

Análises comparativas de modelos de séries temporais para previsão de preços do leite cru

Comparative analyses of time series models for forecasting raw milk prices

João Vitor Sesso de Freitas

Universidade de São Paulo. Piracicaba, SP, Brasil

Natália Salaro Grigol

Centro de Estudos Avançados em Economia Aplicada (CEPEA) - Universidade de São Paulo.

Piracicaba, SP, Brasil

GT 03 - Evolução, estrutura, competitividade e dinâmica das cadeias agroindustriais

Resumo: A previsão do preço do leite cru possui relevância econômica para o setor lácteo, pois pode contribuir para reduzir a incerteza nas decisões produtivas e comerciais dos agentes da cadeia. Entretanto, a literatura de previsão do preço do leite se concentra em um número limitado de modelos e janelas de previsão, não faz uso da técnica de validação cruzada ou não se aplica ao contexto brasileiro. Assim, este estudo compara o desempenho preditivo de diferentes modelos de séries temporais na previsão do preço do leite cru no Brasil em múltiplos horizontes futuros. Os modelos comparados foram Naive, Naive Sazonal, Theta, ETS, Holt-Winters e SARIMA, na previsão de 3, 6 e 12 meses. O desempenho de cada modelo foi calculado a partir da técnica de validação cruzada com origem móvel, e as métricas de desempenho avaliadas foram o Erro Absoluto Médio (EAM) e o Erro Absoluto Percentual Médio (EAPM). Para verificar se a diferença entre o erro dos modelos foi estatisticamente significativa, aplicou-se o teste de Diebold-Mariano. Os modelos que apresentaram menor erro foram o SARIMA, Theta e ETS, nessa ordem. Apesar de não ter havido diferença estatisticamente significativa entre o desempenho do SARIMA e o desses outros dois modelos, o SARIMA foi o único desses três modelos a demonstrar diferença significativa de desempenho em relação ao Holt-Winters e aos *benchmarks* Naive e Naive Sazonal. Esses resultados indicam maior competitividade do SARIMA na previsão do preço brasileiro do leite cru e encontram respaldo na literatura de previsão de séries temporais. Passos futuros de pesquisa podem testar também modelos multivariados na previsão do preço do leite cru no Brasil, além de combinar abordagens estatísticas e/ou de *machine learning*, em busca de uma capacidade preditiva superior.

Palavras-chave: previsão de séries temporais, preço do leite, validação cruzada, ARIMA, suavização exponencial

Abstract: Forecasting raw milk prices has economic relevance for the dairy sector, as it may help reduce uncertainty in the production and commercial decisions of agents across the supply chain. However, the literature on milk price forecasting focuses on a limited number of models and forecast horizons, does not employ the cross-validation technique or does not apply to the Brazilian context. Thus, this study compares the predictive performance of different time series models in forecasting the price of raw milk in Brazil across multiple future horizons. The models compared were Naive, Seasonal Naive, Theta, ETS, Holt-Winters, and SARIMA, for forecasts of 3, 6, and 12 months. The performance of each model was calculated using the rolling-origin cross-validation technique, and the performance metrics evaluated were Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE). To verify whether the difference between model errors was statistically significant, the Diebold–Mariano test was applied. The models that presented the lowest errors were SARIMA, Theta, and ETS, in that order. Although there was no statistically significant difference between the performance of SARIMA and that of the other two models, SARIMA was the only one among these three models to demonstrate a significant performance difference in relation to Holt-Winters and the Naive and Seasonal Naive benchmarks. These results indicate greater competitiveness of SARIMA in forecasting Brazilian raw milk prices and are supported by the time series forecasting literature. Future research may also test multivariate models in forecasting raw milk prices in Brazil, in addition to combining statistical and/or machine learning approaches in search of superior predictive capacity.

Keywords: time series forecasting, milk price, cross-validation, ARIMA, exponential smoothing

1. Introdução

A previsão de preços agropecuários desempenha papel relevante na redução da incerteza e no suporte à tomada de decisão de produtores, indústrias e formuladores de políticas públicas. No setor lácteo, a volatilidade dos preços pode afetar decisões de produção, investimentos e estratégias de comercialização, tornando relevantes ferramentas quantitativas capazes de antecipar tendências de mercado.

Nesse contexto, modelos de séries temporais podem ser utilizados pela sua capacidade de capturar padrões como tendência, sazonalidade e ciclos. A comparação de acurácia entre diferentes modelos de séries temporais é amplamente discutida na literatura de previsão. Hyndman *et al.* (2002) destacam que nenhum método de previsão é consistentemente superior em todos os contextos, uma vez que o desempenho depende das características da série e do horizonte de previsão. Nesse sentido, a avaliação fora da amostra e o uso de múltiplas métricas de erro constituem práticas recomendadas para a comparação robusta de modelos preditivos.

A literatura tem abordado a previsão de preços agropecuários, incluindo o leite, por meio de modelos de séries temporais, com destaque para abordagens como ARIMA e métodos estruturais. Estudos aplicados (VILELA; PENEDO, 2024; BERGMANN; O'CONNOR; THÜMMEL, 2018; FACHINELLO; BACCHI, 2009; FACHINELLO; PONCHIO, 2006) demonstram a utilidade dessas ferramentas na modelagem da dinâmica dos preços, embora frequentemente se concentrem em um número limitado de modelos e horizontes de previsão ou não sejam aplicados ao contexto brasileiro, além de não focarem na comparação sistemática de desempenho com a técnica da validação cruzada.

Por isso, permanece relevante a realização de análises comparativas entre diferentes métodos de previsão, de modo a avaliar seu desempenho sob distintos horizontes temporais, contribuindo para a escolha de modelos mais adequados às características dos dados e às necessidades dos agentes econômicos.

Dessa forma, o objetivo deste trabalho é comparar o desempenho preditivo de diferentes modelos estatísticos aplicados à previsão do preço do leite cru no Brasil, considerando horizontes de 3, 6 e 12 meses. Especificamente, busca-se identificar quais modelos apresentam maior acurácia preditiva a partir de métricas tradicionais de erro e de um procedimento sistemático de validação dentro da amostra.

2. Revisão da Literatura

Segundo a FAOSTAT (2026), o Brasil foi o quinto maior produtor de leite de vaca do mundo em 2024 (atrás apenas da União Europeia, Índia, Estados Unidos e China), com produção correspondendo a 4,6% do total mundial. De acordo com o IBGE (2026a), a produção nacional atingiu aproximadamente 35,7 bilhões de litros em 2024 e a captação industrial, 25,4 bilhões de litros (IBGE, 2026b).

A produção do leite cru está amplamente distribuída no território nacional, estando presente em praticamente todos os municípios, o que confere ao setor papel central na geração de renda, especialmente em regiões rurais. Em 2024, Sul e Sudeste concentraram 67,1% da produção nacional (com Minas Gerais, Paraná 12,9% e Rio Grande do Sul representando 27,4%, 12,9% e 11,3% do total, respectivamente) - e a estrutura industrial acompanha, de forma geral, o mesmo padrão (IBGE, 2026a; IBGE, 2026b).

A pulverização da atividade no Brasil explica a forte heterogeneidade da base produtiva, já que a atividade é desenvolvida por um grande número de estabelecimentos com distintos níveis de escala, tecnologia e inserção no mercado. Conforme destacado por Vilela (2016), Zoccal e Stock (2011) e Zoccal *et al.* (2008), os sistemas variam significativamente quanto ao manejo, à base alimentar, à genética do rebanho e ao nível de tecnologia que determinam escala e produtividade (sistemas de subsistência, semiextensivos, especializados e intensivos). Ainda assim, estima-se que aproximadamente 80% da produção nacional seja realizada em sistemas baseados em pastagens, o que implica elevada dependência de condições naturais para a alimentação do rebanho (STOCK, 2015).

Essa dependência estrutural das pastagens estabelece uma forte relação entre a produção de leite e o regime climático. A disponibilidade de forragem varia ao longo do ano em função da pluviosidade e da temperatura, resultando em comportamento sazonal da produção. Nos períodos de maior disponibilidade hídrica, especialmente durante o verão, há aumento da produção de pastagens, o que permite maior oferta de alimento ao rebanho e elevação da produção de leite. Em contrapartida, nos períodos de seca e temperaturas mais baixas, a produção de forragem é reduzida, levando à queda na produção e ao aumento dos custos, devido à necessidade de suplementação alimentar (JUNQUEIRA; ZOCCAL; MIRANDA, 2008).

A sazonalidade da produção se traduz diretamente em variações na oferta de leite ao longo do ano, o que impacta o comportamento dos preços. Diversos estudos identificam padrões sazonais tanto na produção quanto nas cotações do leite cru, indicando que períodos

de maior oferta tendem a estar associados à redução de preços, enquanto períodos de menor oferta resultam em elevação das cotações (GRIGOL, 2026; ALVES; SOUSA; ERVILHA, 2015; MARIN; CAVALHEIRO; ANSCHAU, 2011; PAIVA, 2010; ROMA JÚNIOR et al., 2009; RONSANI; PARRÉ, 2003).

A irregularidade da oferta (associada à sazonalidade da produção), a predominância de sistemas de baixa escala e a dispersão geográfica dos produtores elevam os custos logísticos de captação da indústria (SORIO, 2018; CARVALHO, 2011; LIMA JÚNIOR, 2011). Como o País não é autossuficiente na produção de lácteos, a concorrência entre laticínios pela captação de leite é acirrada, especialmente em períodos de menor oferta. Em situações de escassez, o mercado recorre a importações, contribuindo para a transmissão de choques externos aos preços domésticos. Em situações de sobreoferta, porém, os excedentes não são facilmente direcionados para exportação, já que o Brasil possui baixa participação no comércio internacional de lácteos e produção predominantemente voltada ao mercado interno – o que pode acentuar quedas de preços em momentos de aumento da oferta (GRIGOL, 2026).

Ao longo das últimas décadas, observa-se um processo de transformação estrutural caracterizado pela redução do número de produtores e pela concentração da produção em unidades mais tecnificadas e de maior escala, refletindo um movimento de especialização da atividade (CARVALHO; GALAN; VENTURINI, 2016; LEITE; ZOCCAL, 2016). Em regiões com maior densidade de produtores, o poder de barganha tende a se concentrar na indústria, enquanto, em regiões com menor disponibilidade de fornecedores, os produtores passam a ter maior capacidade de negociação e tendem a obter preços superiores e maior estabilidade nas relações comerciais, enquanto produtores de menor porte enfrentam maior vulnerabilidade às oscilações de mercado (SORIO, 2018; ACOSTA; SOUZA, 2017; CARVALHO; GALAN; VENTURINI, 2016). O segmento industrial também tem passado por intenso processo de concentração desde a década de 1990, impulsionado pela busca por ganhos de escala, aumento da competitividade e maior eficiência operacional (GRIGOL, 2026; SORIO, 2018).

Essas transformações estruturais vêm acirrando os padrões de concorrência na última década e tornando o ambiente competitivo ainda mais dinâmico – marcado pelo elevado nível de incertezas permeando as transações, volatilidade nos preços do leite cru, dificuldade na avaliação do poder de barganha, disputas por fornecedores e ajustes constantes nas estratégias de comercialização da matéria-prima. A elevada incerteza reduz a previsibilidade do mercado e induz os agentes a adotarem estratégias de curto prazo, o que tende a comprometer decisões

de investimento e a limitar ganhos de eficiência e inovação — especialmente em uma atividade como a pecuária leiteira, cujo ciclo produtivo é relativamente longo (GRIGOL, 2026). Em um plano mais amplo, a incerteza também se traduz no aumento dos custos de transação e na dificuldade de coordenação entre os elos da cadeia, restringindo processos de especialização e a geração de ganhos sistêmicos de eficiência (GRIGOL, 2026; NORTH, 2018).

Para os produtores, a incerteza quanto à remuneração futura pode comprometer decisões de investimento em tecnologia, manejo e expansão da produção, afetando a produtividade e a sustentabilidade da atividade (ALVES; LÍCIO; CONTINI, 2016). Para a indústria, a instabilidade de preços aumenta os riscos associados ao abastecimento e à gestão da capacidade produtiva (CARVALHO, 2011).

Além disso, a atividade leiteira está, assim como toda atividade agropecuária, sujeita a riscos adicionais decorrentes de fatores climáticos, biológicos e institucionais. Eventos relacionados a mudanças climáticas, variações na pluviosidade, ocorrência de doenças e mudanças nas exigências de mercado contribuem para ampliar a incerteza enfrentada pelos agentes (GODDE et al., 2021; BUAINAIN; SILVEIRA, 2017). O aumento da complexidade do ambiente produtivo e competitivo, associado ao uso crescente de capital e à intensificação dos sistemas produtivos, reforça a necessidade de instrumentos capazes de auxiliar na gestão desses riscos (GRIGOL, 2026).

Nesse contexto, a previsão de preços agropecuários assume papel fundamental como ferramenta de suporte à decisão, permitindo a antecipação de tendências de mercado e contribuindo para o planejamento produtivo, a definição de estratégias de comercialização e a mitigação dos riscos associados à atividade.

Estudos empíricos sobre a previsão de preços do leite frequentemente utilizam modelos univariados da família ARIMA, devido à sua capacidade de capturar padrões de dependência temporal e sazonalidade. Vilela e Penedo (2024) identificaram melhor desempenho de um modelo SARIMA em relação a modelos não sazonais na previsão de preços no Triângulo Mineiro e Alto Paranaíba, destacando a relevância da sazonalidade. De forma semelhante, Fachinello e Bacchi (2009) também encontraram resultados favoráveis ao uso de modelos SARIMA na previsão de preços pagos aos produtores em Santa Catarina.

Outros trabalhos reforçam a utilidade desses modelos, sobretudo em previsões de curto prazo. Fachinello e Ponchio (2006) concluíram que modelos ARIMA e SARIMA são ferramentas adequadas para previsões de preços em diferentes estados brasileiros, enquanto

Bergmann, O'Connor e Thümmel (2018) observaram bom desempenho de modelos ARIMA em horizontes curtos na União Europeia, além de ganhos de precisão quando há combinação de previsões entre modelos.

Apesar dessas contribuições, a literatura ainda apresenta limitações, como a análise de um número restrito de modelos ou horizontes de previsão e menor foco em comparações sistemáticas de desempenho com validação cruzada. Além disso, parte dos estudos concentra-se em contextos regionais ou internacionais. Nesse sentido, análises comparativas mais amplas permanecem relevantes, especialmente no contexto brasileiro, motivando a abordagem adotada neste estudo.

3. Metodologia

A análise foi realizada a partir de uma série temporal mensal do preço do leite cru no Brasil. Essa série vai de dezembro de 2004 a dezembro de 2025 e, portanto, é composta de 253 observações (n). Os dados foram obtidos do CEPEA (2026) e utilizou-se a média nacional do preço do leite cru disponibilizado por esse centro de pesquisa, em oposição às médias estaduais. Os resultados foram elaborados em Python.

Para avaliação da capacidade preditiva dos modelos foi utilizada a técnica de validação cruzada com origem móvel (*rolling origin*), na qual o conjunto de treino de dados é expandido progressivamente e previsões são geradas para dados da amostra em cada momento dessa expansão.

Assim, em lugar de dividir rigidamente a amostra em treino e teste, usar aquele para prever este e obter uma única métrica de desempenho, esse processo é repetido múltiplas vezes: define-se o tamanho inicial do treino (t), realiza-se a previsão do teste para h períodos e calcula-se a métrica de desempenho. Em seguida, o treino passa a ser de tamanho $t+1$, a previsão é feita novamente para h períodos e a nova métrica de desempenho é calculada. Esse processo se repete até o treino ser de tamanho $n-h$, e enfim faz-se a média das métricas de desempenho. Essa técnica foi aplicada para todos os modelos empregados neste estudo e para $h = 3, 6, 12$. O tamanho inicial do treino foi definido como 70% da série.

O propósito da origem móvel é garantir que cada modelo revele sua verdadeira capacidade preditiva dada a estrutura da série temporal. O emprego de diversas partições da amostra em treino e teste alimenta o modelo com diversas “versões” da série e evita que resultados obtidos de uma única partição mascarem problemas de *overfitting* ou mesmo puro

acaso. As vantagens da origem móvel sobre a avaliação tradicional de partição única são discutidas em Hyndman e Athanasopoulos (2021).

Os modelos avaliados foram: Naive, Naive Sazonal, Theta, Holt-Winters, ETS e SARIMA. Os dois primeiros são tradicionalmente utilizados como benchmarks na literatura de previsão, servindo como critérios de referência para avaliar os ganhos de desempenho proporcionados por modelos mais sofisticados. O modelo Theta destaca-se por sua robustez empírica e bom desempenho em competições de previsão, combinando simplicidade estrutural com elevada acurácia preditiva (ASSIMAKOPOULOS; NIKOLOPOULOS, 2000).

Os modelos de suavização exponencial, como Holt-Winters e ETS, possuem forte fundamentação teórica, o que garante consistência estatística e flexibilidade para modelar componentes de nível, tendência e sazonalidade (WINTERS, 1960; HYNDMAN *et al.*, 2002). Por fim, o modelo SARIMA constitui uma das abordagens mais consolidadas na análise de séries temporais, com ampla aplicação empírica e sólida base metodológica (BOX *et al.*, 2015; BROCKWELL; DAVIS, 2016).

Os modelos exponenciais (Holt-Winters e ETS) consideraram componentes de tendência e sazonalidade multiplicativos, assim como a componente de erro do modelo ETS. O modelo SARIMA, por sua vez, teve sua ordem definida com base no critério de informação de Akaike (AIC) (1974), de modo a minimizar o número de parâmetros e maximizar a log-verossimilhança do modelo, buscando simplicidade e precisão. A sazonalidade foi especificada como de 12 meses.

A estacionariedade da série de preços do leite cru é um requisito fundamental para a aplicação do modelo SARIMA (BOX *et al.*, 2015). Para testar a presença de estacionariedade, utilizou-se o teste Dickey-Fuller Aumentado (ADF), conforme proposto por Said e Dickey (1984). O teste avalia a presença de uma raiz unitária, que indicaria que a série não é estacionária. Para estacionarizar a série, empregou-se a primeira diferença de seu logaritmo natural, com o objetivo de controlar sua média e variância antes de aplicar o SARIMA.

Como métricas de desempenho foram utilizados o Erro Absoluto Médio (EAM) e o Erro Absoluto Percentual Médio (EAPM), que são amplamente utilizadas na literatura (HYNDMAN *et al.*, 2002). Adicionalmente, foi analisada a distribuição dos erros por meio de boxplots, permitindo avaliar não apenas sua tendência central, mas também sua dispersão e a presença de valores extremos.

Por fim, para testar se a diferença de desempenho entre os modelos foi estatisticamente significativa, aplicou-se o teste de Diebold e Mariano (1995) para as três

janelas de previsão. Esse teste é adequado para a comparação de acurácia entre previsões concorrentes, pois relaxa suposições restritivas de normalidade e ausência de correlação serial nos erros de previsão. Assim, o teste verifica se o modelo vencedor tem, de fato, uma capacidade superior de prever o preço do leite em comparação aos demais modelos testados.

4. Resultados




Figura 1 - Série em reais e transformada do preço do leite cru na média Brasil (dez/2004 a dez/2025). Fonte: Elaboração própria com dados do CEPEA (2026).

A partir de um teste visual inicial, a Figura 1 revela que a série apresenta comportamentos indicativos de não-estacionariedade, como tendência crescente e heterocedasticidade. Além disso, parece haver uma ruptura ao redor do ano de 2020, data da pandemia do COVID-19. O p-valor do teste Dickey-Fuller Aumentado (ADF) confirma essa intuição visual mostrando forte evidência de raiz unitária e, portanto, de não-estacionariedade.

Após sua transformação em logaritmo natural e integração de primeira ordem, a série muda visualmente de comportamento. Não parece mais existir tendência e a variância parece ser mais estável ao longo de toda a série. O p-valor do teste ADF da série transformada novamente corrobora a intuição visual, mostrando evidência da ausência de raiz unitária. Apesar de esta ausência não garantir estacionariedade, assume-se que a série se tornou estacionária com essas transformações, a partir da avaliação visual.

Os modelos Naive e Naive Sazonal servem como *benchmarks* ou referências para avaliar o desempenho dos modelos mais complexos. O Naive consiste na repetição do último valor da série, enquanto o Naive Sazonal repete o último padrão sazonal desta. O desempenho inferior dos modelos mais sofisticados em relação a esses critérios simples deixaria de fornecer uma justificativa para aplicar esses modelos mais sofisticados, em primeiro lugar.

Como mostram as Figuras 2 e 3, apenas os modelos SARIMA, Theta e ETS possuíram um desempenho superior aos *benchmarks* em todos os horizontes temporais. A suavização exponencial do tipo Holt-Winters, por outro lado, falhou em demonstrar resultados consistentemente melhores que os *benchmarks*. Isso não implica que o modelo Holt-Winters absolutamente careça de capacidade preditiva, mas que não demonstrou essa capacidade dada a estrutura da série temporal analisada e a metodologia deste trabalho, em relação aos outros modelos.

Desse modo, os achados apontam para diferenças no desempenho dos modelos em cada horizonte temporal. De forma geral, o modelo SARIMA, cujos parâmetros encontrados pelo critério de minimização do AIC foram (2, 1, 1)(3, 0, 2)[12], apresentou os menores valores de Erro Absoluto Médio (EAM) e Erro Absoluto Percentual Médio (EAPM) em todos os cenários, seguido pelos modelos Theta e ETS, como pode ser visto nas Figuras 2 e 3.

Para a previsão de 3 meses, o modelo SARIMA apresentou um EAM de 0,1436 reais, seguido pelos modelos Theta (0,1532) e ETS (0,1579). Na janela de previsão de 6 meses, o SARIMA também apresentou o melhor desempenho em termos absolutos (0,2025), seguido por aqueles dois modelos (0,2209 e 0,2275, respectivamente). Esse padrão se repete no

horizonte de 12 meses, que produziu um resultado de 0,2876 para o SARIMA e 0,3135 e 0,3278 para o Theta e ETS, nessa ordem

Modelo	3 Meses	6 Meses	12 Meses
Naive	0.1807	0.2535	0.3426
Naive Sazonal	0.4412	0.4505	0.4764
Theta	0.1532	0.2209	0.3135
Holt-Winters	0.1839	0.3025	0.5346
ETS	0.1579	0.2275	0.3278
SARIMA	0.1436	0.2025	0.2876

Modelo	3 Meses	6 Meses	12 Meses
Naive	0.0748	0.1052	0.1422
Naive Sazonal	0.1863	0.1897	0.2000
Theta	0.0648	0.0930	0.1316
Holt-Winters	0.0783	0.1298	0.2267
ETS	0.0669	0.0965	0.1391
SARIMA	0.0595	0.0847	0.1214

Figura 2 - Erro Absoluto Médio (em R\$, acima) e Erro Absoluto Percentual Médio (abaixo) de cada modelo e horizonte temporal. Fonte: Elaboração própria.





Figura 3 - Comparação do Erro Absoluto Médio de cada modelo e horizonte temporal (R\$). Fonte: Elaboração própria

Em termos percentuais, a métrica EAPM mostra os mesmos resultados relativos, com o SARIMA demonstrando um desempenho superior aos outros modelos em todas as janelas temporais, seguido pelos modelos Theta e ETS.

Em contraste, o modelo Naive Sazonal apresentou os maiores erros em quase todos os horizontes analisados, sugerindo que a simples repetição do último padrão sazonal não captura a dinâmica da série tão bem quantos os outros modelos.

A análise da dispersão dos erros, na Figura 4, confirma esses resultados, mostrando consistentemente menor variabilidade para os modelos SARIMA, Theta e ETS em todos os horizontes de previsão. O modelo Holt-Winters, por outro lado, apresentou a maior dispersão incluindo valores extremos ou *outliers*, especialmente no horizonte de 12 meses, indicando maior instabilidade preditiva de longo prazo. Sem levar em conta valores extremos, o modelo Naive Sazonal foi o de maior dispersão nas janelas de 3 e 6 meses.






Figura 4 - Dispersão do Erro Absoluto Médio em cada modelo e horizonte temporal (R\$). Fonte: Elaboração própria

De forma geral, observa-se também que os erros aumentam conforme o horizonte de previsão se amplia, resultado esperado em exercícios de previsão temporal devido ao aumento da incerteza. Pode-se notar, além disso, que a dispersão do modelo Naive Sazonal relativamente aos outros modelos diminui com o aumento do horizonte temporal, sugerindo uma previsão de curto prazo mais incerta.

Para verificar se as disparidades observadas na precisão dos modelos possuem significância estatística, é preciso todavia observar os resultados do teste Diebold-Mariano (DM). A Figura 5 exibe esses resultados para cada par de modelos em todos os horizontes de previsão.

De maneira reveladora, as estatísticas do teste DM comparando o SARIMA com o Theta e ETS mostram que a diferença no desempenho preditivo do “primeiro” em relação ao “segundo e terceiro colocados” não é significativa a 5% em nenhum dos três horizontes temporais. Ao contrário, o p-valor nessas comparações é relativamente alto, indicando que a influência do acaso na diferença de desempenho do SARIMA em relação aos outros dois modelos foi relevante.

No entanto, dois padrões nos resultados do teste DM sugerem que a superioridade do SARIMA sobre os outros modelos analisados possui significância estatística. Em primeiro lugar, o SARIMA foi o único dos três modelos de menor erro a demonstrar significância

estatística a 5% na comparação com o Holt-Winters. Mesmo na janela de previsão de 12 meses, o p-valor nessa comparação foi de 0,05, sugerindo uma diferença de previsão do SARIMA sobre o Holt-Winters não devida ao acaso de nenhum modo relevante.

h = 3 meses	Naive	Naive Sazonal	Theta	Holt-Winters	ETS	SARIMA
Naive						
Naive Sazonal	5.49* (0.000)					
Theta	-1.54 (0.129)	-5.52* (0.000)				
Holt-Winters	0.64 (0.522)	-5.43* (0.000)	1.32 (0.191)			
ETS	-1.19 (0.236)	-5.54* (0.000)	0.70 (0.484)	-1.34 (0.184)		
SARIMA	-2.01* (0.049)	-5.50* (0.000)	-0.69 (0.495)	-2.04* (0.045)	-1.05 (0.297)	

h = 6 meses	Naive	Naive Sazonal	Theta	Holt-Winters	ETS	SARIMA
Naive						
Naive Sazonal	4.80* (0.000)					
Theta	-1.22 (0.227)	-4.83* (0.000)				
Holt-Winters	0.79 (0.430)	-4.82* (0.000)	1.51 (0.135)			
ETS	-0.93 (0.356)	-4.86* (0.000)	0.75 (0.455)	-1.53 (0.131)		
SARIMA	-2.03* (0.046)	-4.83* (0.000)	-0.79 (0.434)	-2.21* (0.030)	-1.13 (0.263)	

h = 12 meses	Naive	Naive Sazonal	Theta	Holt-Winters	ETS	SARIMA
Naive						
Naive Sazonal	4.83* (0.000)					
Theta	-1.15 (0.255)	-4.90* (0.000)				
Holt-Winters	0.70 (0.486)	-4.93* (0.000)	1.49 (0.140)			
ETS	-0.82 (0.416)	-4.93* (0.000)	1.26 (0.211)	-1.43 (0.158)		
SARIMA	-1.98 (0.053)	-4.91* (0.000)	-0.65 (0.515)	-2.00 (0.050)	-1.08 (0.284)	

Figura 5 - Estatística e p-valor do teste Diebold-Mariano para cada par de modelos e horizonte temporal. Fonte: Elaboração própria

Além disso, o SARIMA foi também o único dos três modelos de menor erro a demonstrar significância a 5% em relação aos *benchmarks* de modo consistente ao longo dos três horizontes de previsão. Se não o demonstra para o horizonte de 12 meses em comparação

ao critério Naive, está de todo modo relativamente próximo de demonstrá-lo, dado o p-valor de 0,053. Desse modo, apenas o SARIMA justificou sua aplicação em favor de critérios mais simples como considerar o último valor ou padrão sazonal da série como previsões futuras.

Esses resultados também encontram respaldo na literatura de séries temporais, que destaca a robustez metodológica dos modelos SARIMA em contextos nos quais a estrutura temporal da série pode ser adequadamente capturada por componentes autorregressivos, de médias móveis e sazonais. Conforme destacado por Box *et al.* (2015), a metodologia Box-Jenkins oferece um arcabouço sistemático para identificação, estimação e validação de modelos, favorecendo especificações parcimoniosas e com boa capacidade preditiva.

De forma semelhante, Brockwell e Davis (2016) ressaltam que modelos ARIMA sazonais tendem a apresentar desempenho competitivo quando a série apresenta dependência temporal bem definida, o que ajuda a explicar a consistência dos resultados obtidos neste estudo. Assim, o desempenho do SARIMA observado nesta análise reforça evidências já estabelecidas na literatura quanto à sua confiabilidade como ferramenta de previsão em séries econômicas.

5. Considerações finais

Este estudo comparou o desempenho de diferentes modelos de séries temporais na previsão do preço do leite cru no Brasil. Os resultados mostram que modelos estatísticos mais estruturados, como SARIMA, ETS e Theta, tendem a apresentar melhor desempenho preditivo do que abordagens mais simples, como tratar o último valor ou padrão sazonal da série como previsão futura.

O modelo SARIMA destacou-se como a melhor alternativa geral, apresentando os menores erros médios e menor dispersão dos erros. Apesar de não serem observadas diferenças estatisticamente significativas entre os erros de previsão do SARIMA e os dos modelos ETS e Theta, essa diferença foi significativa na comparação do SARIMA com o modelo de suavização exponencial Holt-Winters e com os critérios simples Naive e Naive Sazonal. O mesmo não ocorreu com o ETS e Theta.

Esse resultado sugere que a modelagem explícita da estrutura autoregressiva, de média móvel e sazonal pode melhorar a qualidade das previsões e ser preferível a abordagens de suavização exponencial e a *benchmarks* simples.

Cabe destacar que a obtenção de previsões precisas para o preço do leite cru representaria um avanço relevante para o setor lácteo brasileiro, na medida em que poderia contribuir para reduzir a incerteza inerente às decisões produtivas e comerciais.

Caso tal capacidade preditiva seja alcançada e continuamente aprimorada, modelos estatísticos de previsão poderão se tornar ferramentas importantes de apoio à tomada de decisão, auxiliando produtores, indústrias e demais agentes da cadeia na gestão de riscos, no planejamento da produção e na definição de estratégias comerciais. Nesse sentido, o desenvolvimento e a avaliação sistemática de métodos de previsão constituem um passo importante na direção de uma gestão mais eficiente no agronegócio.

Uma das limitações deste trabalho, porém, é a consideração apenas de modelos univariados. Pesquisas futuras podem incorporar variáveis explicativas macroeconômicas, climáticas ou outras variáveis relevantes. Além disso, explorar métodos mistos que combinem abordagens estatísticas e/ou de *machine learning* pode trazer ganhos adicionais de precisão preditiva, segundo resultados da 4ª competição Makridakis de previsão de séries temporais (MAKRIDAKIS; SPILOTIS; ASSIMAKOPOULOS, 2020, p. 31).

Referências

ACOSTA, D. C.; SOUZA, J. P. Estratégias de organização da cadeia do leite no Paraná. **Revista Ibero-Americana de Estratégia**, São Paulo, v. 16, n. 2, p. 66–89, 2017.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716-723, 1974.

ALVES, E. R. A.; LÍCIO, A. M. A.; CONTINI, E. Perspectivas do Brasil no comércio internacional de lácteos. In: VILELA, D.; FERREIRA, R. P.; FERNANDES, E. N.; JUNTOLLI, F. V. (org.). **Pecuária de leite no Brasil: cenários e avanços tecnológicos**. Brasília: Embrapa, 2016. p. 17–31.

ALVES, F. F.; SOUSA, L. C. V.; ERVILHA, G. T. Planejamento e previsão do preço do leite em Minas Gerais: análise empírica com base no modelo X12-ARIMA. **Revista de Economia e Agronegócio**, v. 12, n. 1–3, 2015.

ASSIMAKOPOULOS, V.; NIKOLOPOULOS, K. The theta model: a decomposition approach to forecasting. **International Journal of Forecasting**, v. 16, p. 521–530, 2000.

BERGMANN, D.; O'CONNOR, D.; THÜMMEL, A. An evaluation of point and density forecasts for selected EU farm gate milk prices. **International Journal of Food and Agricultural Economics**, v. 6, n. 1, p. 23–53, 2018.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time series analysis: forecasting and control**. 5. ed. Hoboken: John Wiley & Sons, 2015.

BROCKWELL, P. J.; DAVIS, R. A. **Introduction to time series and forecasting**. 3. ed. New York: Springer, 2016.

BUAINAIN, A. M.; SILVEIRA, R. L. F. da. **Manual de avaliação de riscos na agropecuária: um guia metodológico**. Rio de Janeiro: ENS, 2017.

CARVALHO, G. R. Indústria de laticínios no Brasil. In: STOCK, L.; ZOCCAL, R.; CARVALHO, G. R.; SIQUEIRA, K. B. **Competitividade do agronegócio do leite brasileiro**. Brasília, DF: Embrapa Informação Tecnológica, 2011. p. 108–131.

CARVALHO, M. P.; GALAN, V. B.; VENTURIN, C. E. P. Cenários para pecuária de leite no Brasil. In: VILELA, D.; FERREIRA, R. P.; FERNANDES, E. N.; JUNTOLLI, F. V. (coord.). **Pecuária de leite no Brasil: cenários e avanços tecnológicos**. Brasília: Embrapa, 2016. p. 105–126.

CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA (CEPEA). **Preços ao Produtor**. Disponível em: cepea.org.br/br/indicador/leite.aspx. Acesso em: 29 mar. 2026.

DIEBOLD, F. X.; MARIANO, R. S. Comparing Predictive Accuracy. **Journal of Business & Economic Statistics**, v. 13, n. 3, p. 253–263, jul. 1995.

FACHINELLO, A. L.; BACCHI, M. R. P. Determinação de um modelo de previsão univariado para preços de leite pagos aos produtores em Santa Catarina. **Análise Econômica**, v. 24, n. 46, 2009.

FACHINELLO, A. L.; PONCHIO, L. A. Modelo de previsão univariado para preços de leite pagos aos produtores nas principais regiões brasileiras. In: Congresso Brasileiro de Economia e Sociologia Rural, 44., 2006, Fortaleza. **Anais do Congresso Brasileiro de Economia e Sociologia Rural**. Fortaleza: SOBER, 2006.

FAOSTAT. **Food and agriculture data**. Food and Agriculture Organization of the United Nations. Disponível em: [/www.fao.org/faostat/en/#home](http://www.fao.org/faostat/en/#home). Acesso em: 3 abr. 2026.

GODDE, C. M.; MASON-D'CROZ, D.; MAYBERRY, D. E.; THORNTON, P. K.; HERRERO, M. Impacts of climate change on the livestock food supply chain: a review of the evidence. **Global Food Security**, v. 28, p. 100488, 2021.

GRIGOL, N. S. **Dinâmica de comercialização do leite cru no Brasil**. 2024. Tese (doutorado), Universidade Estadual de Campinas, 2024, 213 p.

HYNDMAN, R. J.; ATHANASOPOULOS, G.. **Forecasting: Principles and Practice**. 3. ed. Melbourne: OTexts, 2021.

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**, v. 18, n. 3, p. 439–454, 2002.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa Pecuária Municipal**. Número de informantes e quantidade de leite cru, resfriado ou não, adquirido e industrializado, no mês e no trimestre, por tipo de inspeção. 2026a.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa Trimestral do Leite**. Número de informantes e quantidade de leite cru, resfriado ou não, adquirido e industrializado, no mês e no trimestre, por tipo de inspeção. 2026b.

JUNQUEIRA, R. V. B.; ZOCCAL, R.; MIRANDA, J. E. C. **Análise da sazonalidade da produção de leite no Brasil**. Juiz de Fora: Embrapa Gado de Leite, 2008.

LEITE, J. L. B.; ZOCCAL, R. Cenários para o agronegócio e as implicações para a cadeia produtiva do leite no Brasil. In: VILELA, D.; FERREIRA, R. P.; FERNANDES, E. N.; JUNTOLLI, F. V. (org.). **Pecuária de leite no Brasil: cenários e avanços tecnológicos**. Brasília, DF: Embrapa, 2016. p. 83–104.

LIMA JÚNIOR, A. C. S. Logística de captação de leite. In: SOTCK, L.; ZOCCAL, R.; CARVALHO, G. R.; SIQUEIRA, K. B. (org.). **Competitividade do agronegócio do leite brasileiro**. Brasília, DF: Embrapa Informação Tecnológica, 2011. p. 77–105.

MAKRIDAKIS, S.; SPILIOTIS, E.; ASSIMAKOPOULOS, V. Predicting/hypothesizing the findings of the M4 Competition. **International Journal of Forecasting**, v. 36, n. 1, p. 29-36, 2020.

MARIN, S. R.; CAVALHEIRO, A. G.; ANSCHAU, D. Sazonalidade do preço do leite no Rio Grande do Sul (1986–2009). **Ciência Rural**, Santa Maria, v. 41, n. 2, p. 361–364, 2011.

NORTH, D. C. **Instituições, Mudança Institucional e Desempenho Econômico**. São Paulo: Três Estrelas, 2018, 256p.

PAIVA, C. A. V. **Efeitos da produção e da sazonalidade sobre a qualidade do leite cru refrigerado processado em uma indústria de Minas Gerais**. 2010. Dissertação (Mestrado em Tecnologia e Inspeção de Produtos de Origem Animal) – Universidade Federal de Minas Gerais, Belo Horizonte, 2010.

RONSANI, A. J; PARRÉ, J. L. Variação estacional da produção e do preço do leite no Estado do Paraná (1980-1999). **Revista Unioeste**, v. 7, n. 1, 2003.

ROMA JÚNIOR, L. C.; MONTOYA, J. F. G.; MARTINS, T. T.; CASSOLI, L. D.; MACHADO, P. F. Sazonalidade do teor de proteína e outros componentes do leite e sua relação com programa de pagamento por qualidade. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 61, n. 6, p. 1411–1418, 2009.

SAID, S. E.; DICKEY, D. A. Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order. **Biometrika**, v. 71, n. 3, p. 599-607, 1984.

SORIO, A. **Cadeia agroindustrial do leite no Brasil: diagnóstico dos fatores limitantes à competitividade**. Brasília, DF: Ministério da Indústria, Comércio Exterior e Serviços (MDIC), 2018. 261 p.

STOCK, L. **A cadeia produtiva do leite no contexto nacional e internacional. Diagnóstico da cadeia produtiva do leite de Rondônia**. Apresentação realizada ao SEBRAE-RO / SEAGRI / CONDALRON. Porto Velho: Embrapa, 18 ago. 2015. Disponível em: www.sebrae.com.br/Sebrae/Portal%20Sebrae/UFs/RO/Artigos/Diagn%C3%B3stico%20Cadeia%20do%20Leite%20-%20Rond%C3%B4nia%202015%20-%20Apresenta%C3%A7%C3%A3o%20em%20SLIDES.pdf

VILELA, D. Desafios e oportunidades para a pecuária de leite no Brasil. In: VILELA, D.; FERREIRA, R. P.; FERNANDES, E. N.; JUNTOLLI, F. V. (org.). **Pecuária de leite no Brasil: cenários e avanços tecnológicos**. Brasília, DF: Embrapa, 2016. p. 127–144.

VILELA, E. H. P.; PENEDO, A. S. T. Previsão do comportamento dos preços do leite usando modelos ARIMA e SARIMA. **Estação Científica**, v. 18, 2024.

WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. **Management Science**, v. 6, n. 3, p. 324-342, abr. 1960.

ZOCCAL, R.; STOCK, L. A. Estrutura da produção de leite no Brasil. In: SOTCK, L.; ZOCCAL, R.; CARVALHO, G. R.; SIQUEIRA, K. B. (org.). **Competitividade do agronegócio do leite brasileiro**. Brasília, DF: Embrapa Informação Tecnológica, 2011. p. 36–57.

ZOCCAL, R.; CARNEIRO, A. V.; JUNQUEIRA, R.; ZAMAGNO, M. A nova pecuária leiteira brasileira. In: BARBOSA, S. B. P.; BATISTA, A. M. V.; MONARDES, H. (org.). **III Congresso Brasileiro de Qualidade do Leite**. Recife: CCS Gráfica e Editora, 2008. v. 1, p. 85–95.