFICO:

Previsão de preços para a cadeia de lácteos no Brasil utilizando aprendizado de máquina

Price forecasting for the dairy supply chain in Brazil using machine learning models

A.R. P. Simões,¹, M. S. Roschel,^{1*}

¹Zootecnia, Universidade Estadual do Mato Grosso do Sul, Mato Grosso do Sul, Brazil 79200-000

*Autor para correspondência: marcelo_roschel@hotmail.com

ABSTRACT

Milk production in Brazil has grown significantly over recent decades, increasing from 7 billion liters in 1975 to nearly 35 billion in 2022, accompanied by gains in productivity. However, the volatility of UHT milk prices creates uncertainties that affect producers, consumers, and the industry, which is further exacerbated by the lack of formal price discovery mechanisms. This study compared the predictive capacity of traditional econometric models and artificial intelligence (AI) to forecast UHT milk prices, testing the hypothesis that recurrent neural networks (LSTM) outperform traditional methods in terms of accuracy. Monthly time series were used for UHT milk prices (2005-2024) and feed costs (corn and soybeans, 2006-2024), deflated by the IGPM and normalized. Four models were evaluated: ETS (classical decomposition), UCM (unobserved components model), SARIMA (seasonal autoregressive integrated moving average), and LSTM (neural network), both with and without including the exogenous variable "feed." Data was split into training (up to 2021), testing (2022-2023), and validation (2024) periods, with metrics such as MAPE and RMSPE used to compare performance. Hyperparameters were optimized, particularly in the LSTM, which tested 1,890 different combinations of activation functions and optimizers. The results indicated that SARIMA had the best overall performance without exogenous variables, with a MAPE of 4.79% (training) and 7.39% (validation), effectively capturing seasonality and historical peaks with minimal lag. The UCM model showed intermediate results, with an MAPE of 6.00% (training) and 8.56% (validation), while the ETS model had the poorest fit, with a MAPE of 15.50% (training) and 8.45% (validation). Despite being promising during training (MAPE: 6.19%), the LSTM showed limitations during validation (MAPE: 9.80%) due to error accumulation in one-step-ahead forecasts and high sensitivity to noise. Including the exogenous variable "feed" partially improved the LSTM (MAPE: 6.98% with lag 1), but negatively impacted the SARIMA model, possibly due to multicollinearity and overparameterization. This study revealed that traditional models such as SARIMA have an advantage in practical scenarios due to their simplicity and stability, while LSTM requires structural adjustments (for example, more robust time windows and regularization techniques) to mitigate error propagation. The findings highlight computational and methodological challenges but also pave the way for more informed public policies and business management, reducing asymmetries and strengthening the production chain.

KEYWORDS: Time series, predictive models, price forecasting.

INTRODUÇÃO

A produção de leite no Brasil registrou um crescimento expressivo, passando de 7 bilhões de litros em 1975 para quase 35 bilhões em 2022, acompanhada por um avanço de 3,4 vezes na produtividade (IBGE, 2023). Esse crescimento destaca a importância do setor, no entanto, o entendimento da dinâmica dos preços pagos aos produtores e seus derivados ainda representa um grande desafio. O leite UHT é um dos principais direcionadores dos preços dessa cadeia produtiva e, portanto, flutuações nos seus preços geram incertezas que impactam diretamente o planejamento da produção nas fazendas, o poder de compra dos consumidores e a competitividade da indústria de laticínios. Essas oscilações, associadas a fatores como concentração de mercado, políticas fiscais e gestão de riscos, criam um ambiente volátil que prejudica a tomada de decisões estratégicas, afetando a competitividade e a estabilidade setorial (Scalco & Braga, 2015).

No Brasil, a ausência de mecanismos estruturados de descoberta de preços do leite e derivados, como os mercados futuros, representa um obstáculo significativo para a formulação de políticas públicas e o desenvolvimento de estratégias empresariais. Essa lacuna prejudica o planejamento interno da produção, processamento e comercialização dos lácteos, comprometendo a coordenação da cadeia produtiva e restringindo a competitividade do país no mercado internacional (Yamakawa et al., 2023). Assim como em outros mercados agrícolas, o aprimoramento dos mecanismos de formação de expectativas de preços tem o potencial de ampliar a transparência, reduzir a assimetria de informações, favorecer a convergência de expectativas entre os agentes e promover maior estabilidade no mercado a longo prazo.

Diante desse cenário, a aplicação de métodos matemáticos e estatísticos a fim de aprimorar a descoberta de preços dos lácteos surge como uma alternativa estratégica. Ao desenvolver modelos capazes de antecipar tendências e reduzir incertezas, essas ferramentas podem compensar parcialmente a falta de mecanismos formais de descoberta de preços, contribuindo para um ambiente de negócios mais previsível. Além disso, ao

fornecer bases técnicas sólidas para a tomada de decisão, elas não apenas apoiam a formulação de políticas públicas mais eficazes, mas também fortalecem a coordenação entre os elos da cadeia produtiva, aspectos essenciais para mitigar as fragilidades atuais e elevar a competitividade internacional do setor.

Os métodos de previsão de preços para produtos agrícolas podem ser classificados em duas abordagens principais. A primeira baseia-se em modelos econométricos tradicionais (Kmytiuk et al., 2024; Shao, Y., 2024; Vilela et al., 2024; Simões et al., 2023; Jammeh et al., 2023; Kaur, 2018), que partem de premissas específicas sobre a natureza dos dados temporais, como a estacionariedade e a linearidade dos processos. Apesar desses modelos terem evoluído ao longo do tempo, ainda persistem limitações em seus usos quando as séries temporais exibem comportamentos não lineares complexos, em cenários de alta volatilidade ou de eventos extremos. Um exemplo é a limitação suposta pela normalidade dos resíduos, frequentemente violada na presença de choques exógenos, como crises econômicas e eventos climáticos externos. Esses elementos reduzem a capacidade preditiva desses modelos pela dificuldade de identificação de padrões atípicos ou irregularidades nos dados (Alba & Muñoz-Zavala, 2015).

A segunda categoria abrange métodos mais modernos, como aprendizado de máquina, que vem ganhando destaque com os avanços na capacidade computacional, especialmente no uso de redes neurais recorrentes (RNNs). Modelos dessa natureza, como o LSTM (Tami et al., 2024; Sun et al., 2023; Kurumatani, 2020), destacam-se por sua capacidade de identificar padrões complexos, processar grandes volumes de dados e lidar com séries temporais caracterizadas por não linearidade, ruídos e não estacionalidade (Sezer et al., 2020).

Neste trabalho, assumimos a hipótese de que os modelos RNN possuem uma melhor acurácia na previsão dos preços do leite UHT quando comparados aos modelos econométricos tradicionais. Portanto, o objetivo deste estudo é comparar a capacidade preditiva de modelos econométricos tradicionais e de *machine learning* para o preço do leite em mercados competitivos.

MATERIAIS E MÉTODOS

Os dados utilizados foram coletados da plataforma do Centro de Estudos Avançados em Economia Aplicada (CEPEA) e consistem em duas séries temporais. A primeira série refere-se aos preços mensais do leite UHT no mercado atacadista, praticados pelos laticínios, abrangendo o período de janeiro de 2005 a setembro de 2024. A segunda série contempla os preços do milho e da soja no mercado nacional, que foram combinados em uma média ponderada de 60% e 40%, respectivamente, para criar uma série denominada preço da ração, no período de março de 2006 a agosto de 2024.

O preço da ração foi incorporado com a finalidade de se testar a capacidade preditiva dos diferentes modelos na presença de variáveis exógenas. A escolha do preço da ração como variável exógena justifica-se devido ao seu peso nos custos na produção de leite, representando um dos principais componentes na restrição da oferta do produto (Krasniqi et al., 2018). Buscou-se comparar a performance preditiva dos modelos frente a essa variável-chave, sem pretender esgotar relações causais ou capturar todos os choques exógenos da série histórica. Para otimizar a relação temporal, foram testadas diferentes defasagens entre a ração e o preço do UHT por meio de análise de correlação cruzada.

As séries temporais foram deflacionadas utilizando o Índice Geral de Preços – Mercado (IGPM), garantindo a comparabilidade temporal ao eliminar efeitos inflacionários. No pré-processamento, todas as variáveis passaram por normalização via método Min-Max Scaler no intervalo $[0, 1]$, estratégia que reduz discrepâncias de escala entre dados heterogêneos e otimiza a convergência dos algoritmos (Shantal et al., 2023). Com os dados ajustados, aplicaram-se quatro modelos preditivos ao preço do leite UHT: Error, Trend, Seasonality (ETS), UCM (Unobserved Components Model), SARIMA (Seasonal Autoregressive Integrated Moving Average) e LSTM (Long Short-Term Memory).


O ETS decompõe a série em erro, tendência e sazonalidade, sendo eficaz para padrões não lineares determinísticos (Hyndman & Khandakar, 2008). O modelo UCM identifica componentes latentes (como tendência e ciclos) por meio de processos estocásticos, permitindo a análise de fenômenos não observáveis (Harvey, 1989). Já o modelo SARIMA incorpora sazonalidade e lida

com dados não estacionários e padrões cíclicos (Box & Jenkins, 1976). Por fim, o modelo LSTM (*Long Short-Term Memory*) se caracteriza em capturar dependências de longo prazo em sequências complexas, como séries temporais (Hochreiter & Schmidhuber, 1997).

A divisão das séries em conjuntos de treino, teste e validação foi definida conforme critérios específicos para cada modelo, considerando suas particularidades (Figura 1). A fase de teste teve como objetivo selecionar o modelo que melhor se ajusta aos dados reais durante o treino, otimizando seu desempenho. Após essa escolha, a fase de validação foi utilizada para simular um cenário realista, permitindo avaliar o desempenho prático do modelo em condições próximas às aplicações reais, sem interferência de ajustes adicionais.

Para modelos sem variáveis exógenas, o treino abrangeu janeiro/2005 a dezembro/2021. Já nos modelos com variáveis exógenas, o treino iniciou em setembro/2006, devido à indisponibilidade de dados para o mesmo período, a seção de teste foi de janeiro/2022 a dezembro/2023 e a de validação de 2024 em diante. A seleção do número de defasagens foi realizada por meio de análise de correlação cruzada entre o preço da ração e o do leite UHT, visando identificar intervalos temporalmente plausíveis para a influência da variável exógena.

Figura 1. Divisão da série temporal do preço do leite UHT no Brasil durante o período de janeiro de 2005 a dezembro de 2023 nas seções de treino, teste e validação.



Diferentemente dos demais métodos, para implementar o modelo LSTM, foi utilizada uma abordagem baseada em janelas deslizantes, em que cada janela foi composta por 36 meses. Essa configuração foi escolhida para capturar padrões sazonais e tendências de longo prazo presentes nos dados. O objetivo do modelo é prever o próximo valor da série, ou seja, o valor do mês subsequente ao último da janela. Esse método permite que o modelo aprenda relações temporais importantes, explorando dependências complexas entre os valores passados e a previsão futura. Os dados dos intervalos de tempo $t_1, t_2, \dots, t_n$, juntamente aos fatores determinantes associados (variáveis exógenas, componentes da série temporal, características estatísticas do processo, entre outros) foram combinados e utilizados como entrada nos modelos LSTM. Esses modelos transformam essa sequência de entradas em uma previsão correspondente ao intervalo de tempo t_{n+1} .

A avaliação da precisão dos modelos preditivos em séries temporais requer o uso de métricas que capturam diferentes dimensões do erro, permitindo identificar tendências de subestimação ou superestimação e avaliar a robustez do modelo. Para isso, foram utilizadas seis métricas: Erro Médio (ME), Erro Médio Percentual (MPE), Erro Absoluto Médio (MAE), Erro Quadrático Médio (RMSE), Erro Percentual Médio Quadrático (RMSPE) e Erro Absoluto Percentual Médio (MAPE). Cada métrica oferece uma perspectiva única sobre o desempenho do modelo, como proposto por Kuhn e Johnson (2013).

Tabela 1. Equações das Métricas de Erro para Avaliação de Modelos Preditivos em Séries Temporais.

Métricas de desempenho	Equação
ME (Erro Médio)	$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)$
MPE (Erro Médio Percentual)	$\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right) \times 100$
MAE (Erro Absoluto Médio)	$\frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $

RMSE (Erro Quadrático Médio)	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$
RMSPE (Erro Percentual Médio Quadrático)	$\sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2} \times 100$
MAPE (Erro Absoluto Percentual Médio)	$\frac{1}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right \times 100$

Para cada modelo preditivos (ETS, UCM, SARIMA e LSTM), foi desenvolvida uma função específica de otimização de parâmetros, com o objetivo de minimizar o valor do MAPE durante a fase de treino.

No modelo ETS, foram avaliadas diferentes combinações de tipo de tendência (aditiva, multiplicativa ou nenhuma) e sazonalidade (aditiva, multiplicativa ou nenhuma), com períodos de 12, 24, 36, 48 e 60 meses. Além disso, três métodos de inicialização dos parâmetros (estimada, heurística e legado) foram considerados.

A abordagem para o modelo UCM seguiu estrutura similar, avaliando diversas configurações para os componentes sazonais e a presença de componentes de nível, tendência, irregularidades e ciclos. Para o modelo SARIMA, os parâmetros não sazonais (p, d, q) e sazonais (P, D, Q) foram inicialmente definidos com base nas funções de autocorrelação (ACF) e autocorrelação parcial (PACF), permitindo uma análise preliminar das dependências temporais. Diversas combinações de parâmetros foram testadas, levando em conta o impacto de cada configuração na precisão das previsões.

Para a construção e otimização do modelo LSTM, foi realizada a busca sistemática dos hiperparâmetros visando minimizar o MAPE e o RMSE. A arquitetura do modelo seguiu uma abordagem simplificada, utilizando apenas uma camada simples de neurônios. Foram testados diferentes números de neurônios na camada oculta: 10, 30, 50, 70, 90 e 110. Essa variação permitiu identificar o número ideal de neurônios, que permita ao modelo capturar suficientemente os padrões subjacentes (evitando underfitting) sem se ajustar

excessivamente aos ruídos específicos dos dados de treinamento (evitando overfitting).

Quanto às funções de ativação, três opções foram avaliadas: ReLU (para evitar gradientes desaparecentes), Tanh (para saídas normalizadas) e Sigmoid (para comportamentos não lineares suaves). A fim de garantir a generalização do modelo, aplicou-se Dropout como técnica de regularização, com taxas de 10%, 30% e 50%. Essa etapa foi crítica para reduzir a dependência do modelo a padrões específicos dos dados de treino. Na otimização, sete algoritmos foram comparados: Adam, RMSprop, SGD (com momentum), Adagrad, Adadelta, Adamax e Nadam, todos com taxa de aprendizado fixa em 0.001. O SGD, por exemplo, utilizou momentum de 0.9 para acelerar a convergência.

O treinamento considerou ainda diferentes tamanhos de *batch_size* (8, 16, 24, 32 e 64), buscando equilibrar velocidade de treino e estabilidade na atualização dos pesos. O critério de parada foi definido por Early Stopping, interrompendo o treino após 20 épocas sem melhoria na perda de validação (*val_loss*), com restauração automática dos melhores pesos. Para as janelas deslizantes foram testados 12, 24, 36, 48 e 60 meses.

Todos os cenários (combinações de neurônios, ativação, *dropout*, otimizador e *batch_size*) foram testados exaustivamente para cada uma das seis defasagens temporais, incluindo 6 neurônios, 3 ativações, 3 *dropout*, 7 otimizadores, 5 *batches_size*, resultando em 1.890 combinações por defasagem.

Os experimentos foram conduzidos no Laboratório de Inteligência Artificial Aplicada UEMS/KEROW, utilizando uma estação de trabalho equipada com GPU NVIDIA L40S (48 GB VRAM), processador Intel Xeon e 128 GB de memória RAM. Esse ambiente possibilitou a realização eficiente dos testes de diferentes combinações de hiperparâmetros, permitindo explorar adequadamente o espaço de soluções dos modelos LSTM e demais técnicas computacionalmente intensivas avaliadas no estudo.

Essa abordagem garantiu uma exploração rigorosa do espaço de hiperparâmetros, priorizando a robustez e a capacidade preditiva do modelo, com foco em aplicações práticas de previsão de séries temporais. A restrição a uma única camada de neurônio, embora limitasse a profundidade do modelo,

permitiu viabilidade computacional sem comprometer significativamente o desempenho preditivo.

É importante destacar que apenas os modelos SARIMA e LSTM foram configurados para incorporar a variável exógena. Após a definição dos melhores parâmetros para ambos os modelos, sem o uso de variáveis exógenas, esses parâmetros foram usados como ponto de partida para a modelagem com a variável “ração”. Nessa fase, foram realizados ajustes finos nos hiperparâmetros para otimizar o desempenho dos modelos.

RESULTADOS

A otimização dos parâmetros de cada modelo buscou equilibrar complexidade e capacidade de capturar padrões temporais (Tabela 2), sendo que as escolhas refletem-se tanto nas métricas quantitativas quanto na análise visual.

Tabela 2. Parâmetros otimizados dos modelos avaliados nos conjuntos de treino e validação da série temporal do preço do leite UHT no Brasil.

Modelos	Melhores Parâmetros
ETS	trend=add, seasonal=add, seasonal periods=36, initialization method=none
UCM	level=true, trend=false, seasonal=36, autoregressive=none, mle_regression=true, irregular=true, stochastic_level=false, stochastic_trend=true, stochastic_seasonal=false, damped_cycle=true, exog=none
SARIMA	p=11, d=0, q=3, P=1, D=1, Q=1, s=36
SARIMA_Lag (incluindo variável exógena)	p=15, d=0, q=4, P=1, D=1, Q=1, s=36
LSTM	Janela deslizante: 36 meses lstm(50, activation='relu', return_sequences=False) kernel_regularizer=l2(0.001) recurrent_regularizer=l2(0.001))) dropout(0.01) Dense(1) optimizer=Nadam, loss=mean_absolute_error, epochs=500 patience = 20 batch_size=16 validation_split=0,1
LSTM_Lag (incluindo variável exógena)	Janela deslizante: 36 meses lstm(10, activation='tanh', return_sequences=False) kernel_regularizer=l2(0.001)

```

recurrent_regularizer=l2(0.001)))
dropout(0.01)
Dense(1)
optimizer=Adamax, loss=mean_absolute_error,
epochs=500
patience = 20
batch_size=32
validation_split=0,1

```

* ETS: trend = Tendência, seasonal = Sazonalidade, seasonal periods = Período sazonal e initialization method = Método de inicialização; UCM: level = Nível, trend = Tendência, seasonal = Sazonalidade, autoregressive = Componente autorregressivo, mle_regression = Regressão via máxima verossimilhança, irregular = Irregularidade, stochastic_level = Nível estocástico, stochastic_trend = Tendência estocástica, stochastic_seasonal = Sazonalidade estocástica, damped_cycle = Ciclo amortecido e exog = Variáveis exógenas; SARIMA: p = Ordem autorregressiva (AR) não sazonal, d = Ordem de diferenciação não sazonal, q = Ordem de médias móveis (MA) não sazonal, P = Ordem autorregressiva (AR) sazonal, D = Ordem de diferenciação sazonal, Q = Ordem de médias móveis (MA) sazonal, s = Período sazonal; LSTM: lstm(número de neurônios) return_sequences = retorno de sequência ativado, dropout = Camada de dropout, dense= Camada densa, optimizer = Otimizador, loss = Função de perda epochs = Número de épocas , batch_size = Tamanho do lote.

Dentre os modelos sem a variável exógena razão, o SARIMA apresentou o melhor desempenho geral, com MAPE de 4,79% e RMSPE de 6,23%, seguido pelo UCM, que obteve um MAPE de 6,00% e RMSPE de 8,83%. Embora promissor em cenários não lineares, o modelo LSTM alcançou um MAPE de 6,19% e RMSPE de 9,78%, enquanto o modelo ETS teve o pior ajuste, com MAPE de 15,50% e RMSPE de 17,35%.


Tabela 3. Métricas de desempenho dos modelos preditivos do preço do UHT na fase de treino.

	ME	MPE %	MAE	RMSE	RMSPE %	MAPE %
ETS	-0,67	-15,50	0,67	0,81	17,35	15,50
UCM	-0,03	0,20	0,26	0,36	8,83	6,00
SARIMA	-0,01	0,29	0,20	0,25	6,23	4,79
SARIMA_Lag1	0,11	3,25	0,25	0,30	7,31	6,05
SARIMA_Lag2	-0,06	-0,89	0,20	0,26	6,43	4,70
SARIMA_Lag3	0,02	1,06	0,21	0,26	6,49	5,04
SARIMA_Lag4	0,08	2,38	0,22	0,27	6,66	5,23
SARIMA_Lag5	-0,02	0,05	0,23	0,29	7,00	5,47
SARIMA_Lag6	-0,06	-0,89	0,21	0,27	6,64	4,77
LSTM	-0,11	-2,24	0,28	0,39	9,78	6,19
LSTM_Lag1	-0,22	-4,30	0,31	0,48	11,78	6,85

LSTM_Lag2	-0,22	-4,41	0,28	0,45	11,00	6,05
LSTM_Lag3	-0,18	-3,59	0,29	0,45	11,15	6,49
LSTM_Lag4	-0,18	-3,57	0,29	0,45	10,93	6,36
LSTM_Lag5	-0,20	-4,11	0,28	0,46	11,22	6,32
LSTM_Lag6	-0,21	-4,20	0,29	0,46	11,31	6,25

O modelo ETS foi o único a captar todos os pontos abaixo dos valores reais. Já o modelo UCM captou apenas o movimento geral do preço, mas falhou em representar os picos de alta registrados em julho de 2022, janeiro de 2023 e abril de 2023 (Figuras 2 e 3).

Figura 2. Comparação entre valores reais do UHT e previsões do melhor modelo ETS, UCM, SARIMA e LSTM, durante a fase de treino.



Os modelos SARIMA e LSTM conseguiram capturar melhor o pico de julho de 2022, mas também apresentaram limitações nos picos subsequentes de 2023. O modelo LSTM, assim como o SARIMA, foram eficazes em identificar os movimentos de pico e fundo, porém ambos apresentaram um atraso (erro) nas previsões, captando os valores dos picos apenas após a ocorrência destes (Figuras 4 e 5). Essa característica é comum para modelos preditivos que utilizam valores anteriores para prever dados futuros, o que pode resultar em erros nas previsões.

A análise de correlação cruzada entre o preço do leite UHT, o valor pago ao produtor e o custo da ração considerando defasagens de até 15 meses revelou padrões temporais significativos nas interações entre essas variáveis (Figura 6).

Entre o preço do leite UHT e o valor recebido pelo produtor, identificou-se uma correlação positiva moderada e imediata (0,371) entre essas duas variáveis. Contudo, ao analisar defasagens progressivas, a correlação inverteu-se, atingindo um coeficiente negativo de -0,427 após 6 meses. Esse comportamento sugere que, aproximadamente seis meses após variações no preço ao produtor, ocorre uma tendência contrária no preço do leite UHT, refletindo os ajustes de oferta e demanda ao longo da cadeia produtiva.

Embora a correlação identificada não implique em uma relação de causalidade, os resultados sugerem que aumentos no preço pago aos produtores tendem a ser repassados imediatamente aos preços no atacado pelos laticínios. Contudo, ao transferir esses custos para a cadeia de distribuição, os laticínios enfrentam resistência da demanda especialmente de varejistas e consumidores finais, o que limita a absorção dos produtos. Com o tempo, essa dinâmica resulta no acúmulo progressivo de estoques, criando pressões para redução dos preços junto aos fornecedores de leite, em um ciclo retroalimentado de autoajuste.


A correlação entre o preço pago ao produtor e o preço da ração apresenta um padrão temporal distinto: positiva e crescente nas defasagens iniciais, com pico de intensidade após 5 meses. No momento atual (lag 0), a correlação é moderada (0,502), indicando que variações imediatas no custo da ração impactam parcialmente o valor recebido pelos produtores. Esse efeito se intensifica até o lag 5, atingindo 0,588, o que sugere que, após cinco meses, o ajuste nos preços ao produtor reflete integralmente pressões de custos.

Contudo, a partir do *lag* 6, a correlação inicia um declínio gradual, reduzindo-se para 0,351 no *lag* 15. Essa trajetória revela que, embora os produtores respondam rapidamente a custos operacionais diretos (ração), fatores de médio prazo tornam-se mais relevantes, diluindo a influência isolada da ração. Assim, a relação entre as variáveis é mais crítica em horizontes curtos (3-6 meses), período em que ajustes de preços são essenciais para manter a viabilidade econômica das propriedades.

A correlação direta entre o preço do leite UHT e o preço da ração é fraca e negativa, com coeficientes estatisticamente insignificantes ($p > 0,05$) em todas


as 15 defasagens analisadas. Isso indica que não há uma relação linear robusta ou imediata entre essas variáveis. No entanto, o preço da ração impacta diretamente os custos de produção, pressionando o valor pago aos produtores, variável intermediária que, por sua vez, afeta a oferta de leite. Quando os custos da ração se elevam, produtores podem reduzir o rebanho ou a produção, restringindo a oferta e gerando pressões inflacionárias indiretas sobre o preço do UHT no atacado. Assim, embora a correlação direta seja limitada, a ração atua como um fator indireto na formação do preço final, mediado por ajustes na cadeia produtiva.

Figura 3. Evolução das correlações temporais entre o preço do leite UHT, preço pago ao produtor e preços da ração ao longo das defasagens.




Em alguns modelos não são observadas melhorias nas métricas de desempenho quando a variável ração e suas respectivas defasagens são incorporadas. Ao comparar o modelo SARIMA com a configuração SARIMA_Lag2 (Figura 2), observa-se que a diferença nas métricas é bastante reduzida, com uma variação de apenas 0,09 pontos percentuais no MAPE e aumento de 0,20 no RMSPE. Esses resultados sugerem que, para o modelo ARIMA, a inclusão da variável exógena defasada não resulta em um ganho substancial de desempenho. No modelo LSTM, especificamente na configuração LSTM_Lag2, observou-se uma redução de apenas 0,14 no MAPE.

Figura 4. Comparação entre valores reais do UHT e previsões do melhor modelo com defasagens (SARIMA_Lag2, SARIMA_Lag6, LSTM_Lag2) durante a fase de treino.




Na seção de validação, o modelo SARIMA apresentou o melhor desempenho geral, destacando-se com o menor valor de MAPE (7,39%) e RMSPE (9,51%), evidenciando melhor eficácia na captura dos padrões da série temporal. O modelo ETS, por sua vez, apresentou resultados intermediários, com valores de MAPE (8,45%) e RMSPE (10,78%) e ligeiramente piores aos do SARIMA. O modelo UCM obteve desempenho comparável ao ETS, MAPE (8,56%) e RMSPE (10,85%), sugerindo que ambos os métodos identificaram padrões na série com precisão moderada, sendo ligeiramente piores que valores obtidos pelo SARIMA. A proximidade nos valores de MAPE entre ETS (-0,37) e UCM (-0,38) reforça a similaridade de desempenho e o viés equilibrado desses modelos.

Figura 5. Comparação entre valores observados do UHT e previsões dos melhores modelos (SARIMA, LSTM, UCM, ETS) durante a fase de validação.



O modelo LSTM apresentou desempenho inferior em relação aos demais modelos, com valores mais elevados de RMSPE (11,54%) e MAPE (9,80%), indicando que, mesmo com sua capacidade de aprendizado não linear, o modelo não foi suficientemente eficaz em capturar os padrões da série. Uma explicação plausível para esse desempenho inferior do LSTM está na abordagem de previsão utilizada, baseada na técnica *one-step-ahead* (Figura 6). Nessa abordagem, o valor predito em cada etapa é realimentado no modelo para gerar a previsão subsequente, simulando condições reais de uso. Apesar de reproduzir fielmente um cenário prático, essa estratégia acumula erros a cada interação, impactando negativamente o desempenho geral, sobretudo em séries temporais com alta variabilidade e padrões complexos.

Figura 6. Estratégia de Previsão com Janela Deslizante em Séries Temporais.



* Conceito de previsão: o conjunto de dados de treinamento utiliza os 36 primeiros passos de tempo da série temporal (ex.: jan-2021 a dez-2023), enquanto o conjunto de validação abrange os 36 passos seguintes (ex.: fev-2021 a jan-2024). As variáveis dos 36 passos iniciais são usadas como entrada, e o último passo como valor de referência. O objetivo do conjunto de treinamento é realizar previsões até 2023. Previsões após 2024 utilizam uma estratégia de janela deslizante, em que previsões anteriores são incorporadas ao treinamento.

Os resultados evidenciam uma limitação crítica na modelagem de séries temporais com redes neurais: enquanto muitos estudos enfatizam a otimização do treinamento, frequentemente negligenciam os desafios impostos para realizar previsões reais. Assim, embora o LSTM tenha se mostrado promissor no treino, os resultados da validação destacam a necessidade de estratégias mais robustas para lidar com a propagação de erros e garantir a consistência das previsões em cenários práticos.

Ao incorporar variáveis explicativas exógenas com defasagens (lags), os modelos apresentaram resultados heterogêneos. Os modelos SARIMA tiveram uma performance inferior quando variáveis exógenas foram incluídas, em

comparação com a abordagem que não as utilizou. Isso pode ser explicado por diversos fatores. Primeiramente, a inclusão de defasagens pode introduzir ruídos e redundância informacional, especialmente se os lags selecionados não capturam de maneira adequada a dinâmica real entre as variáveis. Além disso, essa estratégia pode ocasionar problemas de multicolinearidade e sobreparametrização, dificultando, pelo modelo, o isolamento do efeito preditivo real das variáveis externas.

Outro ponto a ser considerado é que o modelo SARIMA é caracterizado por ser linear e estacionário. Quando variáveis exógenas não seguem essas características, ao serem adicionadas ao modelo, elas geram distorções que podem prejudicar sua performance.


Tabela 4. Desempenho dos modelos preditivos em séries temporais: resultados das métricas de erro na fase de validação.

	ME	MPE %	MAE	RMSE	RMSPE %	MAPE %
ETS	-0,37	8,18	0,38	0,50	10,78	8,45
UCM	-0,38	8,46	0,38	0,50	10,85	8,56
SARIMA	-0,18	3,73	0,34	0,45	9,51	7,39
SARIMA_Lag1	-0,25	5,33	0,38	0,49	10,36	8,30
SARIMA_Lag2	-0,28	6,13	0,39	0,50	10,59	8,59
SARIMA_Lag3	-0,27	5,82	0,38	0,49	10,39	8,40
SARIMA_Lag4	-0,20	4,19	0,35	0,46	9,85	7,73
SARIMA_Lag5	-0,30	6,64	0,40	0,51	10,92	8,93
SARIMA_Lag6	-0,31	6,74	0,39	0,51	10,86	8,66
LSTM	-0,35	7,97	0,43	0,50	11,54	9,80
LSTM_Lag1	-0,30	-6,86	0,31	0,42	9,73	6,98
LSTM_Lag2	-0,36	-8,16	0,39	0,49	11,39	8,83
LSTM_Lag3	-0,37	-8,34	0,37	0,48	11,13	8,39
LSTM_Lag4	-0,30	-6,58	0,35	0,46	10,68	7,70
LSTM_Lag5	-0,41	-9,29	0,43	0,52	12,16	9,65
LSTM_Lag6	-0,37	-8,38	0,39	0,49	11,34	8,72

Nos modelos LSTM, o uso de variáveis exógenas demonstrou resultados superiores. Em todas as defasagens analisadas, as métricas de desempenho nas previsões de validação melhoraram. O destaque foi o modelo LSTM_Lag1, que registrou um MAPE de 6,98%, quase três pontos percentuais abaixo do modelo sem defasagens, porém sem uma redução grande em relação ao RMSPE. Já o modelo LSTM_Lag5 apresentou alteração mínima, com variação

de apenas 0,15 pontos para o MAPE e para o RMSPE em 0,62. Isso destaca a capacidade dos modelos LSTM de extraírem informações relevantes de dados exógenos à estrutura da série temporal com a finalidade de melhorar a capacidade preditiva.

Figura 7. Comparação entre valores reais do UHT e previsões do melhor modelo com uso de diferentes defasagens (SARIMA_Lag1, SARIMA_Lag4, LSTM_Lag1, LSTM_Lag4) durante a fase de validação.



A inclusão de variáveis exógenas nos modelos impõe um desafio prático adicional: durante a validação, as projeções da variável de interesse dependem diretamente das projeções das próprias variáveis exógenas. No entanto, o uso de variáveis exógenas defasadas mitiga essa dificuldade, uma vez que seus valores futuros são seus próprios valores defasados. Por exemplo, um modelo com defasagem de quatro períodos nas variáveis exógenas permite realizar previsões para os próximos quatro meses sem a necessidade de projeções adicionais para essas variáveis.

A incorporação de variáveis exógenas e defasagens ao modelo LSTM elevou significativamente seu desempenho. Entretanto, uma das principais limitações está associada à estruturação dos dados, que utiliza uma janela deslizante que divide a série temporal em intervalos, em contraste com modelos tradicionais, que operam com a série histórica completa, sem divisões. Essa diferença metodológica pode gerar uma comparação desigual entre as abordagens, visto que o número de informações fornecidos a cada modelo é diferente.

A expectativa de que modelos de IA teriam desempenho superior com a mesma quantidade de dados é válida, porém a modelagem mais “justa” (com igualdade de dados) não foi viável devido à natureza intrínseca de cada técnica. O uso da janela deslizante é essencial para o LSTM, pois permite capturar dependências temporais locais e padrões sequenciais, algo inviável de ser replicado em modelos tradicionais sem comprometer sua arquitetura original. Por outro lado, padronizar os dados para todos os modelos sob a mesma estrutura exigiria descaracterizar a abordagem do LSTM, eliminando sua capacidade de aprender relações temporais complexas. Assim, optou-se por respeitar as especificidades metodológicas de cada modelo, ainda que isso implicasse uma assimetria na base comparativa. Essa decisão priorizou a integridade das técnicas em detrimento de uma comparação equilibrada, mantendo a viabilidade prática da aplicação em contextos reais.

Uma das limitações deste trabalho se refere à elevada demanda computacional exigida pelos modelos LSTM, especialmente devido à complexidade inerente à arquitetura e ao processamento sequencial. Além disso, a multiplicidade de opções de hiperparâmetros (como número de camadas, tamanho da janela temporal e taxa de aprendizado) e configurações de arquitetura disponíveis introduz um desafio significativo na seleção da combinação ideal. Essa ampla gama de possibilidades, somada à limitação de recursos computacionais, pode impedir a realização de testes exaustivos para otimização do modelo, resultando em configurações subótimas que, potencialmente, limitam o desempenho final. Assim, a dificuldade em equilibrar a exploração de parâmetros com a viabilidade técnica pode ser um fator determinante para que o modelo não atinja resultados mais robustos.

DISCUSSÃO

A previsão de preços de produtos lácteos, como o leite UHT, é um tema que ainda apresenta uma limitação significativa de estudos na literatura. Diferentemente de ativos financeiros ou commodities amplamente estudados, como preço de ações, petróleo, criptomoedas ou energia (Alizadegan et al., 2025; Song et al., 2024; Zhao et al., 2024; Kanaparthi et al., 2024), os preços do leite e seus derivados receberam menos atenção, especialmente no que diz respeito ao uso de modelos preditivos avançados.

A comparação dos resultados deste estudo com pesquisas anteriores revela nuances críticas na aplicação de modelos preditivos para séries temporais agrícolas. No contexto indonésio, Ghiffary et al. (2025) observaram desempenho superior do SARIMA sobre o LSTM na previsão de importações de laticínios, mesmo em séries não estacionárias. Esse alinhamento com nossos achados sugere que a eficácia do SARIMA pode estar menos vinculada à estacionalidade estrita ou normalidade dos resíduos e mais relacionada à sua capacidade de decompor padrões sazonais e tendências dominantes, mesmo em séries com heterogeneidade estrutural. No caso do leite UHT brasileiro, embora a série não seja estacionária e os resíduos violem pressupostos de normalidade, a forte sazonalidade intrínseca ao setor lácteo associada a ciclos de produção, períodos de entressafra e demandas regulares parece ter sido adequadamente capturada pelo componente sazonal do SARIMA ($s=36$), mitigando parcialmente os efeitos da não estacionalidade.

A divergência entre os resultados de Kumar et al. (2025) e os achados deste estudo oferece uma reflexão crítica sobre a influência da natureza das séries temporais no desempenho dos modelos. No estudo de Kumar et al. (2025), que analisou preços da batata na Índia, o LSTM superou o SARIMA na validação (MAPE: 7,99% vs. 24,40%), apesar do SARIMA ter tido desempenho ligeiramente melhor no treino (MAPE: 6,37 vs. 6,55). Esse fenômeno pode ser atribuído à dinâmica intrínseca do mercado de batatas. Nesse contexto, a capacidade do LSTM de adaptar-se a relações dinâmicas e capturar dependências de longo prazo, mesmo com erros acumulados, mostrou-se vantajosa fora da amostra.

Já no estudo de Kurnadipare et al. (2025), o qual comparou o desempenho entre os modelos SARIMA e LSTM para prever o valor das exportações do setor agrícola, constatou-se que o modelo LSTM demonstrou melhor desempenho, apresentando um erro quadrático médio (RMSE) significativamente menor em comparação ao SARIMA (1939.02 contra 4182.133). Isso indica que o LSTM conseguiu captar padrões mais complexos e fornecer previsões mais precisas.

No estudo de Veverita (2023), em que se analisou a previsão do consumo de energia na Holanda e na Moldávia, utilizando variáveis exógenas

(preços de energia, inflação e condições climáticas), o modelo LSTM superou o SARIMAX em ambos os países: na Holanda, com RMSE de 205,72 contra 991,89 do SARIMAX, evidenciando maior capacidade de capturar padrões não lineares e sensibilidade a mudanças externas. Na Moldávia, o LSTM manteve vantagem, porém com diferença menor (RMSE de 18,81 versus 43,10), reforçando sua eficácia em sistemas energéticos complexos e dinâmicos.

Essa variação no desempenho entre os estudos reflete as diferenças estruturais das séries temporais analisadas. A discussão ganha profundidade ao integrar análises de séries financeiras. He et al. (2023), ao estudarem mercados eficientes, destacaram que modelos complexos, como LSTM e CNN, falham em superar métodos simples como o Random Walk. De forma semelhante, em nossa pesquisa, o modelo LSTM não superou o SARIMA, sugerindo que, para determinados conjuntos de dados, modelos mais simples podem ser suficientes e até mais eficazes do que abordagens mais complexas.

CONCLUSÃO

A análise comparativa entre modelos econométricos tradicionais e técnicas de aprendizado de máquina revelou que, em séries temporais com padrões sazonais não lineares, como os preços do leite UHT, abordagens clássicas, em especial o SARIMA, demonstraram maior eficácia preditiva. Essa superioridade foi observada de forma consistente nas fases de treinamento e validação (previsão fora da amostra). Por outro lado, a inclusão de variáveis exógenas, como o custo da ração, não gerou melhorias significativas no desempenho do SARIMA, chegando inclusive a prejudicá-lo. Já para os modelos LSTM, a inclusão dessas variáveis exógenas resultou em melhorias relevantes em todas as seis defasagens testadas, permitindo-lhes superar o desempenho do SARIMA na fase de validação. Assim, o estudo evidencia que a complexidade inerente às redes neurais recorrentes nem sempre se traduz em vantagens práticas, sobretudo quando as relações temporais são lineares e sujeitas a uma sazonalidade previsível. A principal contribuição desta pesquisa reside na demonstração de que a escolha de modelos preditivos deve ser guiada pelas características intrínsecas dos dados, pelo contexto setorial e pela disponibilidade de capacidade computacional.

Um dos pontos críticos para os modelos de aprendizado de máquina está relacionado à otimização insuficiente dos hiperparâmetros e à impossibilidade de implementar arquiteturas mais complexas (com mais camadas ocultas), devido a restrições técnicas de processamento. Esse resultado evidencia a importância de considerar o desempenho nos dados de validação para avaliar a eficácia do modelo em condições práticas. Embora um modelo possa apresentar bons resultados no treino, é a validação que confirma sua capacidade de fazer previsões consistentes e confiáveis da série temporal.

REFERÊNCIAS

Alba, D.; Muñoz-Zavala, A. E. A comparison between SARIMA models and Feed Forward Neural Network Ensemble Models for Time Series Data. *Research in Computing Science*, v. 92, n. 1, p. 9–22, 31 dez. 2015.

Alizadegan, H; Malki, B.R; Radmehr, A; Karimi, H; Ilani, M.A. Comparative study of long short-term memory (LSTM), bidirectional LSTM, and traditional machine learning approaches for energy consumption prediction. *Energy Exploration & Exploitation*, v. 43, n. 1, p. 281–301, jan. 2025.

Ghiffary, G.G; Yanuari, E.D.D; Notodiputro, K.A; Angraini, Y; Mualifah, L.N.A. Comparative performance of sarimax and lstm model in predicting import quantities of milk, butter, and eggs. *Barekeng: jurnal ilmu matematika dan terapan*, v. 19, n. 1, p. 407–418, 13 jan. 2025.

He, k; Yang, Q; Ji, L; Pan, J; Zou, Y. Financial time series forecasting with the deep learning ensemble model. *Mathematics*, v. 11, n. 4, p. 1054, 20 fev. 2023.

IBGE. Pesquisa da pecuária municipal. 2023b. Disponível em: <https://sidra.ibge.gov.br/pesquisa/ppm/quadros/brasil/2022>. Acesso em: 5 dez. 2023.

Jammeh, L.B; Guobadia, E.K; Ugoh, C.I. Exponential Smoothing State Space Innovation Model for Forecasting Export Commodity Price Index in Nigeria. *African Journal of Economics and Sustainable Development*, v. 6, n. 4, p. 74–84, 23 nov. 2023.

Kanaparthi, V. Robustness Evaluation of LSTM-based Deep Learning Models for Bitcoin Price Prediction in the Presence of Random Disturbances. *International Journal of Innovative Science and Modern Engineering*, v. 12, n. 2, p. 14–23, 28 fev. 2024.

Kaur, S. Time Series Analysis of Average Retail Price of Milk with Autoregressive Integrated Moving Average in R. v. 04, n. 04, 2018.

Kmytiuk, T; Majore, G; Bilyk, T. Time series forecasting of price of the agricultural products using data science. *Agricultural and Resource Economics: International Scientific E-Journal*, v. 10, n. 3, p. 5–33, 20 set. 2024.

Krasniqi, F; Kamberi, M.A; Kastrati, R; Emiri-Sallaku, E; Tafaj, M. The Impact of Feeding Factors on Holstein Dairy Farms Costs in Kosovo. *Turkish Journal of Agriculture - Food Science and Technology*, v. 6, n. 9, p. 1175–1183, 11 set. 2018.

Kuhn, M; Johnson, K. *Applied Predictive Modeling*. New York, NY: Springer New York, 2013.

Kumar, R; Lad, Y.A; kumari, P. Forecasting potato prices in agra: comparison of linear time series statistical vs. Neural network models. *Potato research*, 13 jan. 2025.

Kurnadipare, A.I; Amaliya, S; Notodiputro, K.A; Angraini, Y; Mualifah, L.N.A. Comparing forecasts of agricultural sector export values using sarima and long short-term memory models, vol. 19, no. 1, pp. 385-396, Jan. 2025.

Kurumatani, K. Time series forecasting of agricultural product prices based on recurrent neural networks and its evaluation method. *SN Applied Sciences*, v. 2, n. 8, p. 1434, ago. 2020.

Ozbayoglu, A. M.; Gudelek, M. U.; Sezer, O. B. Deep Learning for Financial Applications : A Survey. *arXiv*, 9 fev. 2020. Disponível em: <<http://arxiv.org/abs/2002.05786>>. Acesso em: 24 jan. 2025.

Scalco, P. R; Braga, M. J. Identification of market power in bilateral oligopoly: the brazilian wholesale market of uht milk. 2015.

Sezer, O. B; Gudelek, M. U; Ozbayoglu, A. M. Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. *Applied Soft Computing*, v. 90, p. 106181, 2020.

Shantal, M; Othman, Z; Bakar, A. A. A Novel Approach for Data Feature Weighting Using Correlation Coefficients and Min–Max Normalization. *Symmetry*, v. 15, n. 12, p. 2185, 11 dez. 2023.

Shao, Y. Time Series Analysis of Grains Commodity Futures Price Trends. *Highlights in Science, Engineering and Technology*, v. 92, p. 20–31, 10 abr. 2024.

Simões, A. R. P; Nicholson, C. F; Carvalho, G. R. Components of farm milk price behavior in Brazil from 2005 to 2020. *Revista Brasileira de Zootecnia*, v. 52, p. e20220116, 14 jul. 2023.

Song, J; Cheng, Q; Bai, X; Jiang, W; Su, G. LSTM-Based Deep Learning Model for Financial Market Stock Price Prediction. 14 abr. 2024.

Sun, C; Pei, M; Cao, B; Chang, S; Si, H. A Study on Agricultural Commodity Price Prediction Model Based on Secondary Decomposition and Long Short-Term Memory Network. *Agriculture*, v. 14, n. 1, p. 60, 28 dez. 2023.

Tami, M; Owda, A. Y. Efficient commodity price forecasting using long short-term memory model. *IAES International Journal of Artificial Intelligence (IJ-AI)*, v. 13, n. 1, p. 994, 1 mar. 2024.

Veverita, V. LSTM Modelling for Energy Prediction in the Current Global Context, University of Twente, Faculty of Electrical Engineering, Mathematics and Computer Science, 2023.

Vilela, E.H.P; Penedo, A.S.T. Previsão do comportamento dos preços do leite usando modelos arima e sarima. 2024.

Yamakawa, F.M; Magnani, V.M; Gatsios, R.C; Ambrozini, M.A. Analysis of the relationship between futures market instruments and the spot market. Revista de gestão e secretariado (management and administrative professional review), v. 14, n. 5, p. 8041–8060, 2023.

Zhao, Y; Hu, B; Wang, S. Prediction of Brent crude oil price based on LSTM model under the background of low-carbon transition. 2024.

Este artigo está elaborado nas normas da Milkpoint.

CAPÍTULO 3 – ARTIGO TÉCNICO POPULAR (ATP)

Título: Previsão de preços para a cadeia de lácteos no Brasil utilizando machine learning

Autores: M. S. Roschel ^{1*}, A. R. P. Simões ¹

¹Universidade Estadual do Mato Grosso do Sul, Zootecnia

* Autor correspondente: marcelo_roschel@hotmail.com

Introdução

O preço do leite no Brasil é essencialmente formado em um mercado de livre concorrência e é afetado complexamente por variáveis locais e globais relativos aos custos de produção, escolhas do consumidor, variações cambiais e fatores climáticos (FAO, 2025). Após a desregulamentação iniciada em 1991, que substituiu controles rígidos por maior abertura de mercado, houve avanço em tecnologias e aumento de produtividade, mas também aumento na oscilação dos preços recebidos pelos produtores. Essa liberalização trouxe benefícios em eficiência e inovação, entretanto expôs o setor a flutuações mais acentuadas, exigindo dos agentes maior capacidade de adaptação a choques externos e variações de mercado.

Entender como os preços se formam e como as mudanças em uma região afetam outras é crucial. Esse conhecimento é a base para criar políticas que estabilizem o mercado, ajudem produtores e indústrias a gerenciar riscos e

planejar melhor a logística (como transporte e armazenamento). Saber os padrões de oscilação passada ("volatilidade histórica") e como os mercados de diferentes regiões estão conectados ("integração espacial") é essencial para desenvolver ferramentas de proteção contra essas variações bruscas (Hayashi, 2017).

Contudo, prever o preço futuro do leite não é tarefa simples. Ele não depende apenas da oferta e demanda imediatas, mas também de tendências econômicas mais amplas, cenários políticos, valorização de ativos e dinâmicas financeiras complexas, o que torna projeções simplistas pouco eficazes (Yamakawa et al., 2023). Nesse contexto, empregar métodos estatísticos e de aprendizado de máquina para aprimorar a formação de preços de produtos lácteos se apresenta como uma estratégia valiosa.

Na vertente estatística, destacam-se modelos como ETS (Erro, Tendência e Sazonalidade), que decompõe a série em componentes básicos para revelar padrões recorrentes, e UCM (Unobserved Components Model), que busca capturar elementos subjacentes não observáveis diretamente, como tendências estocásticas e ciclos latentes. Além desses, técnicas consolidadas como ARIMA (Autorregressivo Integrado de Médias Móveis) e sua versão sazonal SARIMA são amplamente usadas para séries em que há padrões recorrentes em intervalos fixos (Brockwell et al., 2016).

O avanço de poder computacional impulsionou o uso de métodos de aprendizado de máquina, especialmente redes neurais recorrentes (RNNs), concebidas para lidar com dependências ao longo do tempo. Entre elas, o modelo LSTM (Long Short-Term Memory) se destaca por reconhecer padrões não lineares em sequências, lidar com ruídos e processar grandes volumes de dados, sem exigir pressupostos rígidos sobre sazonalidade ou linearidade dos processos subjacentes. Essas características tornam as RNNs atraentes para mercados dinâmicos, como o setor lácteo, em que choques externos imprevisíveis e interações complexas frequentemente limitam a eficácia de modelos tradicionais (Sezer; Gudelek; Ozbayoglu, 2020).

O objetivo deste estudo é realizar previsões do preço do leite em mercados competitivos, comparando a capacidade preditiva de modelos econométricos tradicionais e de *machine learning*.

Materiais e métodos

Os dados foram obtidos na plataforma do Centro de Estudos Avançados em Economia Aplicada (CEPEA) e englobam duas séries temporais que fundamentam a análise. A primeira série refere-se aos preços mensais do leite UHT, praticados pelos laticínios, cobrindo de janeiro de 2005 a setembro de 2024. A segunda série reúne os preços do milho e da soja no mercado nacional, combinados em média ponderada de 60% para milho e 40% para soja, gerando a variável ração no período de março de 2006 a agosto de 2024.


Para testar a influência do preço da ração nas previsões, aplicou-se análise de correlação cruzada entre as séries, buscando defasagens temporais plausíveis em que a variação do custo de insumos repercutiria no preço do leite UHT. Essa etapa auxilia a identificar após quantos meses a oscilação na ração tende a impactar o mercado de leite, sem pretender inferir causalidade plena nem capturar todos os choques externos, mas sim adicionar contexto econômico relevante aos modelos.

No pré-processamento, as séries foram deflacionadas pelo Índice Geral de Preços Mercado (IGP-M) para eliminar efeitos de inflação e garantir comparabilidade ao longo do tempo. Em seguida, todas as variáveis passaram por normalização via Min-Max Scaler no intervalo $[0, 1]$, procedimento que reduz discrepâncias de escala entre dados heterogêneos e facilita a convergência de algoritmos de previsão (Shantal et al., 2023).

Quatro abordagens preditivas foram comparadas para estimar o preço do leite UHT: ETS (Error, Trend, Seasonality), UCM (Unobserved Components Model), SARIMA (Seasonal Autoregressive Integrated Moving Average) e rede neural LSTM (Long Short-Term Memory).

A divisão dos dados em conjuntos de treino, teste e validação considerou as particularidades de cada modelo. Para as abordagens univariadas (sem ração), o período de treino foi de janeiro de 2005 a dezembro de 2021, com teste de janeiro de 2022 a dezembro de 2023 e validação a partir de janeiro de 2024.

Figura 8. Divisão da série temporal do preço do leite UHT no Brasil durante o período de janeiro de 2005 a dezembro de 2023 nas seções de treino, teste e validação.



Para modelos com variável exógena, o treino iniciou em setembro de 2006 (primeiro dado disponível de ração) até dezembro de 2021, mantendo-se as mesmas janelas de teste e validação. A fase de teste teve o propósito de selecionar o modelo que melhor se ajustasse aos dados históricos, enquanto a etapa de validação simulou cenário real de uso, avaliando a capacidade preditiva sem novos ajustes de parâmetros.

Para o modelo LSTM, empregou-se uma abordagem de janelas deslizantes de 36 meses visando capturar sazonalidade e tendências de longo prazo, prevendo o valor do mês seguinte. Essa configuração permite ao modelo explorar dependências temporais complexas entre observações passadas e o próximo ponto da série, incluindo variáveis exógenas quando pertinente.

A avaliação dos modelos utilizou seis métricas (ME, MPE, MAE, RMSE, RMSPE e MAPE) para fornecer visão abrangente sobre erros absolutos, percentuais e quadráticos (Kuhn; Johnson, 2013). Cada método (ETS, UCM, SARIMA e LSTM) teve sua própria rotina de otimização de parâmetros, com foco em minimizar o MAPE no treino.


Resultados

A otimização dos parâmetros de cada modelo buscou equilibrar complexidade e capacidade de capturar padrões temporais, sendo que as escolhas se refletem tanto nas métricas quantitativas quanto na análise visual.

Na fase de treino, os modelos sem a variável exógena ração, o SARIMA apresentou o melhor desempenho geral, com MAPE de 4,79% e RMSPE de 6,23%, seguido pelo UCM, que obteve um MAPE de 6,00% e RMSPE de 8,83%. Embora promissor em cenários não lineares, o modelo LSTM alcançou um MAPE de 6,19% e RMSPE de 9,78%, enquanto o modelo ETS teve o pior ajuste, com MAPE de 15,50% e RMSPE de 17,35%.

Ainda na fase de treino, a análise visual (Figura 2) indicou que o modelo ETS foi o único a captar todos os pontos abaixo dos valores reais. Já o modelo UCM captou apenas o movimento geral do preço, mas falhou em representar os picos de alta registrados em julho de 2022, janeiro de 2023 e abril de 2023 os modelos SARIMA e LSTM mostraram capacidade de identificar o pico de preços registrado em julho de 2022, mas também revelaram limitações ao lidar com picos ocorridos em 2023, apresentando atraso (erros) nas previsões que só refletiam os valores máximos após sua efetiva ocorrência. Esse comportamento decorre da própria lógica de previsão baseada em históricos: como ambos dependem de observações anteriores para gerar estimativas futuras, tornam-se sensíveis a mudanças repentinas e tendem a “acompanhar” o movimento em vez de antecipá-lo completamente.

Figura 9. Comparação entre valores reais do UHT e previsões do melhor modelo ETS, UCM, SARIMA e LSTM, durante a fase de treino.



A análise de correlação cruzada entre o preço do leite UHT e o preço da ração mostrou-se fraca e estatisticamente não significativa em todas as defasagens analisadas ($p > 0,05$), o que sugere ausência de relação linear imediata entre esses dois indicadores. Ainda assim, a ração influencia

indiretamente o preço final: ao elevar os custos de produção, ela pressiona inicialmente o valor pago ao produtor variáveis intermediária que, ao afetar a oferta de leite, pode levar a reduções na produção ou ajuste no rebanho.

Essas mudanças na oferta, por sua vez, tendem a repercutir no preço do UHT no atacado, mesmo que essa cadeia de efeitos não se reflita em correlação imediata e direta. Assim, o papel da ração na formação de preço aparece como um fator indireto, mediado por respostas dos produtores e pela dinâmica de oferta ao longo do tempo.

Em alguns modelos, a inclusão do preço da ração e suas defasagens não trouxe melhorias relevantes nas métricas de previsão. Ao comparar o SARIMA padrão com a configuração SARIMA_Lag2, a variação no MAPE foi de apenas 0,09 ponto percentual e o RMSPE aumentou em 0,20, indicando ganho insignificante ao incorporar essa exógena para o modelo ARIMA. No LSTM, a configuração LSTM_Lag2 também apresentou redução mínima no MAPE, de apenas 0,14 ponto.

Na fase de validação, o SARIMA manteve-se como o mais eficaz, com MAPE de 7,39% e RMSPE de 9,51%, capturando com maior precisão os padrões observados. O ETS ficou em posição intermediária, com MAPE de 8,45% e RMSPE de 10,78%, seguido de perto pelo UCM, com MAPE de 8,56% e RMSPE de 10,85%, mostrando desempenho similar e viés equilibrado. O LSTM teve os valores mais altos de erro na validação (MAPE de 9,80% e RMSPE de 11,54%), sugerindo que, apesar de sua capacidade de modelar relações não lineares, não conseguiu superar os modelos tradicionais nesse contexto.


Uma justificativa para o desempenho inferior do LSTM está na estratégia de previsão one-step-ahead: a cada etapa, o valor previsto é realimentado para estimar o próximo ponto, simulando o uso prático, mas acumulando erros sucessivos. Em séries com alta variabilidade e picos inesperados, essa acumulação tende a degradar a precisão ao longo do horizonte de previsão, o que explica em parte por que o LSTM, mesmo bem calibrado, não apresentou vantagem considerável sobre métodos mais simples neste estudo.

Ao incluir variáveis exógenas com defasagens em SARIMA, observa-se desempenho heterogêneo ou piora, pois lags podem adicionar ruído ou

informações redundantes, e gerar multicolinearidade (quando variáveis exógenas correlacionam-se entre si) e sobreajuste.

Nos modelos LSTM, o uso de variáveis exógenas demonstrou resultados superiores. Em todas as defasagens analisadas, as métricas de desempenho nas previsões de validação melhoraram. O destaque foi o modelo LSTM_Lag1, que registrou um MAPE de 6,98%, quase três pontos percentuais abaixo do modelo sem defasagens, porém sem uma redução grande em relação ao RMSPE. Já o modelo LSTM_Lag5 apresentou alteração mínima, com variação de apenas 0,15 pontos para o MAPE e para o RMSPE em 0,62. Isso destaca a capacidade dos modelos LSTM de extraírem informações relevantes de dados exógenos à estrutura da série temporal com a finalidade de melhorar a capacidade preditiva.

Figura 10. Comparação entre valores reais do UHT e previsões do melhor modelo com uso de diferentes defasagens (SARIMA_Lag1, SARIMA_Lag4, LSTM_Lag1, LSTM_Lag4) durante a fase de validação.



O uso de variáveis exógenas melhorou o desempenho do LSTM. No entanto, destaca uma diferença importante: o LSTM usa janelas deslizantes, ou seja, divide a série temporal em blocos menores, enquanto modelos tradicionais analisam a série como um todo. Isso impede uma comparação totalmente justa, já que adaptar os modelos clássicos para imitar essa estrutura mudaria seu funcionamento. Por outro lado, retirar as janelas do LSTM comprometeria sua capacidade de captar padrões temporais locais.

Conclusão

Uma análise comparativa entre modelos econométricos tradicionais e técnicas de inteligência artificial revelou que, em séries temporais com padrões

sazonais não lineares, como os preços do leite UHT, abordagens clássicas, em especial o SARIMA, demonstraram maior eficácia preditiva. Essa superioridade foi observada de forma consistente nas fases de treinamento e validação (previsão fora da amostra). Por outro lado, a inclusão de variáveis exógenas (como o custo da ração) não apenas deixou de gerar melhorias significativas para o SARIMA, como chegou a comprometer seu desempenho. Já nos modelos LSTM, melhorias relevantes ocorreram em todas as seis defasagens testadas, que superou o SARIMA na fase de validação.

Assim, o estudo evidencia que a complexidade inerente às redes neurais recorrentes nem sempre se traduz em vantagens práticas, sobretudo quando as relações temporais são lineares e sujeitas a uma sazonalidade previsível. A principal contribuição desta pesquisa reside na demonstração de que a escolha de modelos preditivos deve ser guiada pelas características intrínsecas dos dados, pelo contexto setorial e pela disponibilidade de capacidade computacional.

Um dos pontos críticos para os modelos de IA está relacionado à otimização insuficiente dos hiperparâmetros e à impossibilidade de implementar arquiteturas mais complexas (com mais camadas ocultas), devido a restrições técnicas de processamento. Esse resultado evidencia a importância de considerar o desempenho nos dados de validação para avaliar a eficácia do modelo em condições práticas. Embora um modelo possa apresentar bons resultados no treino, é a validação que confirma sua capacidade de fazer previsões consistentes e confiáveis da série temporal.

Referências

Brockwell, P. J; Davis R. A. Introduction to Time Series and Forecasting, 2nd edition. New York: Springer, 2002.

FAO, Food and Agriculture Organization of the United Nations. FAO STAT. Disponível em: <https://www.fao.org/home/en> , Acesso em: 20 de maio 2025, 2025.

HAYASHI, A. H. Processo para predição de preços das ações no mercado financeiro com uso de Big Data. 2017. 90 f. Dissertação (Mestrado) - Curso de Engenharia de Computação: Redes de Computadores, Instituto de Pesquisas Tecnológicas do Estado de São Paulo, São Paulo, 2017.

Kuhn, M; Johnson, K. Applied Predictive Modeling. New York, NY: Springer New York, 2013.

Sezer, O. B; Gudelek, M. U; Ozbayoglu, A. M. Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. *Applied Soft Computing*, v. 90, p. 106181, 2020.

Shantal, M; Othman, Z; Bakar, A. A. A Novel Approach for Data Feature Weighting Using Correlation Coefficients and Min–Max Normalization. *Symmetry*, v. 15, n. 12, p. 2185, 11 dez. 2023.

Yamakawa, F.M; Magnani, V.M; Gatsios, R.C; Ambrozini, M.A. Analysis of the relationship between futures market instruments and the spot market. *Revista de gestão e secretariado (management and administrative professional review)*, v. 14, n. 5, p. 8041–8060, 2023.

CAPÍTULO 4 – CONSIDERAÇÕES FINAIS

Os resultados deste estudo evidenciaram nuances críticas na capacidade preditiva de modelos econométricos tradicionais e de inteligência artificial para prever o preço do leite UHT em mercados competitivos. O modelo SARIMA destacou-se como o mais eficaz, com menor MAPE (7,39%) e RMSPE (9,51%) na fase de validação, demonstrando robustez na captura de padrões sazonais e tendências lineares. Em contraste, o modelo LSTM, embora promissor em cenários não lineares, apresentou desempenho inferior na validação (MAPE de 9,80%), possivelmente devido à acumulação de erros na estratégia *one-step-ahead* e à alta complexidade computacional inerente à sua arquitetura.

Podendo ser explicados pelas características intrínsecas das séries temporais analisadas. O desempenho superior do SARIMA decorre de sua eficácia em capturar sazonalidades claras e padrões lineares, típicos do mercado lácteo brasileiro, caracterizado por ciclos produtivos bem definidos e relativamente previsíveis. Por outro lado, os modelos LSTM, apesar de mais complexos e adaptáveis, tiveram desempenho prejudicado pela volatilidade inerente ao método de previsão passo a passo, embora tenham se beneficiado significativamente da capacidade de incorporar variáveis exógenas com relações complexas e não lineares.

Considerando que o modelo LSTM apresentou dificuldade em antecipar picos de preços, reagindo apenas após sua ocorrência, recomenda-se para estudos futuros a adoção de estratégias alternativas de previsão multi-etapas diretas (*direct multi-step forecasting*) ou o emprego de arquiteturas baseadas em

sequence-to-sequence, capazes de capturar padrões de longo prazo sem depender exclusivamente de realimentação de previsões passadas. Além disso, a incorporação de mecanismos de atenção temporal (attention) pode permitir ao modelo identificar variações abruptas de forma mais eficiente.

Outra recomendação para pesquisas futuras consiste na diversificação das métricas utilizadas na avaliação dos modelos preditivos. Embora indicadores como o MAPE e o RMSPE sejam amplamente utilizados por sua capacidade de quantificar o erro percentual entre os valores previstos e observados, eles apresentam limitações relevantes, especialmente em contextos com elevada variabilidade ou mudanças abruptas nos padrões da série. Essas métricas tradicionais avaliam essencialmente a magnitude do erro, mas não são sensíveis à forma da série temporal, tampouco à direção dos movimentos ou à precisão na identificação de picos e vales.

Em cenários como o do mercado de leite UHT, onde os ciclos produtivos coexistem com oscilações ocasionais de difícil previsão, torna-se necessário adotar métricas complementares que permitam uma avaliação mais abrangente do desempenho preditivo. Métricas como o Erro Absoluto Escalonado (MASE), a Acurácia Direcional (Directional Accuracy) e a Distância por Dynamic Time Warping (DTW) oferecem vantagens nesse sentido, ao incorporarem elementos como a comparação com benchmarks simples, a capacidade de prever corretamente a direção das variações e a similaridade estrutural entre as séries prevista e observada. A utilização conjunta dessas métricas pode aprimorar o processo de seleção e validação dos modelos, especialmente quando o objetivo é capturar não apenas valores pontuais, mas a dinâmica completa do comportamento da série ao longo do tempo.

A inclusão de variáveis exógenas, como o preço da ração, trouxe resultados heterogêneos. Enquanto o SARIMA não obteve ganhos significativos, o LSTM melhorou seu desempenho com defasagens específicas (ex.: MAPE de 6,98% no LSTM_Lag1), o que ressalta a capacidade das redes neurais em explorar relações indiretas e não lineares. Contudo, a incorporação dessas variáveis também expôs desafios metodológicos, como multicolinearidade e dependência de projeções exógenas, que demandam ajustes cuidadosos.

Para trabalhos futuros com uso de variáveis exógenas, uma possibilidade consiste em integrar variáveis adicionais, como indicadores climáticos, políticas de importação e informações de mercado futuro, para enriquecer o contexto informativo do modelo e melhorar sua capacidade de antecipação de choques de mercado. Por fim, estruturas híbridas, combinando modelos estatísticos tradicionais para sazonalidade (por exemplo, SARIMA) com redes neurais para os resíduos não lineares, podem representar uma abordagem promissora para lidar com séries temporais complexas e voláteis como a do preço do leite UHT.

Sendo assim as implicações práticas são relevantes para agentes da cadeia láctea. A adoção de modelos como o SARIMA pode auxiliar na redução de incertezas para planejamento produtivo e estratégias de precificação, enquanto o LSTM, com otimizações, oferece potencial para cenários complexos e multivariados.