

AJUSTE TEMPORAL DO SALÁRIO MÍNIMO REAL COM MODELOS SARIMA¹

Rodnei Alves Marques²

RESUMO

As discussões sobre o salário mínimo se iniciaram na década de 1930 visando diminuir desigualdades sociais e melhorar a relação entre trabalhadores, empregadores e estado. No ano 2000, o governo federal aprovou uma lei que permite aos estados fixarem pisos salariais acima do mínimo federal. A presente proposta procura ajustar um modelo SARIMA a série dos salários mínimos estaduais com objetivo de fazer previsões futuras. As séries foram ajustadas com a metodologia de Box & Jenkins com utilização dos softwares R e GRET. Foi observada uma tendência crescente histórica ao longo dos anos para a série mensal de salário mínimo real, com desaceleração a partir de 2015 e concluiu-se que o modelo SARIMA se ajustou de forma significativa aos dados ao ponto de fazer previsões seguras para os próximos meses.

Palavras-chave: Séries temporais. Salário Mínimo. Modelos SARIMA. Previsões.

TEMPORAL ADJUSTMENT OF THE REAL MINIMUM WAGE WITH SARIMA MODELS

ABSTRACT

Discussions on the minimum wage began in the 1930 with the aim of reducing social inequalities and improving the relationship between workers, employers and the state. In 2000, the federal government passed a law that allows states to set salary floors above the federal minimum. The present proposal aims to adjust a SARIMA model to the series of state minimum wages in order to make future predictions. The series were adjusted using the Box & Jenkins methodology using R and GRET software. And a historical growing trend was observed in the series over the years for the monthly series of real minimum wage, with a deceleration from 2015, and it is concluded that the SARIMA model has adjusted significantly to the data to the point of making safe predictions for the next months.

Keywords: Time series. Minimum wage. SARIMA Models. Forecasts.

¹ **Como citar este artigo:**

MARQUES, R. A. Ajuste temporal do salário mínimo real com modelos SARIMA. *ForScience*, Formiga, v. 10, n. 2, e00905, jul./dez. 2022. DOI: 10.29069/forscience.2022v10n2.e1167.

² **Autor para correspondência:** Rodnei Alves Marques, rodnei.marques@ifmg.edu.br

1 INTRODUÇÃO

Os debates sobre o salário mínimo no Brasil se iniciaram na década de 1930. Nas discussões era proposto a construção e o aceite de um "sujeito mínimo" do trabalho elaborado em trocas sociais que estabeleciam entre as classes trabalhadoras, empregadores e estado. A demanda em torno da fixação do salário mínimo mostram grandes embates em torno do que seria "mínimo de dignidade", de "justiça" e de "viver bem" para o trabalhador (HOSTIN; DIANA, 2016).

Um levantamento da consultoria IDados mostrou que o número de trabalhadores brasileiros com renda de um salário mínimo chega a 30 milhões. Os números são de um estudo realizado em 2021 com base nos indicadores da pesquisa nacional por amostra de domicílio, concluindo que são 34,4% de trabalhadores estão recebendo até um salário mínimo.

De acordo com Prado et al. (2006), parece não haver controvérsias em relação à contribuição do salário mínimo para a diminuição da pobreza através de políticas de proteção social. O autor argumenta que o salário mínimo teve "impactos favoráveis na pobreza sob a ótica do trabalho", fato negado desde os primórdios de sua história. No entanto, há controvérsias em relação ao ritmo e sustentabilidade da contribuição do salário mínimo em ambiente de restrição fiscal e baixo crescimento do PIB brasileiro.

O valor do salário mínimo e a sua difusão dependem de um conjunto de circunstâncias macroestruturais e institucionais. Como o salário mínimo é um salário político e sua efetividade sobre os baixos salários depende não apenas de aspectos institucionais (fiscalização, poder de barganha, etc.), mas também da relação que ele guarda com outros salários. Ou seja, ao lado do seu poder de compra (valor absoluto) é necessário considerar o seu valor relativo (MEDEIROS, 2015).

Esse valor relativo discute o "efeito farol" e o "efeito propulsão" do salário mínimo sobre o setor informal. Para o primeiro, a expansão de maiores oportunidades ampliam a sua influência nos salários informalmente estabelecidos. Para o "efeito propulsão", o aumento do salário mínimo se deu por maior demanda, enquanto contribuía, paralelamente as políticas de transferência, para a redução da população ocupada.

Diante do tema, o objetivo é modelar e fazer previsões para a série mensal do salários mínimo real, de modo que as análises sejam mais uma alternativa às secretarias sociais e também para que organizações não governamentais preparem, juntamente com estudos sociais, um planejamento de ações que possam reduzir a diferença de renda dos trabalhadores brasileiros.

Os dados foram obtidas no banco de dados do Instituto de Pesquisas Econômicas Aplicadas IPEA (2022), que define salário mínimo real como sendo o valor do salário mínimo nominal

abatido o percentual de inflação do mês.

Para ajuste dos modelos foi utilizada a metodologia de Box & Jenkins, que consiste nos modelos autorregressivos integrados de médias móveis sazonais a série mensal do salário mínimo real. Essa metodologia parte do princípio de que os modelos temporais podem ser desenvolvidos em ciclos iterativos, onde a estrutura do modelo é baseada nos próprios dados. Foi escolhido o modelo que apresentou melhor ajuste e feitas previsões para o período de 2022/05 a 2023/02.

A série foi analisada com auxílio do *software* R e no *software* GRETL. O artigo está organizado da seguinte forma: na seção 2 é apresentada uma revisão de literatura com citações de trabalhos que desenvolveram previsões com modelos SARIMA; na seção 3 são abordados os materiais e métodos com apresentação dos dados e a metodologia adotada; na seção 4 os resultados e discussões com apresentação dos melhores modelos, consolidados com testes estatísticos; e por fim, na seção 5, são apresentadas as conclusões.

2 REVISÃO DE LITERATURA

O conceito de fazer previsões já é conhecido e pode ser encontrado nas mais diversas áreas do conhecimento, como por exemplo: engenharia, economia, saúde, meio ambiente, etc. Com previsões futuras é possível tomar decisões prévias e fazer correções em uma sequência de eventos. O pressuposto básico da análise de séries temporais é a de que fatores que influenciam o comportamento da série no passado continuarão a fazê-lo no futuro, conforme comentam [Araújo et al. \(2009\)](#).

Uma série temporal pode ser definida como um conjunto de observações discretas ou contínuas ao longo do tempo, que apresentam dependência de um instante para outro. Estas observações podem ser decompostas nos componentes de tendência, ciclo e sazonalidade. As análises e previsões podem ser feitas no domínio temporal com modelos paramétricos ou no domínio de frequências com modelos não paramétricos.

O estudo de séries temporais é necessário para investigar o mecanismo gerador da série, fazer previsões futuras, descrever seu comportamento temporal, além de procurar periodicidades relevantes. Existem vários modelos de ajuste temporal na literatura, aqui será apresentado uma aplicação do modelo SARIMA.

2.1 Modelos SARIMA

Modelos estatísticos para séries temporais autorregressivos de médias móveis (ARMA) tem sido utilizado amplamente para ajuste de séries econômicas, devido ao seu grande poder de modelagem e previsão. Os modelos são utilizados quando a série é estacionária, ou seja,

suas propriedades estatísticas, como média, variância e covariância permanecem constantes ao longo do tempo (HANKE; WICHERN, 2005). Entretanto, quando a série não é estacionária, ela é transformada em estacionária através de processos de diferenciação dos dados (Δ_1). Com isso é utilizada de interação $I(d)$, resultando no modelo ARIMA, também conhecido como metodologia Box & Jenkins.

O modelo tem como princípio que a série temporal seja gerada por um processo estocástico cuja natureza pode ser representada através de um modelo. A notação empregada para designação do modelo é $ARIMA(p, d, q)$, em que p representa o número de parâmetros autorregressivos, d o número de diferenciações para que a série se torne estacionária e q o número de parâmetros de médias móveis, ou seja, uma combinação linear dos termos que ocorrem atualmente e em momentos do passado.

Os modelos autorregressivo, integrado, de médias móveis, ou modelo ARIMA pode ser representado por:

$$\phi(B)\Delta^d Z_t = \theta(B)a_t \quad (1)$$

onde

$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é operador autorregressivo de ordem p ,

$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ é operador de médias móveis de ordem q , e

$\Delta^d = (1 - B)^d$, d indicando o número de diferenças aplicadas na série.

Algumas séries temporais apresentam padrões repetitivos que aparecem regularmente a cada intervalo de tempo. O efeito sazonal em determinados períodos do ano pode ocorrer, por exemplo, em séries de temperatura, na indústria em séries de vendas, em precipitações pluviométricas, ou seja, toda vez que um determinado comportamento aparece com frequência determinada.

As sazonalidades referem-se a movimentos de padrões regulares ou repetidos de curto prazo em torno de uma linha de tendência, em que os dados da série temporal parecem obedecer a períodos como dias, semanas, meses, etc. São classificados como movimentos sistemáticos causados por fenômenos não econômicos e aparecem quando as observações são intra-anuais (MORETTIN; TOLOI, 2006).

Para lidar com séries que apresentam autocorrelação sazonal, Box et al. (1994) generalizaram o modelo ARIMA e definiram o modelo ARIMA sazonal multiplicativo, também conhecido como modelo $SARIMA(p, d, q) \times (P, D, Q)$, representado por

$$\phi(B)\Phi(B^{12})\Delta_{12}^D \Delta^d Z_t = \Theta(B^{12})\theta(B)a_t \quad (2)$$

onde

$\Phi(B^{12}) = 1 - \Phi^1 B^{12} - \dots - \Phi_P B^{12P}$ é o operador autorregressivo sazonal de ordem P ,
 $\Theta(B^{12}) = 1 - \Theta^1 B^{12} - \dots - \Theta_Q B^{12Q}$ é o operador de médias móveis sazonal de ordem Q , e

$\Delta_{12}^D = (1 - B^{12})^D$, D indicando o número de diferenças sazonais.

De modo a produzir a condição de estacionalidade, não há, em princípio, dificuldades adicionais na identificação, estimação e verificação de modelos sazonais. A diferença será na diferenciação da série com respeito a Δ_1 e Δ_{12} .

2.2 Etapas da modelagem

A metodologia de Box & Jenkins, com objetivo de fazer previsões em séries temporais, é definida por quatro etapas interativas: identificação do modelo, estimativa dos parâmetros, diagnóstico e por fim, previsões.

• Identificação

Na primeira etapa de identificação do modelo SARIMA, são feitas diferenciações na série original e diferenciações sazonais, quantas forem necessárias, para que a série resultante seja estacionária. Os números de diferenciações d e D é aquele para que a função de autocorrelação amostral da série transformada decresça rapidamente para zero.

Para apontar o processo SAR, são feitas análises das funções de autocorrelação parcial (*facp*) e, para o processo SMA, é feita uma análise da função de autocorrelação (*fac*), com as séries diferenciadas em d e em D , para determinação dos parâmetros p , q , P e Q (MORETTIN; TOLOI, 2006). Para obedecer ao princípio da parcimônia, deve-se usar um modelo com melhor ajuste e menor número de parâmetros.

• Estimação dos parâmetros

Esta etapa é executada por meio de *software* específico para análise de séries temporais. São diversos métodos para estimação dos parâmetros com resultados semelhantes, embora exista diferença quanto à eficiência computacional. De modo mais geral, utiliza-se algum procedimento interativo de estimação de mínimos quadrados não linear ou utilizam-se métodos de máxima verossimilhança (MORETTIN; TOLOI, 2006).

• Verificação

O pesquisador necessita examinar previamente os pressupostos da regressão para que o uso do modelo seja eficaz na predição da variável dependente em estudo, bem como identificar

as consequências da sua violação. Entre as hipóteses estão: normalidade, independência e média dos resíduos.

Ao ajustar um modelo SARIMA, o objetivo é capturar toda estrutura de dependência e sazonalidade presente na série. Então, os resíduos do modelo não devem apresentar autocorrelação e autocorrelação parcial significativa, ou seja, os erros de previsão (resíduos) devem ser uma sequência de ruídos brancos. Os testes estatísticos nessa etapa envolvem verificações da condição de estacionalidade, normalidade dos resíduos, análise de significância dos parâmetros estimados e critérios de seleção de modelo. Os testes utilizados para verificação foram: teste de Box & Pierce, critério de Akaike e o teste de Shapiro-wilk.

• Previsões

Fazer previsões é um dos principais objetivos da análise de séries temporais, ou seja, prever um valor Z_{t+h} , com $h \geq 1$, supondo que temos as observações $\dots, Z_{t-2}, Z_{t-1}, Z_t$, até o instante t . A notação mais utilizada é denotada como $\hat{Z}_t(h)$, ou seja, previsão de origem t no tempo h .

Essas previsões também podem ser obtidas por meio de intervalos de confiança para os Z_{t+1}, Z_{t+2} , etc. No entanto, vale ressaltar que a variância aumenta a medida que h cresce, logo as amplitudes desses intervalos aumentam à medida que se afasta da origem t , caracterizando o aumento da incerteza das previsões.

3 METODOLOGIA

Os dados mensais do salário mínimo real no Brasil entre janeiro de 2000 e abril de 2022 (total de 268 observações) foram obtidos no banco de dados do Instituto de Pesquisas Econômicas Aplicadas [IPEA \(2022\)](#), vinculado ao Ministério da Economia. A Lei Complementar 103 permite que os estados fixem pisos estaduais superiores ao mínimo nacional, portanto, os dados da série analisada, para o período em que a legislação federal definia faixas diversificadas, referem-se sempre ao maior salário mínimo vigente no país.

Inicialmente, foi realizada uma análise descritiva da série com a construção do gráfico Salário (R\$) x Tempo (meses), para observar indícios visuais de tendência e sazonalidade. Em seguida verificada a necessidade de transformação logarítmica dos dados, por meio do gráfico amplitude versus média.

Foram aplicados os testes de Dickey Fuller Aumentado (ADF) e Kruskal-Wallis para verificar a presença de tendência e sazonalidade. Além disso, uma análise dos gráficos Amplitude vs Média e de subséries para um diagnóstico visual da tendência e sazonalidade.

Em seguida, tradicionalmente a seleção dos modelos ocorreu mediante observação das funções de autocorrelação (*fac*) e autocorrelação parcial (*facp*) na série livre de tendência e sazonalidade para estimar a ordem do modelo SARIMA(p, d, q)(P, D, Q).

Com a ordem do modelo identificada, foram estimados os parâmetros com utilização do método de máxima verossimilhança, e no último passo na construção do modelo, foi feita a verificação de sua adequação por meio do diagnóstico dos resíduos.

Com isso, após o ajuste, foram analisadas as funções *fac* e *facp* dos resíduos e aplicado o teste de Ljung-Box para verificar se os resíduos não são correlacionados, além da análise gráfica dos resíduos padronizados, efetivo x ajustado e efetivo x previsto.

O índice utilizado para a seleção dos modelos é o critério de informação Akaike - *Akaike Information Criterion* (AIC). Definido como $AIC = -2\log(L) + 2m$, sendo L a função de verossimilhança do modelo SARIMA ajustado; e m , o número de parâmetros do modelo (EHLERS, 2009). O melhor modelo ajustado foi escolhido segundo o critério de Akaike (AIC), valores menores indicam modelos mais próximos da série original, ou que têm menos perda de informação em relação à realidade (GUJARATI; PORTER, 2011).

As análises foram feitas com utilização do *software* R (Core Team, 2018), com emprego dos pacotes de ferramentas *forecast* - (HYNDMAN; KHANDAKAR, 2008), *tseries* (TRAPLETTI; HORNIK, 2022), *descomponer* (PARRA, 2021) *urca* - (PFAFF, 2008), *FitAR* - (MCLEOD; ZHANG, 2008), *runstats* - (KARAS; URBANEK, 2019), *randtests* - (CAEIRO; MATEUS, 2014) e *lmtest* - (ZEILEIS; HOTHORN, 2002). Também foi utilizado o *software* GRETL (ANDRADE, 2013).

4 RESULTADOS E DISCUSSÃO

Nessa seção serão apresentadas as análises com o modelo de ajuste SARIMA (p, d, q)(P, D, Q), obtidos com aplicação da metodologia de Box et al. (1994) na série temporal do salário mínimo real brasileiro, com objetivo de mostrar o bom ajuste do referido modelo para fazer previsões.

4.1 Identificação dos modelos

A proposta deste trabalho é a analisar da série temporal mensal dos salários mínimos reais entre janeiro de 2000 e abril de 2022, obtidos no banco de dados do Instituto de Pesquisas Econômicas Aplicadas IPEA (2022), vinculado ao Ministério da Economia do governo federal. Seguindo os primeiros passos de uma análise temporal, segue na Figura 1, a série mensal do salário mínimo real do período em estudo.

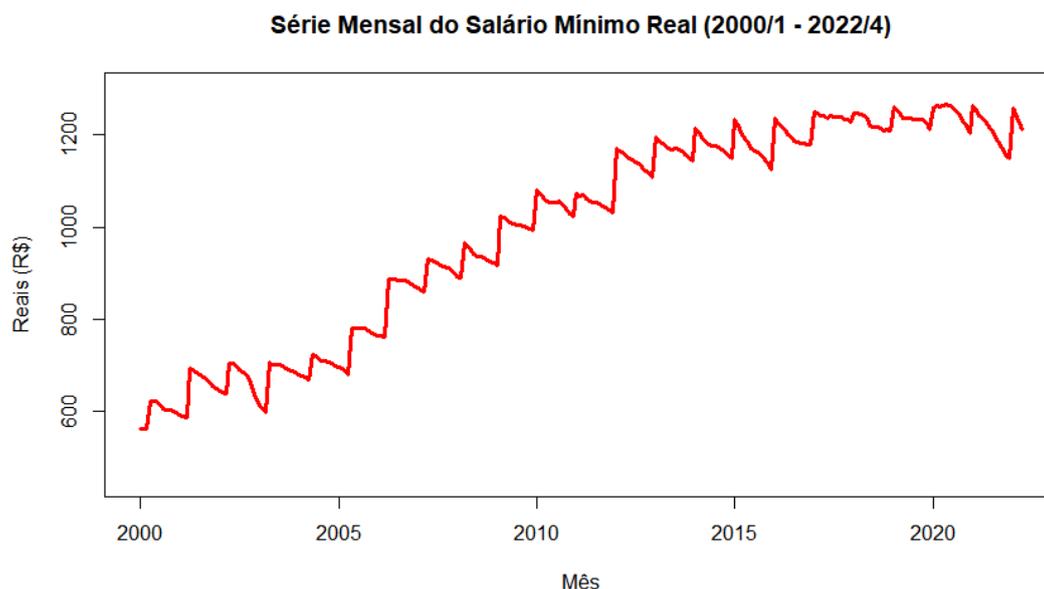


Figura 1 – Séries mensal dos salários mínimos reais (2000/01-2022/04)

A partir de uma inspeção visual do seu gráfico, Figura 1, a princípio, a série mostra indícios da presença de tendência e sazonalidade ao longo do tempo. Além disso, podemos observar, pelo comportamento da série, uma desaceleração do crescimento a partir de 2015.

Também observada por [Barbosa \(2012\)](#), que fez análises dos coeficientes de penetração das importações por setores industriais, e verificou que a concorrência externa e a valorização do câmbio afetaram a evolução dos salários. Além disso, observou-se a redução de postos de trabalho de melhor qualificação com maiores salários e um crescimento menor dos salários dos trabalhadores mais qualificados.

Ao iniciar a análise da série foi verificado a necessidade de transformação dos dados. Com a análise do gráfico da amplitude versus média, Figura 2a, constatou-se a não necessidade de transformação dos dados, já que a média não se mostrou diretamente proporcional à amplitude.

O efeito da sazonalidade pode ser constatado com a análise da Figura 2b, onde observa-se o comportamento semelhante dos gráficos das sub-séries fixado os 12 meses. Também comprovado com o teste de Kruskal - Wallis, p-valor de 0.0488, rejeitando a hipótese nula de não existência de sazonalidade. Vale ressaltar, que as análises de séries temporais são feitas em séries estacionárias, já que séries não estacionárias podem fornecer resultados preditivos viesados. Com isso, série foi submetida ao teste de raiz unitária (ADF) para verificar a existência ou não de estacionalidade. Com p-valor de 0,9527, mostrou-se que a hipótese nula de pelo menos

uma raiz dentro do círculo unitário não é rejeitada, ou seja, que a série não é estacionária. Comprovando o observado com a análise visual da série, o aumento ao longo do tempo do salário mínimo real.

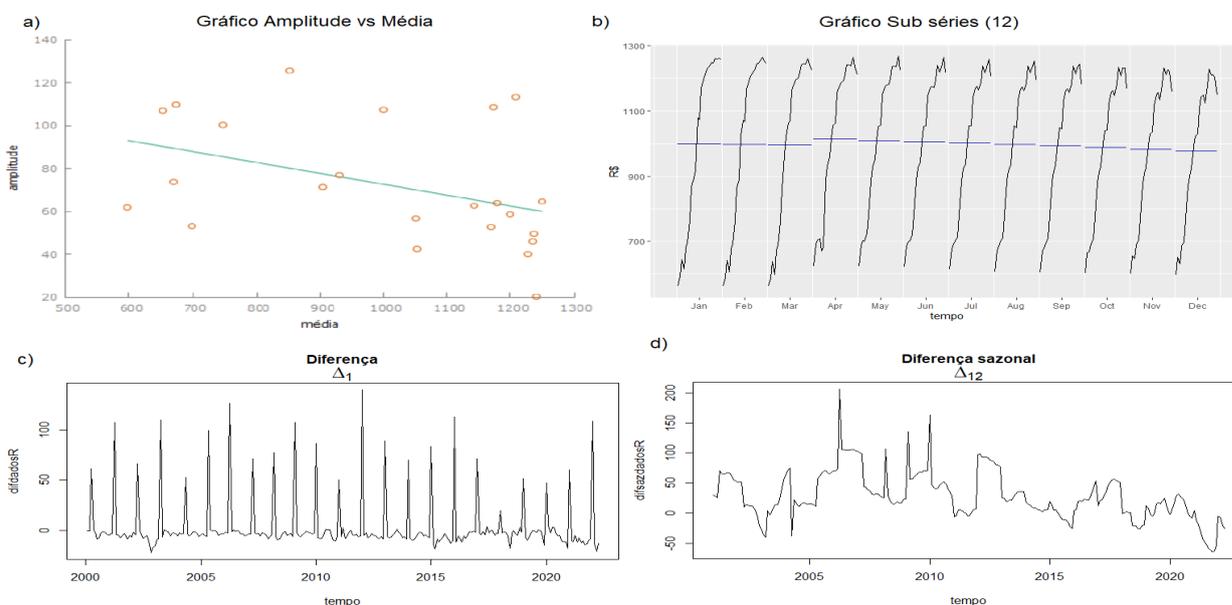


Figura 2 – Gráficos - Amplitude vc Média, Sub séries, Primeira diferença (Δ_1) e Diferença sazonal (Δ_{12})

A aplicação de diferenças Δ_1 na série é uma forma de transformá-la em estacionária. O número de diferenças necessárias para essa transformação será a componente de integração (d) do modelo $SARIMA(p, d, q) \times (P, D, Q)$. Após a aplicação da primeira diferença, percebe-se, pelo gráfico na Figura 2c, que a série diferenciada apresenta estacionalidade, contendo ainda a componente sazonal.

Da mesma forma, para retirar o efeito da sazonalidade, são aplicadas diferenças Δ_{12} na série (foi considerado um período sazonal $s = 12$ meses), a fim de produzir uma estacionariedade. O número de diferenças necessárias para transformá-la em estacionária será o componente (D) do modelo $SARIMA(p, d, q) \times (P, D, Q)$. Na Figura 2d, é mostrado o gráfico da primeira diferença sazonal Δ_{12} da série em análise.

Para comprovar que após as primeiras diferenças a série tornou-se estacionária, foi aplicado novamente o teste ADF a série diferenciada. Com p-valores de 0,01, comprovou-se que após a primeira diferença a série se torna estacionária. Ademais, foi verificado que após a primeira diferença sazonal, por meio do gráfico das subséries, que a série não apresentou mais efeito sazonal, concluímos então que os parâmetros $d = 1$ e $D = 1$ no modelo SARIMA.

4.2 Estimação dos modelos

Para verificar da ordem do modelo SARIMA(p,d,q)x(P,D,Q) a ser ajustado, foram analisados os gráficos das funções de autocorrelação e autocorrelação parcial da série diferenciada Δ_1 e Δ_{12} , eles indicam os primeiros modelos a serem experimentados. Na Figura 3, são mostradas as funções de autocorrelação e autocorrelação parcial da série com a primeira diferença e a diferença sazonal.

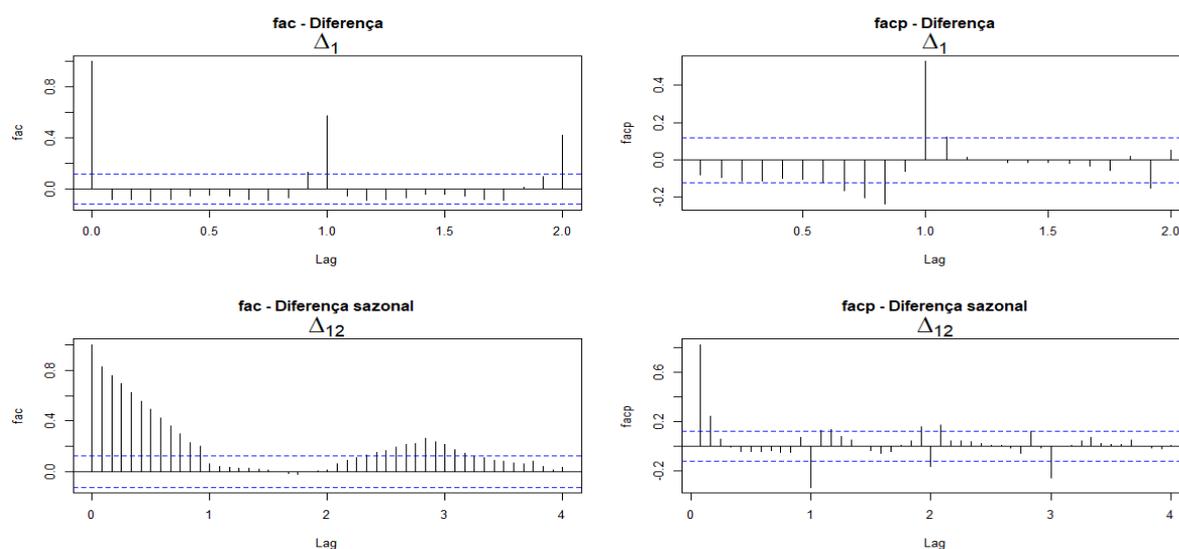


Figura 3 – Funções de autocorrelação e autocorrelação parcial da série diferenciada

Com análises dos correlogramas na Figura 3, foram testados os modelos SARIMA(0,1,1)x(0,1,1), SARIMA (0,1,1)x(1,1,1), SARIMA (1,1,1)x(0,1,2) e SARIMA(1,1,1)x(2,1,0) para a série mensal do salário mínimo real. Como a série tornou-se estacionária com a primeira diferença temporal e primeira diferença sazonal, todos os modelos foram rodados com $d = 1$ e $D = 1$. Os critérios AIC para cada modelo são apresentados na Tabela 1.

Tabela 1 – Critério de Akaike para os modelos estimados

Modelos	AIC
SARIMA(0,1,1)x(0,1,1)	2251,42
SARIMA(0,1,1)x(1,1,1)	2250,06
SARIMA(1,1,1)x(0,1,2)	2248,14
SARIMA(1,1,1)x(2,1,0)	2253,44

Fonte: Autores (2022).

Na Tabela 1, observa-se a partir do critério de AIC e pelo princípio da parcimônia, que o melhor ajuste foi do modelo SARIMA(1,1,1)x(0,1,2) sem necessidade de constante. Na Tabela 2, são mostrados os coeficientes, o erro padrão e o p-valor para o modelo escolhido.

Tabela 2 – Coeficientes do modelo ajustado

Modelo	Coeficientes	Erro padrão	p-valor
SARIMA (1,1,1)x(0,1,2)	$\phi_1 = +0,4119$	0,1968	0,0364
	$\theta_1 = -0,6792$	0,1617	$2,6 \times 10^{-5}$
	$\Theta_1 = -0,4927$	0,0685	$6,3 \times 10^{-13}$
	$\Theta_2 = -0,1277$	0,6805	0,0506

Fonte: Autores (2022)

O modelo SARIMA(1,1,1)x(0,1,2) para previsão, pode ser escrito da seguinte forma:

$$(1 - 0,4119B)\hat{Z}_t = (1 + 6792B)(1 + 04927B^{12} + 0,1277B^{24})a_t, \quad (3)$$

No passo seguinte, foi verificado a adequação do modelo com base na análise dos resíduos.

4.3 Verificação dos modelos

Seguindo na análise de uma série temporal, o próximo passo foi verificar se o modelo ajustou-se de forma adequada aos dados, com um nível de 5% significância. Na figura 4, o correlograma mostra um comportamento aleatório dos resíduos com a maioria dos legs dentro do intervalo de confiança. Observa-se também, pela Figura 4, que os erros médios padronizados não são correlacionados, indicando um bom ajuste.

Considerando a importância das previsões no incentivo de estudos em outras áreas e respeitando o princípio da parcimônia e acurácia, a escolha do modelo mais adequado pode apresentar melhores previsões. Com isso, para garantir o que foi visualizado com a análise gráfica dos resíduos, foi aplicado o teste Ljung-Box e, com p-valor de 0,8021 e 5% de significância, concluiu-se que os resíduos do modelo SARIMA(1,1,1)(0,1,2) ajustado a série mensal de salário mínimo real não apresenta correlação.

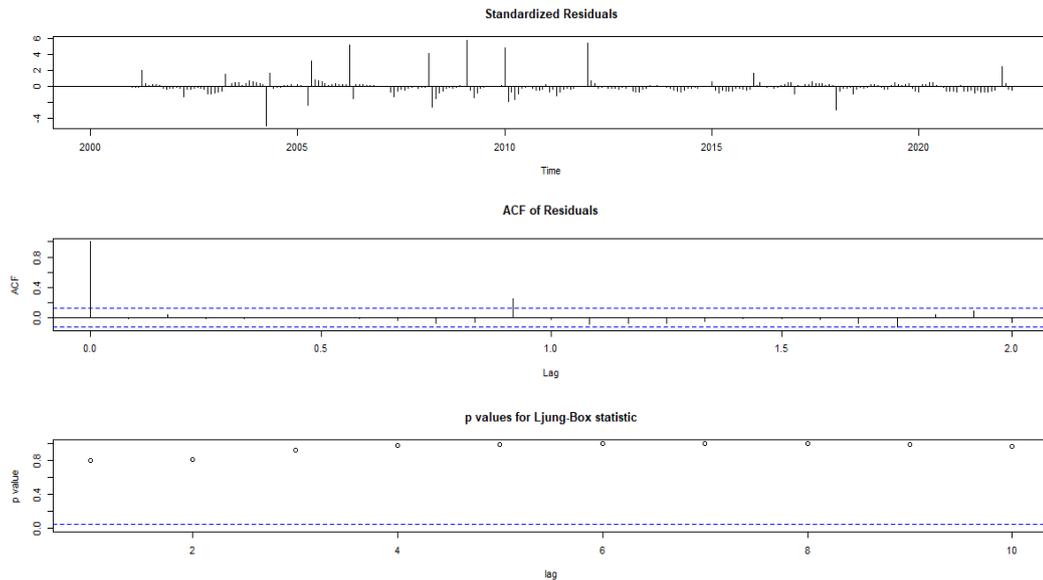


Figura 4 – Resíduos padronizados, função de autocorrelação dos resíduos e teste Ljung-Box

Também observa-se pelo gráfico efetivo x ajustado, Figura 5a, que o modelo SARIMA $(1,1,1) \times (0,1,2)$ ajustado (linha vermelha) se aproxima muito da série original (linha verde) mostrando o bom ajuste do modelo aos dados. Informação complementada com o gráfico efetivo x previsto, Figura 5b, mostrando a existência de uma relação linear entre os valores reais e os previstos pelo modelo.

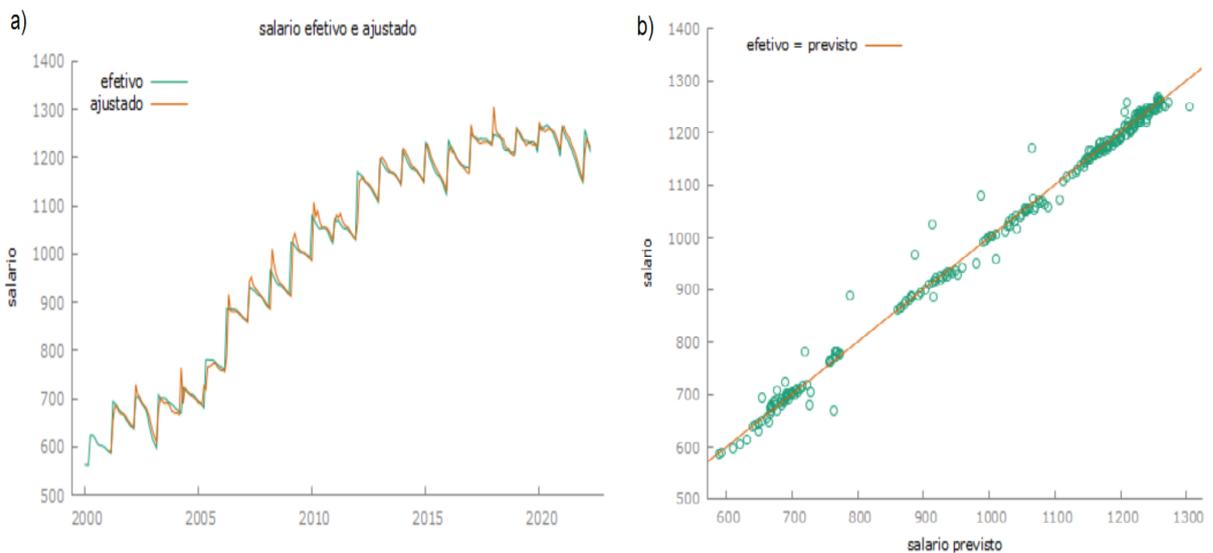


Figura 5 – Gráfico efetivo x ajustado em (a) e gráfico efetivo x previsto em (b)

4.4 Previsões com modelo SARIMA(1,1,1)x(0,1,2)

Nesta etapa do trabalho, foram traçadas previsões dos salários mínimos reais para um horizonte de 10 meses a frente, ou seja, são meses que não foram considerados no ajuste do modelo auto regressivo de médias móveis, sazonal de ordem (1,1,1)x(0,1,2). Utilizando esse modelo, foram feitas previsões futuras na série temporal e, os valores pontuais e por intervalo, previstos para os próximos 10 meses, ao nível de 5% de significância, são apresentados na Tabela 3.

Tabela 3 – Previsões futuras da série salário mínimo real

Mês	Intervalos (R\$)	Previsões (R\$)
2022/05	1168,38 : 1243,99	1206,19
2022/06	1154,06 : 1247,79	1200,93
2022/07	1140,82 : 1245,71	1193,27
2022/08	1130,18 : 1243,79	1186,99
2022/09	1117,30 : 1238,50	1177,90
2022/10	1104,36 : 1232,52	1168,44
2022/11	1093,37 : 1228,06	1160,71
2022/12	1081,05 : 1221,93	1151,49
2023/01	1160,84 : 1307,64	1234,24
2023/02	1149,75 : 1302,24	1226,00

Fonte: Autores (2022)

As previsões feitas pelo modelo proposto, Tabela 3, aponta o decréscimo esperado com a inflação e uma estimativa de depreciação aproximada de 4,99% entre abril e dezembro de 2022 e, considerando os valores na série de janeiro a abril, de aproximadamente 8,5% para o ano de 2022. Além disso, observa-se um aumento para o salário mínimo real em torno de 7,38% para 2023. Posto isto, está previsto, segundo o modelo ajustado, um aumento menor do salário mínimo real para 2023 do que as perdas acumuladas de 2022.

Por fim, observou-se que a previsão do salário mínimo real para janeiro de 2023 (R\$ 1234,24) é menor que janeiro de 2022 (R\$ 1258,00), comprovando a perda do poder de compra dos trabalhadores com a inflação. Na Figura 6, são mostradas graficamente essas conclusões com o gráfico das previsões futuras.

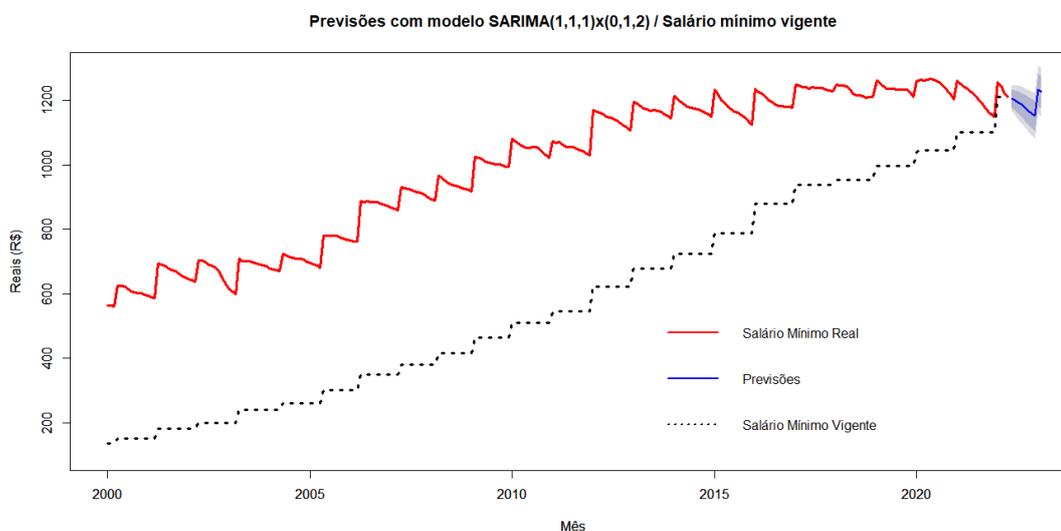


Figura 6 – Gráfico com previsões para a série de salário mínimo real (2022/5 - 2023/02)

Vale ressaltar, observando a linha vermelha da série original e a linha azul das previsões, que o modelo SARIMA(1,1,1)x(0,1,2) ajustado aos dados conseguiu prever a sazonalidade que ocorrerá entre dezembro de 2022 e janeiro de 2023, período em que o governo federal aumenta o valor do salário mínimo nacional, elevando assim os salários mínimos estaduais.

Junto ao gráfico das previsões, Figura 6, foi colocado a série do salário mínimo vigente, que de acordo com IPEA (2022), é o piso mínimo nacional que não considera abonos salariais ocorridos no período. Percebe-se que existe uma convergência dos valores do salário mínimo real para o salário mínimo vigente ao longo do período estudado, ou seja, além das perdas com a inflação os estados tendem cada vez mais utilizar como referência o salário mínimo nacional.

5 CONCLUSÃO

A presente proposta aplicou a metodologia Box et al. (1994) com o modelo SARIMA à série mensal do salário mínimo real no Brasil e, assim, ajustou um modelo sazonal para prever as flutuações até fevereiro de 2023. Foi verificado, de maneira geral, que o modelo SARIMA(1,1,1)x(0,1,2) de Box & Jenkins ajustou-se bem aos dados a ponto de fazer previsões seguras com nível de significância de 5%, além de predizer a sazonalidade esperada para 2023. Com isso, políticas públicas podem ser direcionadas com base nessas análises para diminuir o impacto da inflação no poder de compra dos trabalhadores. Por fim, o modelo prevê um aumento para o salário mínimo real em 2023 menor do que as perdas acumuladas ao longo de 2022. Como se trata de um estudo inicial de análise, é possível considerá-lo como ponto de

partida para pesquisas subsequentes em outras áreas de conhecimento.

REFERÊNCIAS

- ANDRADE, C. H. C. **Manual de introdução ao pacote econométrico Gretl**. 2013. Disponível em: <<https://s3.amazonaws.com/academia.edu.documents/39579087/Gretl.pdf>> Acesso em: 25 mai. 2022.
- ARAÚJO, M. F. C. et al. Precipitação pluviométrica mensal no estado do rio de janeiro: sazonalidade e tendência. **Bioscience Journal**, Uberlândia, v. 25, n. 4, p. 90–100, 2009.
- BARBOSA, L. M. D. L. H. A evolução recente da distribuição de renda brasileira sob a ótica das estruturas sócio-ocupacionais. **Rio de Janeiro**, 2012.
- BOX, G. E. et al. **Time series analysis: forecasting and control**. 3. New Jersey: Prentice Hall, 1994.
- CAEIRO, F.; MATEUS, A. **Randtests: testing randomness in R**. [S.l.], 2014. R package version 1.0. Disponível em: <<https://CRAN.R-project.org/package=randtests>> Acesso em: 25 mai. 2022.
- EHLERS, R. **Apostila Análise de Séries Temporais**. 5. ed. ed. UFPR: Curitiba, 94p, 2009.
- GUJARATI, D. N.; PORTER, D. C. **Econometria básica-5**. [S.l.]: Amgh Editora, 2011.
- HANKE, J. E.; WICHERN, D. W. **Business forecasting**. [S.l.]: Pearson Educación, 2005.
- HOSTIN, E. G.; DIANA, M. H. N. **O sujeito mínimo do salário: os discursos e as representações do trabalho e do trabalhador na criação do salário mínimo no brasil (1920-1940)**. 2016. Disponível em: <<https://eventos.ifc.edu.br/wp-content/uploads/sites/22/2016/12/>> Acesso em: 25 mai. 2022.
- HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for R. **Journal of Statistical Software**, [S.l.], v. 26, n. 3, p. 1–22, 2008. Disponível em: <<http://www.jstatsoft.org/article/view/v027i03>> Acesso em: 25 mai. 2022.
- IPEA. Instituto de pesquisas econômicas e aplicadas. **Tema: Economia**, 2022. Disponível em: <<http://www.ipeadata.gov.br/Default.aspx>> Acesso em: 25 mai. 2022.
- KARAS, M.; URBANEK, J. **Runstats: fast computation of running statistics for time series**. [S.l.], 2019. R package version 1.1.0. Disponível em: <<https://CRAN.R-project.org/package=runstats>> Acesso em: 25 mai. 2022.
- MCLEOD, A. I.; ZHANG, Y. Improved subset autoregression: With R package. **Journal of Statistical Software**, v. 28, n. 2, p. 1–28, 2008. Disponível em: <<http://www.jstatsoft.org/v28/i02/>> Acesso em: 25 mai. 2020.

MEDEIROS, C. A. d. A influência do salário mínimo sobre a taxa de salários no Brasil na última década. **Economia e Sociedade**, Campinas, v. 24, p. 263–292, 2015.

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

PARRA, F. **Descomponer**: seasonal adjustment by frequency analysis [S.1.], 2021. R package version 1.6. Disponível em: <<https://CRAN.R-project.org/package=descomponer>>.

PFÄFF, B. **Analysis of integrated and cointegrated time series with R**. 2. ed. New York: Springer, 2008. Disponível em: <<http://www.pfaffikus.de>> Acesso em: 25 mai. 2022.

PRADO, A. et al. Valorização do salário mínimo reduz a desigualdade. Banco Nacional de Desenvolvimento Econômico e Social, 2006.

TRAPLETTI, A.; HORNIK, K. **Tseries**: time series analysis and computational finance [S.1.], 2022. R package version 0.10-51. Disponível em: <<https://CRAN.R-project.org/package=tseries>>.

ZEILEIS, A.; HOTHORN, T. Diagnostic checking in regression relationships. **R News**, v. 2, n. 3, p. 7–10, 2002. Disponível em : <<https://CRAN.R-project.org/doc/Rnews/>> Acesso em: 25 mai. 2022.

DADOS DO AUTOR

Nome: Rodnei Alves Marques

E-mail: rodnei.marques@ifmg.edu.br

Lattes: <http://lattes.cnpq.br/4173660058765943>

Doutor em Estatística pela Universidade Federal de Lavras (UFLA), curso de Formação Didática em Matemática pelo CIEP (Centre international d'études Pédagogiques - França), Mestrado Profissional em Matemática pela UFLA, Bacharel em estatística pela Universidade Federal de Ouro Preto (UFOP) e Licenciado em Matemática pela Universidade Federal de Minas Gerais (UFMG). Experiência na área de Matemática com ênfase em Álgebra e Cálculo, na área da Estatística com ênfase em Séries Temporais e Transformações Wavelets. Atualmente professor do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG) - Campus Santa Luzia, com atuação nos cursos: Bacharelado em Engenharia Civil, Técnico em Edificações, Técnico em Segurança do Trabalho e Técnico em Paisagismo.