



Revista
**Cadernos de
Finanças Públicas**

02 | 2026

Gastos Previdenciários do INSS e Sustentabilidade Fiscal: Uma Aplicação do Modelo SARIMA

Victor Flávio Pereira Dornelos

Elena Soihet

Julio Cezar Russo Pinto da Silva

RESUMO

O sistema previdenciário brasileiro voltado aos trabalhadores do setor privado é organizado pelo Regime Geral de Previdência Social (RGPS), administrado pelo Instituto Nacional do Seguro Social (INSS). Em um contexto de transição demográfica acelerada, observa-se crescimento das despesas previdenciárias, impondo desafios à sustentabilidade atuarial e ao equilíbrio financeiro do sistema. Este artigo analisa o comportamento da série temporal das despesas do INSS e propõe um modelo de previsão baseado na metodologia SARIMA, contribuindo para o debate sobre a dinâmica da previdência social brasileira. A abordagem é quantitativa, com dados secundários da Empresa de Tecnologia e Informações da Previdência Social (Dataprev) e técnicas de modelagem econométrica. Os resultados indicam que as despesas tendem a crescer acima da meta de inflação nos próximos anos e são influenciadas por fatores macroeconômicos e institucionais complexos, o que limita o desempenho de modelos puramente autorregressivos e sugere a necessidade de abordagens complementares.

Palavras-Chave: Previdência Social; INSS; Séries Temporais; Modelagem SARIMA.

Classificação JEL: H55, C22, C53.

SUMÁRIO

1. INTRODUÇÃO	4
2. FUNDAMENTAÇÃO TEÓRICA E ANÁLISE EXPLORATÓRIA.....	5
2.1. <i>Análise Exploratória da Série Temporal</i>	5
2.2. <i>Modelo SARIMA</i>	7
3. METODOLOGIA	9
4. ANÁLISE DOS RESULTADOS	11
5. CONSIDERAÇÕES FINAIS.....	17
REFERÊNCIAS BIBLIOGRÁFICAS.....	19
APÊNDICE A – MÉTRICAS DE AVALIAÇÃO	21

1. INTRODUÇÃO

A Previdência Social tem por finalidade proteger o trabalhador e seus dependentes diante de situações de perda ou redução da capacidade de trabalho, assegurando a manutenção do sustento familiar. Trata-se de um sistema público, contributivo e de filiação obrigatória, no qual os contribuintes adquirem o direito de receber benefícios conforme o valor e o tempo de suas contribuições, conforme previsto no artigo 201 da Constituição Federal.

O INSS é o órgão responsável pela administração do RGPS e pela execução do Benefício de Prestação Continuada (BPC). O regime previdenciário brasileiro baseia-se no modelo de repartição solidária, no qual os trabalhadores ativos financiam os benefícios pagos aos inativos. Paralelamente, há a dimensão assistencial, representada pelo BPC, que garante renda mínima a idosos e pessoas com deficiência em situação de vulnerabilidade, independentemente de contribuição prévia, sendo financiado por impostos (Afonso; Sidone, 2025).

A elevada concentração do RGPS no método de financiamento por *pay-as-you-go*, torna o sistema altamente sensível às mudanças demográficas e à dinâmica do mercado de trabalho, ampliando sua exposição ao envelhecimento populacional, à redução da base contributiva e à informalidade, com impactos diretos sobre o déficit previdenciário. Nesse contexto, estimativas da Secretaria do Regime Geral de Previdência Social (SRGPS), divulgadas em 2023, indicam que a necessidade de financiamento público dos benefícios pagos pelo INSS deverá crescer de 2,59% do Produto Interno Bruto (PIB), em 2023, para 10,41% em 2100, evidenciando o aprofundamento do desequilíbrio fiscal e os desafios estruturais à sustentabilidade de longo prazo das contas públicas.

No contexto demográfico, as projeções do Instituto Brasileiro de Geografia e Estatísticas (IBGE) de 2024 indicam uma profunda alteração na estrutura etária, comprometendo a sustentabilidade do RGPS. A razão entre contribuintes e beneficiários, que em 2000 era de 10,63 para 1, tende a cair para 1,84 em 2070, evidenciando uma pressão inédita sobre o sistema previdenciário. Além disso, conforme dados da Dataprev, entre 2002 e 2023 o número de benefícios ativos cresceu 88%, enquanto os gastos reais com esses benefícios — corrigidos pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA) a preços de 2023 — aumentaram 215%, revelando que as despesas vêm crescendo em ritmo muito superior à expansão do número de beneficiários e à própria inflação.

Diante desse contexto, torna-se fundamental o uso de instrumentos econométricos que subsidiem o debate sobre políticas públicas voltadas à sustentabilidade do sistema previden-

ciário. Nesse sentido, este artigo investiga se a trajetória das despesas do INSS apresenta um comportamento fiscalmente sustentável, à luz de sua dinâmica temporal observada nas últimas décadas. O objeto de estudo consiste na série histórica das despesas previdenciárias do INSS no período de 2000 a 2024, construída a partir de dados da Dataprev.

Como objetivo geral, o trabalho propõe a modelagem dessa série por meio de um modelo autorregressivo integrado de médias móveis com componente sazonal (SARIMA), buscando captar seus padrões de tendência e sazonalidade e fornecer previsões que auxiliem na compreensão da evolução dos gastos previdenciários no curto prazo.

2. FUNDAMENTAÇÃO TEÓRICA E ANÁLISE EXPLORATÓRIA

2.1 Análise Exploratória da Série Temporal

De acordo com Morettin e Tolo (2006), série temporal corresponde a um conjunto de observações ordenadas de forma cronológica. Nesse sentido, os dados obtidos da Dataprev, referentes às despesas do INSS, organizados mensalmente de janeiro de 2000 até dezembro de 2024, caracterizam-se como uma série temporal.


O recorte temporal adotado justifica-se pelo fato de o ano de 2000 marcar o início de uma nova fase do tripé macroeconômico no Brasil, que trouxe mudanças significativas na dinâmica da inflação (Afonso; Araújo; Fajardo, 2016), segundo Giambiagi (2025) variável que exerce influência direta sobre os valores dos benefícios previdenciários. Dessa forma, com o objetivo de construir uma série mais consistente e representativa da realidade econômica recente, definiu-se como ponto de partida o ano de 2000, utilizando-se os dados mais atualizados disponíveis na Dataprev.

Dessa forma, com o intuito de construir uma ferramenta de projeção eficiente, justifica-se a realização de uma análise exploratória da série de despesas do INSS. Segundo Dataprev, sua composição da rubrica de despesa do INSS em 2024, é feita de majoritariamente de pagamento de benefícios 89,51% e Pessoal e Encargos Sociais com 8,49%. Tal análise visa extrair informações relevantes sobre as principais características da série, tais como tendências, sazonalidades, peculiaridades e comportamentos atípicos, além de buscar compreender como eventos econômicos e sociais ocorridos ao longo do período analisado influenciaram sua dinâmica. Esses elementos são essenciais para orientar o processo de especificação e estimação do modelo econométrico, contribuindo para a definição de estratégias metodológicas mais consistentes e

para o aprimoramento da capacidade preditiva e interpretativa dos resultados obtidos (Hyndman; Athanasopoulos, 2021).

Conforme pode ser observado na Figura 1, os gastos do INSS apresentam uma tendência clara de crescimento ao longo de sua série histórica. Esse comportamento evidencia, de forma preliminar, que a série não é estacionária, uma vez que não se comporta de maneira puramente aleatória, mas sim apresenta uma trajetória sistemática de aumento ao longo do tempo. Tal característica é condizente com séries de natureza econômico-financeira, com base nos fatores demográfico, macroeconômico e especialmente das reformas previdenciárias realizadas durante esse período.

Figura 1- Série temporal das despesas do INSS




Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pela Dataprev.

A análise da dispersão das despesas anuais do INSS revela um padrão consistente ao longo da série temporal, caracterizado por baixa variabilidade dos valores dentro de cada exercício, combinada com a presença recorrente de observações atípicas. Esses *outliers* estão associados, principalmente, à sazonalidade inerente ao pagamento dos benefícios relacionados ao décimo terceiro salário, que ocorre de forma parcelada ao longo do ano. De modo geral, a segunda parcela concentra-se no mês de dezembro, enquanto a primeira é usualmente paga em períodos próximos ao meio do ano, gerando picos pontuais nas despesas mensais. Tal comportamento evidencia a existência de uma estrutura sazonal relevante, que deve ser considerada na modelagem das despesas previdenciárias.

Cabe ressaltar que a periodicidade desses pagamentos adicionais pode sofrer alterações

devido a políticas públicas voltadas para a sustentação da renda, como observado durante a pandemia de COVID-19, período em que os pagamentos foram antecipados. Tal comportamento introduz um componente sazonal relevante na série, claramente identificado também na Figura 2 com *box plot* mensal. Este último evidencia variações expressivas entre os meses, mostrando maior dispersão naqueles impactados diretamente pelo pagamento da primeira parcela do décimo terceiro. Esta volatilidade sazonal impõe desafios adicionais na construção de um modelo preditivo, dificultando a precisão das previsões.

Figura 2 - Box-plot mensal da série histórica de despesas do INSS



Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pelo Dataprev

Observa-se, portanto, que a série histórica do INSS apresenta diversas complexidades ao longo do seu percurso, caracterizando-se por um comportamento não estacionário e com forte presença de sazonalidade. Diante desse contexto, revela-se apropriada a utilização do modelo SARIMA, que permite capturar tais características estruturais da série.

2.2 Modelo SARIMA

A análise exploratória dos dados da série histórica de gastos do INSS evidenciou seu caráter não estacionário, marcado por uma tendência de crescimento ao longo do período analisado, associada a um perfil sazonal recorrente, fortemente influenciado pelo pagamento das parcelas do décimo terceiro salário.

Nesse contexto, conforme orienta a metodologia proposta por Morettin e Toloí (2006), ao

trabalhar com séries temporais univariadas, é fundamental adotar um processo de ajustamento que contemple simultaneamente a tendência e a sazonalidade, evitando a abordagem restrita a apenas um desses componentes. Dessa forma, para modelagem da série temporal de despesas com INSS, foi empregado a metodologia SARIMA, formalizada por Box e Jenkins (1976), que é particularmente o mais ideal visto as características identificadas na análise exploratória preliminar dos dados.

Assim, o modelo SARIMA é autorregressivo e utiliza os valores das observações mensais da própria série para estimar novos valores e realizar previsões, de modo a tratar simultaneamente problemas de tendência e de sazonalidade constante. Os parâmetros do modelo dividem-se em duas partes: a não-sazonal, representada por (p, d, q) , e a sazonal, representada por $(P, D, Q)_s$.

No componente não-sazonal (p,d,q) : Autorregressivo (p), refere-se à ordem do polinômio autorregressivo (ϕ_p) e indica o número de observações passadas da série que são incluídas no modelo para prever o valor corrente.; Integrado (d): integração, indica o número de diferenciações aplicadas para tornar a série estacionária, isto é com média e variância constantes ao longo do tempo; Média Móvel (q): É a ordem do polinômio de médias móveis (θ_q) e especifica o número de erros de previsão passados que influenciam a observação atual, modelando choques aleatórios não previstos.

Já no componente sazonal $(P,D,Q)_s$, este componente modela a dependência periódica da série, onde s representa a frequência sazonal. Autorregressão Sazonal (P), A ordem do polinômio autorregressivo sazonal (Φ_p) que utiliza observações de ciclos sazonais passados para prever a observação atual; Diferenciação Sazonal (D), o número de diferenciações sazonais que é preciso para remover a sazonalidade da série; Média Móvel Sazonal (Q): A ordem do polinômio de média móvel sazonal (Θ_Q) que incorpora os erros de previsão de períodos sazonais anteriores.

A combinação desses componentes resulta na equação geral do modelo SARIMA representada abaixo, que, de forma aditiva, integra os efeitos de tendência, autocorrelação de curto prazo e ciclos sazonais em uma única equação preditiva (Morettin; Toloí, 2006).

Equação geral do modelo SARIMA:

$$\Phi_p(B) \cdot \Phi_p(B^s) \cdot (1 - B)^d \cdot (1 - B^s)^D \cdot y_t = \theta_q(B) \cdot \Theta_Q(B^s) \cdot \varepsilon_t \quad (1)$$

Decompondo cada parte desta equação:

y_t : corresponde ao valor da série no tempo t ;

ε_t : representa o termo de erro (ruído branco).

Componentes não sazonal:

$\Phi_p(B) = (1 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p)$: polinômio autorregressivo não sazonal de ordem

p . Os coeficientes Φ_1, \dots, Φ_p são os parâmetros do modelo AR.

$(1 - B)^d$: operador de diferenciação não sazonal de ordem d .

$\Theta_q(B) = (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q)$: polinômio de médias móveis não sazonal de ordem

q . Os coeficientes $\theta_1, \dots, \theta_q$ são os parâmetros do modelo MA.

Componentes sazonal:

$\Phi_P(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps})$: polinômio autorregressivo sazonal de ordem P . Os coeficientes Φ_1, \dots, Φ_P são os parâmetros do modelo SAR e o operador B^s aplica a defasagem correspondente ao período sazonal s .

$(1 - B^s)^D$: operador de diferenciação sazonal de ordem D , aplicado para remover o componente sazonal da série.

$\Theta_Q(B^s) = (1 + \theta_1 B^s + \theta_2 B^{2s} + \dots + \theta_Q B^{Qs})$: polinômio de médias móveis sazonal de ordem Q . Os coeficientes $\Theta_1, \dots, \Theta_Q$ são os parâmetros do modelo SMA.

Em síntese, o modelo SARIMA mostra-se metodologicamente adequado para a modelagem da série temporal de despesas do INSS, uma vez que sua estrutura permite capturar de forma integrada a tendência de crescimento, a dependência temporal de curto prazo e a sazonalidade recorrente observadas nos dados, assegurando maior consistência estatística às estimativas e maior robustez às projeções de longo prazo, em consonância com a abordagem clássica de análise de séries temporais proposta por Box e Jenkins (1976) e sistematizada por Morettin e Toloí (2006).

3. METODOLOGIA

Metodologicamente, o estudo adota uma abordagem quantitativa aplicada, baseada na modelagem econométrica de séries temporais das despesas do INSS, a partir de dados secundários oficiais da Dataprev. A estratégia analítica concentra-se na estimação de modelos autor-


regressivos integrados de médias móveis com componente sazonal (SARIMA), os quais permitem capturar padrões de tendência, ciclos e sazonalidade presentes na dinâmica dos gastos previdenciários ao longo do tempo.

Esse procedimento viabiliza a análise sistemática do comportamento das despesas e a avaliação de sua evolução temporal, sendo particularmente adequado para estudos voltados ao monitoramento e à análise da sustentabilidade de políticas públicas previdenciárias, em consonância com a abordagem quantitativa aplicada discutida por Creswell (2018) e com a perspectiva de análise empírica de fenômenos sociais fundamentada em bases estatísticas consolidadas, conforme Gil (2019).

A partir da definição da abordagem quantitativa e da escolha da modelagem SARIMA como instrumento analítico central, a etapa metodológica seguinte consistiu na operacionalização empírica do modelo, envolvendo a identificação, estimação e seleção das especificações mais adequadas para a série temporal das despesas do INSS. Esse procedimento seguiu a metodologia clássica de análise de séries temporais, na qual a escolha dos parâmetros é orientada tanto por critérios estatísticos quanto por avaliações de desempenho e diagnóstico dos resíduos, assegurando a robustez do modelo estimado e a confiabilidade das projeções geradas. Nesse contexto, a análise das estruturas de dependência temporal da série tornou-se elemento fundamental para a definição das ordens autorregressivas e de médias móveis, sazonais e não sazonais, conforme detalhado a seguir (Hyndman; Athanasopoulos, 2021).

A seleção dos parâmetros ótimos do modelo foi realizada por meio da análise das Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP), aplicadas à série previamente estacionarizada, utilizando um nível de significância de 5%, com o objetivo de identificar adequadamente as ordens dos componentes autorregressivos, de médias móveis, tanto sazonais quanto não sazonais. Para tal, utilizou-se o software *Python*, versão 3.13.2, juntamente com a biblioteca estatística *Statsmodels*.

Figura 3 - FAC e FACP após diferenciação da série



Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pela Dataprev

Os parâmetros selecionados para realização dos testes com base no FAC E FACP da Figura 3 foram: $q = (1, 2, 3, 4)$, $d = 1$, $p = (1, 2, 4)$, $Q = (1, 2, 3, 4, 5)$, $D = 1$ e $P = (1, 2, 3, 4)$. Após essa seleção, foram realizadas combinações aleatórias dos parâmetros mencionados, resultando em um total de 240 modelos testados. É relevante salientar que, tratando-se de uma série temporal extensa, a utilização de múltiplas combinações de parâmetros com graus elevados tornou-se uma tarefa computacionalmente complexa. Em razão disso, foi necessário recorrer ao processamento paralelo para tornar a análise viável, exigindo também um hardware com capacidade mínima de processamento adequada.

Após a execução das combinações dos modelos, adotou-se como critério inicial de seleção as métricas *Akaike Information Criterion* (AIC), *Bayesian Information Criterion* (BIC) e *Log-Likelihood*, escolhendo-se, dessa forma, os três modelos que apresentaram os melhores desempenhos segundo esses indicadores.

Na etapa seguinte, procedeu-se a uma avaliação mais criteriosa por meio do teste de normalidade de Shapiro-Wilk e das métricas de avaliação dos resíduos: Erro Médio Absoluto (MAE), Erro Percentual Absoluto Médio (MAPE), Erro Quadrático Médio (MSE) e Erro Percentual Médio (MPE) (Bueno, 2011). As formulações matemáticas das métricas utilizadas encontram-se reunidas no apêndice A deste artigo.

Por fim, selecionou-se o modelo que apresentou maior eficiência, isto é, aquele com menores níveis de erro e menor viés sistemáticos, sendo então utilizada esta configuração para a realização das projeções para os próximos 36 meses.

4. ANÁLISE DOS RESULTADOS

Após a realização de diversas combinações de parâmetros, buscando explorar um conjunto amplo de especificações e identificar aquelas com melhor desempenho, foram selecionados os três modelos mais bem avaliados segundo os critérios de AIC, BIC e *Log-Likelihood*. Esses indicadores permitem mensurar a qualidade relativa dos modelos, penalizando configurações excessivamente complexas.

Tabela 1 – Resultados da seleção dos modelos SARIMA

Modelo	p	d	q	P	D	Q	AIC	BIC	Log-Likelihood
SARIMA 1	4	1	4	5	1	1	4512,58	4563,69	-2241,29
SARIMA 2	4	1	4	5	1	2	4513,85	4568,36	-2240,93
SARIMA 3	4	1	4	5	1	3	4514,27	4572,19	-2240,13

Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pela Dataprev

De modo geral, deu-se preferência aos modelos com melhor desempenho segundo os critérios AIC e BIC, uma vez que, conforme Akaike (1974) e Schwarz (1978), a função de Log-Likelihood, quando utilizada de forma isolada, tende a favorecer modelos superparametrizados, aumentando o risco de *overfitting* — situação em que o modelo se ajusta excessivamente aos dados históricos, capturando ruídos e variações aleatórias em detrimento dos padrões estruturais da série, o que compromete sua capacidade de previsão. As especificações e as métricas dos modelos selecionados encontram-se apresentadas na Tabela 1.

A Equação 2 apresenta a especificação do modelo SARIMA 1 (4,1,4)(5,1,1)₁₂, enquanto a Equação 3 corresponde ao modelo SARIMA 2 (4,1,4)(5,1,2)₁₂. Por sua vez, a Equação 4 descreve a formulação do modelo SARIMA 3 (4,1,4)(5,1,3)₁₂.

$$\begin{aligned}
 & (1 - \phi_1 z^{12} - \phi_2 z^{24} - \phi_3 z^{36} - \phi_4 z^{48} - \phi_5 z^{60}) \cdot (1 - \phi_1 z - \phi_2 z^2 - \phi_3 z^3 - \phi_4 z^4) \cdot (1 - \lambda)(1 - \lambda^{12}) \cdot y_t = (1 + \theta_1 z^{12}) \cdot (1 + \theta_2 z + \theta_3 z^2 + \theta_4 z^3 + \theta_5 z^4) \cdot \varepsilon_t \\
 & (1 - \phi_1 z^{12} - \phi_2 z^{24} - \phi_3 z^{36} - \phi_4 z^{48} - \phi_5 z^{60}) \cdot (1 - \phi_1 z - \phi_2 z^2 - \phi_3 z^3 - \phi_4 z^4) \cdot (1 - \lambda)(1 - \lambda^{12}) \cdot y_t = (1 + \theta_1 z^{12} + \theta_2 z^{24}) \cdot (1 + \theta_3 z + \theta_4 z^2 + \theta_5 z^3 + \theta_6 z^4) \cdot \varepsilon_t \\
 & (1 - \phi_1 z^{12} - \phi_2 z^{24} - \phi_3 z^{36} - \phi_4 z^{48} - \phi_5 z^{60}) \cdot (1 - \phi_1 z - \phi_2 z^2 - \phi_3 z^3 - \phi_4 z^4) \cdot (1 - \lambda)(1 - \lambda^{12}) \cdot y_t = (1 + \theta_1 z^{12} + \theta_2 z^{24} + \theta_3 z^{36}) \cdot (1 + \theta_4 z + \theta_5 z^2 + \theta_6 z^3 + \theta_7 z^4) \cdot \varepsilon_t
 \end{aligned}$$

Tabela 2 – Métricas de erro e diagnóstico dos resíduos

Modelo	MAD	MAPE (%)	MSD	MPE (%)	Shapiro-Wilk	ARCH
SARIMA 1	3.423,50	8,28	29.860.717,69	-0,38	1,02×10 ⁻¹¹	2,30×10 ⁻³
SARIMA 2	3.418,68	8,24	29.781.228,79	-0,30	8,96×10 ⁻¹²	2,39×10 ⁻³
SARIMA 3	3.397,77	8,27	29.508.394,30	-0,50	6,28×10 ⁻¹²	1,51×10 ⁻³

Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pela Dataprev

Observa-se que, entre os três modelos avaliados, a especificação mais complexa apresentou desempenho ligeiramente superior na avaliação do desempenho preditivo com base nas métricas de erro e nos testes de diagnósticos dos resíduos, presentes na Tabela 2. Esse resultado sugere que a incorporação de um maior número de parâmetros pode contribuir para uma melhor adequação *in-sample* da série. No entanto, tais ganhos mostraram-se marginais quando com-

parados ao aumento da complexidade do modelo. Ressalta-se que os diagnósticos dos resíduos e as métricas de desempenho foram avaliados exclusivamente a partir do período posterior ao *burn-in*, conforme determinado pelo filtro de Kalman no processo de estimação via *Statsmodels*, com o objetivo de evitar distorções decorrentes da inicialização difusa dos estados no modelo integrado.

Inicialmente, destaca-se que nenhum dos modelos conseguiu satisfazer plenamente os pressupostos de normalidade no teste de *Shapiro -Wilk* e homoscedasticidade com o teste *Autoregressive Conditional Heteroskedasticity* (ARCH). Adicionalmente, os modelos não foram capazes de absorver adequadamente o impacto exógeno provocado pela pandemia, que alterou significativamente o padrão de pagamentos do benefício do décimo terceiro salário.

Outro aspecto relevante evidenciado foi o crescimento contínuo do erro ao longo do tempo, especialmente marcado por uma subestimação do modelo a partir de 2016, sendo ainda mais acentuado durante o período pandêmico. Entretanto, após o término da pandemia, verificou-se um retorno do erro a níveis próximos aos observados anteriormente, em 2016.

Uma possível explicação para esse fenômeno reside no aumento dos benefícios concedidos devido à reforma previdenciária de 2019 (Emenda Constitucional 103/2019), que estimulou uma corrida pela aposentadoria antes da vigência das novas regras. Esse fator exógeno elevou continuamente os gastos previdenciários, representando um desafio adicional que os modelos analisados não conseguiram estimar ou tratar adequadamente.

Por fim, ao analisar as medidas de erro, observa-se que os modelos avaliados apresentam desempenhos bastante próximos, com vantagens relativas distribuídas entre as diferentes especificações. O modelo SARIMA 3 apresentou os menores valores de MAD e MSD, indicando menor erro médio e menor penalização a desvios de maior magnitude. Por sua vez, o SARIMA 2 apresentou o menor MAPE e o MPE mais próximo de zero, sugerindo menor erro percentual médio e menor viés sistemático nas previsões. O modelo SARIMA 1, embora não tenha se destacado isoladamente em nenhuma métrica de erro, apresentou desempenho comparável aos demais modelos.

Em resumo, considerando o equilíbrio entre qualidade de ajuste e complexidade, opta-se pelo modelo SARIMA 1 como especificação final para a realização das previsões. Essa escolha fundamenta-se em sua menor complexidade relativa, conforme indicado pelos critérios de informação, e no fato de que as diferenças observadas nas métricas de erro em relação aos modelos alternativos são marginais, não justificando a adoção de uma estrutura mais parametrizada, seguindo o princípio de parcimônia defendido por Box e Jenkins (1976).

A Tabela 3 apresenta os parâmetros estimados do modelo SARIMA 1 selecionado. No componente não sazonal, observa-se que o coeficiente autorregressivo de segunda ordem (AR(2)) é estatisticamente significativo ao nível de 5% ($p = 0,032$), indicando a presença de dependência temporal de curto prazo, em que variações ocorridas em períodos recentes influenciam o comportamento da série com defasagem de até dois meses. Os demais termos autorregressivos e de média móvel não sazonais não se mostraram estatisticamente significativos individualmente, o que é compatível com modelos de maior ordem e estrutura multiplicativa.

No componente sazonal, destaca-se o termo autorregressivo com defasagem de 60 meses (AR.S(60)), estatisticamente significativo ao nível de 5% ($p = 0,042$), sugerindo a presença de dependência sazonal de longo prazo nas despesas previdenciárias. Adicionalmente, o coeficiente AR.S(48) apresentou significância marginal ao nível de 10% ($p = 0,062$), reforçando a evidência de padrões cíclicos multianuais. Esses resultados são consistentes com a dinâmica institucional das despesas do INSS, influenciadas por reajustes periódicos de benefícios e por componentes recorrentes do calendário previdenciário.

Tabela 3 – Resultados da estimação dos parâmetros do modelo SARIMA 1

Parâmetros	Coefficiente	Erro Padrão	Z	P> z	[0,025	0,975]
ar.L1	-0,3405	1.801	-0,189	0,85	-3.871	3.190
ar.L2	0,9663	0,45	2.145	0,032	0,083	1.849
ar.L3	0,4507	1.438	0,313	0,754	-2.368	3.270
ar.L4	-0,0702	0,142	-0,493	0,622	-0,349	0,209
ma.L1	-0,4733	1.795	-0,264	0,792	-3.991	3.044
ma.L2	-14.582	1.934	-0,754	0,451	-5.250	2.333
ma.L3	0,3749	1.474	0,254	0,799	-2.515	3.264
ma.L4	0,5577	1.610	0,346	0,729	-2.597	3.713
ar.S.L12	-0,9283	0,613	-1.514	0,13	-2.130	0,273
ar.S.L24	-0,1023	0,409	-0,25	0,803	-0,905	0,7
ar.S.L36	-0,11	0,139	-0,793	0,428	-0,382	0,162
ar.S.L48	-0,2185	0,117	-1.865	0,062	-0,448	0,011
ar.S.L60	-0,2543	0,125	-2.033	0,042	-0,5	-0,009
ma.S.L12	0,2828	0,637	0,444	0,657	-0,966	1.531
sigma2	3,95E+10	4,85E-07	8,14E+13	0	3,95E+07	3,95E+07

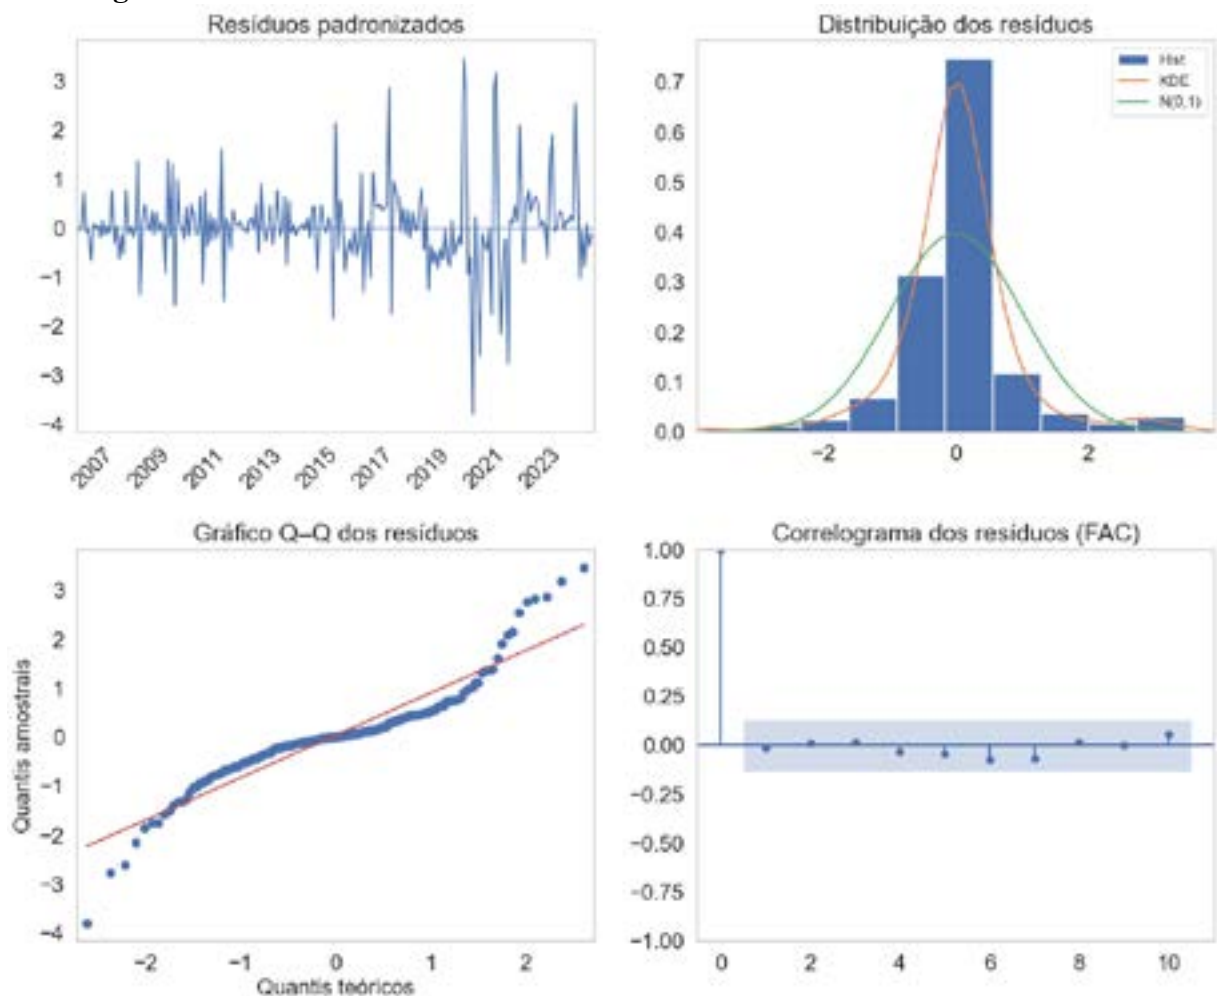
Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pela Dataprev

Em conjunto, os resultados indicam que o modelo é capaz de capturar tanto a dinâmica de curto prazo quanto componentes sazonais de longo horizonte, ainda que nem todos os parâmetros individuais sejam estatisticamente significativos. Essa característica é comum em modelos

SARIMA com múltiplos termos, especialmente quando a escolha do modelo é fundamentada em critérios de informação e desempenho global.

A Figura 4 apresenta a análise dos resíduos padronizados do modelo SARIMA estimado, considerando apenas o período posterior ao *burn-in*, o que permite uma avaliação mais adequada da qualidade do ajuste e do comportamento dos erros. Observa-se, no gráfico superior esquerdo, que os resíduos permanecem distribuídos em torno de zero, sem tendência sistemática aparente e com variância aproximadamente constante ao longo do tempo até 2015, o que indica boa captura da tendência e da sazonalidade pela modelagem. Contudo, nota-se que a partir de 2015 os desvios tornam-se mais intensos, refletindo um aumento da discrepância entre valores observados e estimados. Esse comportamento pode estar associado a mudanças institucionais que abordamos anteriormente, que alteraram a dinâmica das despesas previdenciárias.

Figura 4 – Análise dos resíduos do modelo SARIMA 1




Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pela Dataprev

te normal, centrada em zero, ainda que apresente leve concentração de valores nas caudas, o que sugere a ocorrência de choques de maior magnitude. Essa característica é confirmada pelo gráfico Q–Q (inferior esquerdo), em que os pontos se alinham bem à reta teórica, exceto nas extremidades, indicando desvios modestos da normalidade. Já o correlograma (inferior direito) revela que todas as autocorrelações residuais se encontram dentro dos limites de confiança, evidenciando que os resíduos se comportam como ruído branco, sem padrão temporal remanescente.

Em termos substantivos, é importante destacar que o aumento da variabilidade residual após 2020 coincide com o contexto da pandemia da COVID-19, período em que houve alterações no calendário e na execução do décimo terceiro benefício e uma redução do atendimento presencial do INSS, retardando novos processos de aposentadoria. Esses fatores contribuíram para quebras estruturais temporárias na série, gerando flutuações não previstas pelo modelo. Apesar disso, o comportamento geral dos resíduos indica que o modelo preserva boa capacidade explicativa, capturando adequadamente a tendência e os ciclos sazonais das despesas previdenciárias, com desvios pontuais compatíveis com choques excepcionais.

As projeções das despesas nominais do INSS, presentes na Figura 5, indicam uma trajetória consistente de crescimento nos próximos anos. Entre 2024 e 2027, observa-se um aumento acumulado de 22,63%, valor expressivo mesmo em um horizonte temporal relativamente curto. Em termos anuais equivalentes, esse resultado corresponde a uma taxa média de crescimento composta (CAGR) de 7,04% ao ano, patamar significativamente superior à meta de inflação de 3% estabelecida pelo Banco Central do Brasil.

Figura 5 - Previsão dos gastos previdenciários INSS (2025-2027)



Fonte: Elaborado pelos próprios autores utilizando dados fornecidos pela Dataprev

Considerando que o intervalo analisado abrange apenas 36 meses, não se espera a ocorrência de mudanças demográficas relevantes capazes de explicar, por si só, um crescimento real dessa magnitude. Nesse sentido, o comportamento projetado das despesas está fortemente associado à política de reajuste do salário-mínimo acima da inflação, uma vez que parcela expressiva dos benefícios previdenciários é indexada a esse parâmetro. Tal dinâmica evidencia que, mesmo no curto prazo, reajustes reais dos benefícios geram impactos relevantes sobre o nível de despesas do sistema, aspecto já destacado por Giambiagi (2025) ao discutir os efeitos dessa política sobre a sustentabilidade previdenciária no longo prazo.

5. CONSIDERAÇÕES FINAIS

Portanto, conclui-se que a série histórica das despesas nominais do INSS, no curto prazo, é influenciada por um amplo conjunto de fatores previdenciários, políticos e socioeconômicos, conforme discutido ao longo do artigo. Esses elementos contribuem para a persistência do crescimento das despesas e intensificam o debate acerca da viabilidade econômica e da sustentabilidade do sistema previdenciário brasileiro.

Nesse contexto, o modelo SARIMA estimado mostra-se adequado para a realização de previsões de curto prazo, evidenciando que as despesas do INSS mantêm uma trajetória de crescimento mesmo após as reformas previdenciárias implementadas. Tal resultado reforça a

necessidade de aprofundar o debate sobre novas reformas estruturais, bem como de aprimorar o uso de ferramentas econométricas no apoio ao processo de formulação e avaliação de políticas públicas.

Ademais, a série apresenta, no longo prazo, elevada sensibilidade a variáveis explicativas externas, tais como inflação, dinâmica demográfica, condições do mercado de trabalho e alterações nas regras previdenciárias. Nesse contexto, a incorporação de fatores exógenos mostra-se fundamental para a realização de previsões em horizontes temporais mais longos.

Sob essa perspectiva, torna-se relevante destacar outras classes de modelos de séries temporais que podem contribuir para o aprofundamento desse debate. No âmbito dos modelos univariados, destaca-se a possibilidade de estender estruturas sazonais do tipo SARIMA para incluir componentes de regressão com erros autocorrelacionados, conforme o tratamento de regressão com erros ARIMA apresentado por Shumway e Stoffer (2017). Essa formulação constitui a base teórica de modelos amplamente empregados na prática aplicada, como o SARIMAX (Seasonal Autoregressive Integrated Moving Average with Exogenous Regressors).

Em contextos multivariados, modelos VARX (*Vector Autoregression with Exogenous Variables*) são particularmente adequados quando múltiplas séries apresentam interdependência dinâmica, sendo formalizados de maneira abrangente por Lütkepohl (2005). Ademais, quando há relações de longo prazo entre variáveis cointegradas, a estrutura do VECM (*Vector Error Correction Model*), também tratada por Lütkepohl (2005), oferece um arcabouço adequado para capturar tanto a dinâmica de curto prazo quanto os equilíbrios de longo prazo.

Assim, o objetivo deste artigo é fomentar o debate sobre a adoção de ferramentas econométricas mais avançadas, capazes de gerar informações que apoiem a formulação e a avaliação de políticas públicas voltadas à sustentabilidade do sistema previdenciário.

REFERÊNCIAS BIBLIOGRÁFICAS

AFONSO, José Roberto; ARAÚJO, Eliane Cristina; FAJARDO, Bernardo Guelber. The role of fiscal and monetary policies in the Brazilian economy: understanding recent institutional reforms and economic changes. **The Quarterly Review of Economics and Finance**, v. 62, p. 41–55, 2016. DOI: 10.1016/j.qref.2016.07.005

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

BRASIL. **Constituição da República Federativa do Brasil de 1988**. Disponível em: https://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm. Acesso em: 28 ago. 2024.

BRASIL. **Emenda Constitucional nº 103**, de 12 de novembro de 2019. Altera o sistema de previdência social e estabelece regras de transição e disposições transitórias. Diário Oficial da União, Brasília, DF, 13 nov. 2019.

BOX, George E. P.; JENKINS, Gwilym M. **Time Series Analysis: Forecasting and Control**. San Francisco: Holden-Day, 1976.

BUENO, Rodrigo de Losso da Silveira. **Econometria de séries temporais**. 2. ed. rev. e atual. São Paulo: Cengage Learning, 2011.

CRESWELL, John W. **Projeto de pesquisa: métodos qualitativo, quantitativo e misto**. 5. ed. Porto Alegre: Penso, 2018

Empresa de Tecnologia e Informações da Previdência. **Infologo AEPS**. Disponível em: <https://www3.Dataprev.gov.br/infologo/inicio.htm>. Acesso em: 10 jan. 2025.

GIAMBIAGI, Fabio. **A previdência social no Brasil: tendências e desafios**. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2025. 53 p. (Textos para discussão; 164).

GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social**. 7. ed. São Paulo: Atlas, 2019.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: Principles and Practice**. 3. ed. Melbourne: OTexts, 2021. Disponível em: <https://otexts.com/fpp3/>. Acesso em: 6 out. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Projeção da População do Brasil e das Unidades da Federação**, 2024. Rio de Janeiro: IBGE, 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9109-projecao-da-populacao.html>. Acesso em: 6 out. 2025.

LÜTKEPOHL, Helmut. **New Introduction to Multiple Time Series Analysis**. Berlin: Springer, 2005.

MORETTIN, Pedro A.; TOLOI, Clélia M. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blucher, 2006.

SCHWARZ, Gideon. Estimating the dimension of a model. **The Annals of Statistics**, v. 6, n. 2, p. 461–464, 1978.

SECRETARIA DE REGIME GERAL DE PREVIDÊNCIA SOCIAL. **Projeções Financeiras e Atuariais para o RGPS**. Brasília: Ministério da Previdência Social, 2023.

SHUMWAY, Robert H.; STOFFER, David S. **Time Series Analysis and Its Applications: With R Examples**. 3. ed. New York: Springer, 2017.

SIDONE, Otávio José Guerci; AFONSO, Luís Eduardo. **Economia da previdência: teoria, desenho e avaliação**. Colaboração de Ana Cristina de Souza Queiroz e Emmilly Elizabeth César Félix. São Paulo: Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo – FEA/USP, 2025. 501 p. ISBN 978-85-61522-07-0. DOI: 10.11606/9788561522070

APÊNDICE A – MÉTRICAS DE AVALIAÇÃO

Log – Likelihood:

$$l(\hat{L}) = -\frac{n}{2}l(2\pi) - \frac{n}{2}l(\hat{\sigma}^2) - \frac{1}{2\hat{\sigma}^2} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (5)$$

Onde:

n é o número de observações,

y_t são os valores observados,

\hat{y}_t são os valores previstos pelo modelo,

$\hat{\sigma}^2$ é a variância estimada dos resíduos.

\hat{L} é o valor da função de verossimilhança maximizada.

Akaike Information Criterion (AIC):

$$AIC = 2k - 2 \ln \ln (\hat{L}) \quad (6)$$

Onde:

k é o número de parâmetros do modelo,

Bayesian Information Criterion (BIC):

$$BIC = k \ln \ln (n) - 2 \ln \ln (\hat{L}) \quad (7)$$

Erro Médio Absoluto (MAD):

$$MAD = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (8)$$

Erro Percentual Absoluto Médio (MAPE):

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (9)$$

Erro Percentual Médio (MPE):

$$MPE = \frac{100}{n} \sum_{t=1}^n \left(\frac{y_t - \hat{y}_t}{y_t} \right) \quad (10)$$

Erro Quadrático Médio (MSD):

$$MSD = \frac{1}{n} \sum_{t=1}^n \left(y_t - \hat{y}_t \right)^2 \quad (11)$$

Teste P- valor *Shapiro – Wilk*:

$$W = \frac{\left(\sum_{i=1}^n a_i x_{(i)} \right)^2}{\sum_{i=1}^n \left(x_i - \bar{x} \right)^2} \quad (12)$$

Onde:

$x_{(i)}$ são os resíduos ordenados do modelo SARIMA,

\bar{x} é a média dos resíduos,

a_i são coeficientes constantes baseados na distribuição normal,

n é o número de observações (resíduos).

Teste ARCH (*Autoregressive Conditional Heteroskedasticity*):

$$LM = nR^2 \quad (13)$$

Onde:

n é o número de observações,

R^2 é o coeficiente de determinação da regressão auxiliar.