

---

## Ajuste de modelos de séries temporais com intervenção para prever o consumo de gasolina no Brasil

Nádia G. Biase<sup>1†</sup>, Maria Imaculada S. Silva<sup>2</sup>

<sup>1</sup> Faculdade de Matemática (FAMAT), Universidade Federal de Uberlândia (UFU)

<sup>2</sup> Faculdade de Matemática (FAMAT), Universidade Federal de Uberlândia (UFU).

E-mail: [maria@famat.ufu.br](mailto:maria@famat.ufu.br).

**Resumo:** O consumo de gasolina no Brasil vem passando por consideráveis oscilações ao longo dos anos em decorrência de vários fatores, dentre eles o lançamento dos veículos flex, que podem ser movidos à gasolina, álcool ou uma mistura dos dois combustíveis. Assim, este trabalho teve como principais objetivos analisar o comportamento do consumo médio de gasolina em mil barris/dia no Brasil por meio da análise de séries temporais, averiguar o efeito de sazonalidade, tendência e intervenção e fazer previsões a partir dos modelos de Box Jenkins ajustados. Os dados referente ao consumo médio mensal de gasolina em barris/dia, coletados durante o período de janeiro de 1979 a abril de 2012, foram obtidos no banco de dados do Instituto de Pesquisa Econômica Aplicada (IPEA). Foi possível identificar na série em estudo a presença das componentes tendência e sazonalidade, e dentre os modelos de Box Jenkins, os modelos SARIMA foram os que ajustaram adequadamente aos dados. De acordo com os critérios de seleção de modelos, AIC (Akaike information Criterion), BIC (Information Bayesiano Criterion) e EQMP (Erro Quadrático Médio de Previsão), o modelo SARIMA(2, 1, 0)(0, 1, 1)<sub>12</sub> com intervenção foi o mais apropriado para realizar as previsões.

**Palavras-chave:** tendência; sazonalidade; modelo SARIMA; intervenção; previsão.

**Abstract:** The gasoline consumption in Brazil has undergone considerable fluctuations over the years due to several factors, including the launch of flex-fuel vehicles that can be moved by gasoline, ethanol or a mixture of the two fuels. This work had as main objective to analyze the behavior of the average gasoline consumption in thousand barrels/day in Brazil through time series analysis, verify the effect of seasonality, trend and intervention and making forecasts from the fitted models of Box Jenkins. The data regarding the average monthly consumption of gasoline in barrels/day, collected during the period january 1979 to april 2012 were obtained from the database of the Institute of Applied Economic Research (IPEA). Were identified in the study series on the presence of trend and seasonal components, and models from the Box Jenkins, SARIMA models that were adjusted appropriately to the data. According to the criterion for selection of models, AIC (Akaike information Criterion), BIC (Bayesian Information Criterion) and MSE (Mean Square Error of Prediction), SARIMA(2, 1, 0)(0, 1, 1)<sub>12</sub> model with the intervention was more appropriate for making forecasts.

**Keywords:** trend; seasonality; SARIMA model; intervention; forecasts.

---

<sup>†</sup> Autor correspondente: [nadia@famat.ufu.br](mailto:nadia@famat.ufu.br).

## Introdução

No decorrer das últimas décadas, o consumo de gasolina no Brasil foi afetado de maneira significativa por diversos fatores. Com a implementação do Programa Nacional do álcool (Proálcool) em 1978, o governo incentivou a produção de carros movidos somente a álcool, reduzindo impostos e mantendo o preço do álcool inferior ao da gasolina, o que repercutiu na queda do consumo da gasolina no país. Com a crise desse programa nos anos seguintes, o consumo nacional da gasolina voltou a crescer continuamente por mais de uma década.

Por volta de 1995, os preços dos combustíveis deixaram de ser controlados pelo governo, passando a existir consideráveis oscilações entre os preços do álcool e da gasolina. Por fim, outro fator que tem causado grande impacto no consumo de gasolina no país, desde o ano de 2003, é o lançamento dos veículos flex, que podem ser movidos à gasolina, álcool ou uma mistura dos dois combustíveis. Essa flexibilidade de escolha entre esses combustíveis influenciou fortemente na demanda de gasolina e, atualmente a relação entre os preços da gasolina e do álcool, faz com que os consumidores desse tipo de veículos deem preferência à gasolina (WOSH, 2010).

Assim, torna-se necessário o estudo do comportamento do consumo da gasolina no Brasil ao longo dos anos e, uma das técnicas estatísticas que podem ser utilizadas com essa finalidade é a análise de séries temporais. Uma série temporal é um conjunto de observações ordenadas ao longo do tempo. Uma particularidade relevante desse tipo de dados é que pode existir correlação entre as observações e, neste caso, um dos objetivos do estudo das séries temporais é modelar e analisar essa correlação (MORETTIN; TOLOI, 2006).

Geralmente, uma série temporal ( $Z_t$ ,  $t = 1, 2, \dots, n$ ) pode ser decomposta em função do seguinte modelo:  $Z_t = T_t + S_t + a_t$ , em que  $T_t$  representa a tendência da série e pode ser entendida como um aumento ou diminuição gradual das observações ao longo de um período;  $S_t$  representa a sazonalidade da série, e mostra as flutuações ocorridas em períodos menores que um ano, podendo ser, por exemplo, trimestral, mensal ou diária e,  $a_t$  denota as oscilações aleatórias irregulares. Habitualmente, supõe-se que  $a_t$  seja uma série puramente aleatória e ou ruído branco, com média zero e variância constante.

Segundo Morettin e Toloi (2006) existem vários métodos possíveis de ajustar um modelo de uma série temporal e, uma abordagem bastante utilizada é a de Box e Jenkins. Essa abordagem consiste em ajustar modelos autorregressivos integrados de médias móveis (ARIMA), que são apropriados para descrever séries não estacionárias, ou seja, séries que apresentam tendência e ou sazonalidade. Vale ressaltar que mesmo na ausência da sazonalidade o modelo ARIMA pode ser utilizado para ajustar um conjunto de dados.

No entanto, quando a série temporal apresenta um comportamento periódico em um período máximo de 12 meses é necessário acrescentar uma componente sazonal no modelo, que pode ser estocástica ou determinística. Segundo Box e Jenkins (1976) uma série sazonal é estocástica quando as correlações nos “lags” sazonais são significativas, ou seja, múltiplas do período sazonal e, determinística quando após tomar diferenças sazonais a série se torna estacionária. Nestas condições, a série original pode ser ajustada por meio de um modelo ARIMA sazonal, denominado SARIMA.

Além disso, existem alguns fenômenos que podem afetar o comportamento de uma série temporal e devem ser incorporados no modelo a ser ajustado. Esses fenômenos são conhecidos por intervenção, e representam uma mudança de nível ou inclinação ocorrida com os dados em um determinado instante do tempo, devido a algum motivo conhecido ou não, que podem afetar temporariamente ou permanentemente a série em estudo.

Gonçalves e Sáfiadi (2008) utilizaram modelos de séries temporais para prever séries que compõem o setor energético brasileiro, tais como a produção de cana de açúcar, álcool, óleo diesel e gasolina. Para a produção mensal de gasolina, no período de janeiro de 2000 a setembro de 2006, foram ajustados modelos ARIMA com e sem intervenção, e de acordo com os resultados obtidos, o modelo ARIMA sem intervenção apresentou melhores valores de previsão.

Buscando avaliar o quanto as mudanças no imposto estadual ICMS (Imposto sobre Circulação de Mercadorias e Prestação de Serviços) influencia sobre o consumo de gasolina C, que é uma combinação de gasolina pura com álcool etílico anidro carburante, nos estados do Ceará, Pernambuco, Sergipe, Rio de Janeiro, Paraná, Rio Grande do Sul e Mato Grosso do Sul no período de julho de 2001 a dezembro de 2008, Vilela e Júnior (2010) utilizaram um modelo matemático estimado com base na econometria de séries temporais e verificaram que existem diferenças significativas entre a sensibilidade do mercado de gasolina C nos estados avaliados. Além disso, os resultados indicaram que o consumo de gasolina C é influenciado pelas variáveis: preço da gasolina C, preço do álcool hidratado, renda dos trabalhadores e a frota de automóveis flex.

Fernandes et al. (2012), ao desenvolverem um modelo de autorregressão vetorial reparametrizado, denominado Vetor de Correção e Erro (VEC), para estimar a demanda de gasolina C no Estado de Minas Gerais, verificaram também que essas mesmas variáveis (preço da gasolina C, preço do álcool hidratado e a renda do consumidor) foram relevantes para explicar a variabilidade da demanda de gasolina C em Minas Gerais, no período de janeiro de 2002 a dezembro de 2010. Quanto ao preço da gasolina C no curto e no longo prazo, as referidas autoras concluíram que a demanda foi inelástica. Em relação a renda a longo prazo a demanda é considerada elástica, enquanto a curto prazo ela se revelou inelástica. Já o álcool hidratado é um substituto imperfeito da gasolina C, tanto no curto quanto no longo prazo, uma vez que constatou-se uma correlação positiva entre o preço do álcool hidratado e a quantidade de gasolina C, de modo que se houver um aumento (diminuição) de 10% no preço do álcool hidratado, isso implica em um aumento (redução) de 1,386% na quantidade demandada de gasolina C.

Com o objetivo de prever o consumo de gasolina, óleo diesel, óleo combustível e álcool no Brasil no período de 2008 a 2017, Santiago et al. (2011) estabeleceram um modelo a partir da integração de séries temporais com um modelo de insumo-produto híbrido e, as previsões apontaram crescimento significativo da demanda dos quatro grupos de combustível analisados nos próximos dez anos.

Muradásneto et al. (2008) ajustaram modelos de previsão para a série de preços mensais da gasolina e do álcool na cidade de Lavras-MG, correspondente a janeiro de 1994 a dezembro de 2004. Ambas as séries apresentaram tendência e intervenção significativa, o que possibilitou o ajuste de modelos ARIMA com intervenção. Segundo os autores essa intervenção pode ser explicada pela inserção dos veículos flex, o que ocasionou um aumento acentuado da demanda pelo álcool, e influenciou no preço destes combustíveis.

Figueira e Burnquist (2006) desenvolveram um estudo com o intuito de delinear cenários para o consumo de etanol como combustível nos EUA, no período de 2004 a 2012. Para tal finalidade, utilizaram os modelos de séries temporais de Box-Jenkins para efetuar as projeções do consumo americano de gasolina e, dentre os modelos ajustados, os autores verificaram que o modelo SARIMA apresentou melhores valores de previsão.

Em virtude da grande eficácia e confiabilidade das previsões realizadas a partir dos modelos de Box-Jenkins, essa metodologia se difundiu em diferentes áreas, tais como, para prever o número de casos dengue em Ribeirão Preto-SP (MARTINEZ; SILVA, 2011), a demanda do número de atendimentos de clientes de uma empresa prestadora de serviços de assistência técnica em equipamentos de informática (WERNER; RIBEIRO, 2003), a temperatura média mensal da cidade de Uberlândia-MG (SILVA et al., 2008), a taxa de desemprego na Região Metropolitana de Recife (ANDRADE, 2011), entre outras aplicações.

Assim, realizou-se o presente trabalho, com o objetivo de analisar o consumo médio mensal da gasolina em mil barris/dia a nível nacional, buscando descrever o comportamento da série por meio dos modelos de Box e Jenkins sem e com o efeito das intervenções e ajustar modelos de previsão que possam prever valores futuros para o consumo de gasolina no país.

## Metodologia

Os dados avaliados foram obtidos por meio do banco de dados do Instituto de Pesquisa Econômica Aplicada (IPEA), disponíveis na internet na página <http://www.ipeadata.gov.br/>. A variável em estudo se refere ao consumo médio mensal da gasolina em mil barris/dia, abrangendo o período de janeiro de 1979 a abril de 2012, totalizando 400 observações. Os últimos seis valores foram reservados para comparar com os valores preditos, consequentemente, a série foi analisada com 394 observações.

Para ajustar os modelos da série temporal, o primeiro passo, foi analisar graficamente a série original para verificar a existência de possíveis componentes (tendência e ou sazonalidade) e intervenções. A existência das componentes, tendência e sazonalidade, foram comprovadas por meio do teste de Cox-Stuart e o de Fisher, respectivamente. Para avaliação do teste de Cox-Stuart a série foi dividida em dois grupos, que permitiu comparar as observações  $(Z_1, Z_{1+c})$ ,  $(Z_2, Z_{2+c})$ ,  $\dots$ ,  $(Z_{N-c}, Z_N)$ , sendo  $c = \frac{N}{2}$ . Nas situações em que  $Z_i < Z_{i+c}$  foi atribuído o sinal “+” e nos casos em que  $Z_i > Z_{i+c}$  o sinal “-”, os empates foram eliminados, de modo que  $n$  representou o número total de pares em que  $Z_i \neq Z_{i+c}$ . As hipóteses testadas foram:

$$H_0 : P(Z_i < Z_{i+c}) = P(Z_i > Z_{i+c}), \forall i : \text{n\~{o} existe tend\~{e}ncia};$$

$$H_1 : P(Z_i < Z_{i+c}) \neq P(Z_i > Z_{i+c}), \forall i : \text{existe tend\~{e}ncia}.$$

Adotando  $T_2$  como sendo o número de pares com sinal positivo, a hipótese de nulidade será rejeitada quando  $T_2 \geq n - t$ , em que  $t$  se aproxima de uma distribuição normal com média 0,  $5n$  e variância 0,  $25n$ , considerando um nível de significância  $\alpha$ , sempre que  $n > 20$ .

Para verificar a existência da sazonalidade, foram testadas as seguintes hipóteses ao aplicar o teste de Fisher:

$$H_0 : \text{N\~{o} existe sazonalidade};$$

$$H_1 : \text{Existe sazonalidade}.$$

A estatística deste teste é obtida com base nas análises dos periodogramas e pode ser calculada de acordo com a expressão:

$$g = \frac{\max_j I_j^{(N)}}{\sum_{j=1}^{\lfloor \frac{N}{2} \rfloor} I_j^{(N)}}$$

em que  $I$  representa o valor do periodograma no período  $j$  e  $N$  indica o número de observações da série. A decisão do teste é tomada em relação a distribuição exata de  $g$ , dada por  $z_\alpha = 1 - \left(\frac{\alpha}{2}\right)^{\frac{1}{c-1}}$  sendo  $c = \frac{N}{2}$  e  $\alpha$  o nível nominal de significância, e nas situações em que  $g > z_\alpha$ , a hipótese  $H_0$  é rejeitada e a série apresenta periodicidade no período  $j$ .

O segundo passo consistiu em eliminar as componentes presentes para que a série se tornasse estacionária, e posteriormente, foram ajustados os modelos de Box e Jenkins da classe SARIMA, observando-se as correlações significativas da  $\text{fac}$  e  $\text{facp}$  construídas a partir da série livre de tendência e sazonalidade.

Na sequência, utilizaram-se as estimativas das funções de autocorrelação e autocorrelação parcial para testar se o ajuste dos modelos era adequado, isto é, se o resíduo da série em estudo era independente e identicamente distribuído, com média zero e variância constante, denominado neste caso, de ruído branco. Para tal finalidade, aplicou-se o teste de Box-Pierce, proposto por (PRIESTLEY, 1989), que compara a estatística  $Q$  da função de autocorrelação com a distribuição de qui-quadrado com  $k-p-q$  graus de liberdade, sendo  $k$  as primeiras estimativas das autocorrelações,  $p$  e  $q$  a ordem do modelo autorregressivo e médias móveis, respectivamente.

Posteriormente, para selecionar o melhor modelo dentre os modelos propostos, utilizaram-se os seguintes critérios: Akaike information Criterion (AIC), Bayesian Information Criterion (BIC) e o Erro Quadrático Médio de Previsão (EQMP). O modelo escolhido foi aquele que apresentou o menor valor para esses critérios.

## Resultados e discussão

Na Figura 1 é apresentada a série original do consumo médio mensal da gasolina em mil barris/dia no Brasil. A análise preliminar do comportamento desta série não permite afirmar que existe a presença da sazonalidade, apenas da tendência. Percebe-se também a ocorrência de alguns picos, o que pode resultar em algumas possíveis intervenções.




Figura 1: Representação gráfica da série original do consumo médio mensal da gasolina em mil barris/dia no Brasil, no período de janeiro de 1979 a outubro de 2011.

A função de autocorrelação da série original apresentada na Figura 2 não decai rapidamente para zero, indicando que a série não é estacionária, sendo possível a presença da tendência.




Figura 2: Gráfico da função de autocorrelação da série do consumo médio mensal da gasolina em mil barris/dia no Brasil.

Para aplicação do teste de Cox-Stuart dividiu-se a série em dois grupos de 197 pares  $(Z_i, Z_{i+c})$ , resultando em 194 comparações com sinal “+”, 3 com sinal “-” e nenhum empate. Portanto, o número de pares em que  $Z_i \neq Z_{i+c}$  é igual a 197, ou seja,  $n = 197$  e  $T_2 = 194$ , que é o número de pares com sinal positivo. Usando a aproximação normal, o valor de  $t$  foi igual a 110,0433, e assim, ao nível nominal de 5%, a hipótese  $H_0$  foi rejeitada pois  $T_2 > n - t$ , e concluiu-se que a série apresenta tendência.

O valor da estatística  $g$  do teste de Fisher foi calculada, sendo igual a 0,085, e por ser maior do que o valor  $Z_\alpha = 0,018$ , a hipótese de nulidade ( $H_0$ : Não existe sazonalidade) foi rejeitada, ou seja, a série apresenta sazonalidade ao nível de 5% de significância. Neste caso, verificou-se que o maior período significativo se encontrou entre os 12 primeiros meses, o que confirmou a presença da sazonalidade de 12 meses na série em estudo.

Após identificar a presença da tendência e da sazonalidade, aplicou-se o operador de diferenças para tornar a série estacionária, ou seja, oscilando em torno de uma média constante e apresentando certo equilíbrio estável. A tendência foi eliminada com apenas uma diferença, conforme ilustrado na Figura 3, e tomando uma diferença de 12 para eliminar a sazonalidade, verificou-se na função de autocorrelação (fac) e na função de autocorrelação parcial (facp) da série diferenciada (Figuras 4 (a) e (b)) a existência de “lags” múltiplos de doze significativos, o que implica incluir no modelo uma componente sazonal estocástica, além da determinística, que foi eliminada ao tomar uma diferença de doze.




Figura 3: Gráfico da série diferenciada, sem tendência e sazonalidade.

Pode-se observar também que existem indícios de intervenções nas observações 72 e 254. A observação 72 representa o período de dezembro de 1984, em que o programa Proálcool implementado pelo governo em 1978 atingia seu auge, o que provavelmente ocasionou a redução do consumo de gasolina no país. Já a observação 254 representa o período de fevereiro de 2002, época em que os preços dos combustíveis não eram mais controlados pelo governo e havia muita variação entre os preços do álcool e da gasolina, o que pode ter provocado um aumento da demanda pela gasolina, influenciada pelo seu custo reduzido. Em ambos os casos, foram consideradas intervenções com manifestação gradual e duração temporária.

Nas Figuras 4 (a) e (b) são apresentadas as funções de autocorrelação e autocorrelação parcial da série diferenciada que podem auxiliar na identificação das ordens dos modelos a serem ajustados. Geralmente, as correlações significativas da fac e da facp indicam, respectivamente, a ordem do modelo de médias móveis (MA) e do modelo autoregressivo (AR). Verificou-se que as funções de autocorrelação e autocorrelação parcial da série diferenciada apresentam “lags” sazonais significativos, o que sugere o ajuste de modelos do tipo auto-regressivo integrado de médias móveis sazonal, conhecido por SARIMA(p,d,q)(P,D,Q)<sub>12</sub> e representado por:

$$\phi(B)\Phi(B^s)\Delta^d\Delta_s^D Z_t = \theta(B)\Theta(B^s a_t),$$

em que:  $\phi(B) = 1 - \phi_1(B) - \phi_2(B^2) - \dots - \phi_p(B^p)$  é o polinômio autorregressivo de ordem  $p$ ;  $\Phi(B^s) = 1 - \Phi_1(B^s) - \Phi_2(B^s) - \dots - \Phi_P(B^{P_s})$  é o polinômio autorregressivo sazonal de ordem  $P$ ;  $\Delta^d = (1 - B^s)^d$  é o operador diferença e  $d$  indica o número de diferenças necessárias para retirar a tendência da série;  $\Delta_s^D = (1 - B^s)^D$  é o operador diferença sazonal e  $D$  indica o número de diferenças sazonais necessárias para retirar a sazonalidade da série;  $\theta(B) = 1 - \theta_1(B^1) - \theta_2(B^2) - \dots - \theta_q(B^q)$  é o polinômio médias móveis de ordem  $q$ ;  $\Theta(B^s) = 1 - \Theta_1(B^s) - \Theta_2(B^s) - \dots - \Theta_Q(B^{Q_s})$  é o polinômio médias móveis sazonal de ordem  $Q$ ;  $Z_t$  é a variável resposta do modelo e  $a_t$  é o resíduo do modelo, que eventualmente, pode ser considerado como ruído branco.




Figura 4: Gráfico da função de autocorrelação (fac)(a) e da função de autocorrelação parcial (facp) (b) da série diferenciada.

Segundo Box e Jenkins (1976) quando o comportamento de uma série sofre alterações causadas por algum evento específico, temporário ou permanente, o efeito da intervenção deve ser considerado. Neste caso, o modelo proposto para a análise da intervenção é dado por:

$$Z_t = \sum_{j=1}^I \nu_j(B)X_{j,t} + N_t,$$

sendo que:  $I$  é o número de intervenções na série;  $\nu_j(B)$  é o valor da função de transferência;  $X_{j,t}$  é a variável binária de intervenção e  $N_t$  é o ruído do modelo.

Assim, com base nas funções apresentadas nas Figuras 4 (a) e (b), foram testados vários modelos que poderiam ser adequados para descrever a série em estudo, alguns deles considerando o efeito das intervenções. Desse modo, foram propostos os seguintes modelos: o SARIMA(2,1,0)(0,1,1)<sub>12</sub> e o SARIMA(2, 1, 0)(0, 1, 1)<sub>12</sub> com intervenções nas observações 72 e 254, referente a dezembro de 1984 e fevereiro de 2002. A notação utilizada para apresentar os resultados do modelo SARIMA(2, 1, 0)(0, 1, 1)<sub>12</sub> sem intervenção será dada por SARIMA(2, 1, 0)(0, 1, 1)<sub>12</sub>-SI, sendo que SI indica sem intervenção e a do modelo SARIMA(2, 1, 0)(0, 1, 1)<sub>12</sub> com intervenção será SARIMA(2, 1, 0)(0, 1, 1)<sub>12</sub>-CI, em que CI denota com intervenção. Na Tabela 1 são apresentadas as estimativas dos parâmetros, obtidas pelo método da máxima verossimilhança, com seus respectivos desvios padrão. Pode-se observar que todas as estimativas foram significativas.

Inicialmente, para verificar a qualidade do ajuste dos modelos propostos, analisou-se por inspeção visual, a significância das autocorrelações dos resíduos estimados da função de autocorrelação e autocorrelação parcial, apresentadas nas Figuras 5 (a) e (b) e 6 (a) e (b). Para o

Tabela 1: Estimativas dos parâmetros dos modelos SARIMA(2,1,0)(0,1,1)<sub>12</sub> sem e com intervenção para a série do consumo médio mensal da gasolina em mil barris/dia no Brasil, no período de janeiro de 1979 a outubro de 2011.

Modelo	Parâmetro	Estimativa	Desvio Padrão	Valor-p
SARIMA(2,1,0)(0,1,1) <sub>12</sub> -SI	$\phi_1$	-0,632	0,049	0,000
	$\phi_2$	-0,306	0,049	0,000
	$\Theta_1$	0,687	0,034	0,000
SARIMA(2,1,0)(0,1,1) <sub>12</sub> -CI	$\phi_1$	-0,591	0,049	0,000
	$\phi_2$	-0,352	0,049	0,000
	$\Theta_1$	-0,677	0,040	0,000
	$\omega_1$	29,200	9,663	0,003
	$\delta_1$	-0,734	0,087	0,000
	$\omega_2$	31,241	12,157	0,011
	$\delta_2$	-0,619	0,179	0,001

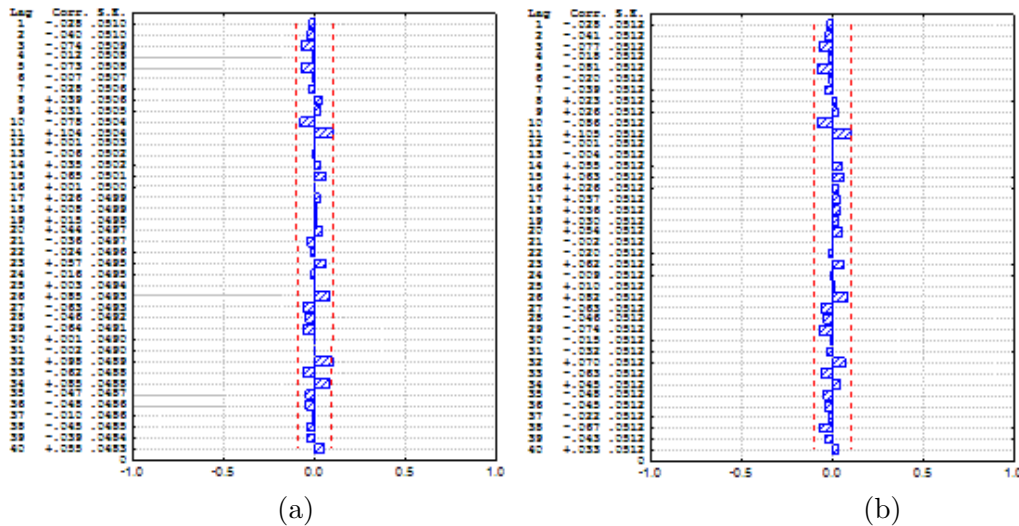


Figura 5: Gráfico da função de autocorrelação (fac) (a) e da função de autocorrelação parcial (facp) (b) residual do modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> sem intervenção.

modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> sem intervenção, observou-se nas Figuras 5 (a) e (b), que aproximadamente 5% dos lags ultrapassaram o limite de confiança e são significativos, os demais são não significativos, indicando que os resíduos deste modelo podem ser considerados ruído branco. Resultados semelhantes foram encontrados para o SARIMA(2,1,0)(0,1,1)<sub>12</sub> com intervenção nas observações 72 e 254, conforme ilustrado nas Figuras 6 (a) e (b).

Tabela 2: Estatísticas para o teste de Box-Pierce do modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> sem e com intervenção da série do consumo médio mensal da gasolina em mil barris/dia no Brasil.

Modelo	Graus de liberdade	$Q_{40}$	$\chi^2$
SARIMA(2,1,0)(0,1,1) <sub>12</sub> -SI	37	39,27	52,19
SARIMA(2,1,0)(0,1,1) <sub>12</sub> -CI	33	36,00	47,39

Para confirmar se os resíduos de ambos os modelos são não correlacionados e se estes foram ajustados adequadamente realizou-se o teste de Box-Pierce que avalia se as autocorrelações dos resíduos estimados são ruído branco. Para tal finalidade, observou-se na Tabela 2 que a estatística  $Q_{40}$  (39,27) do modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> sem intervenção é inferior ao valor da distribuição de qui-quadrado com 37 graus de liberdade (52,19), e quando isso ocorre, a



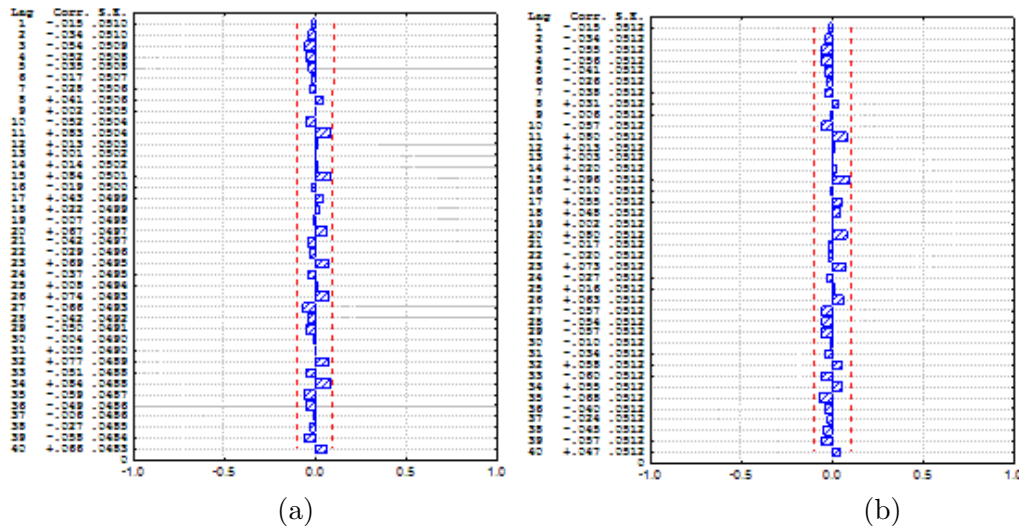


Figura 6: Gráfico da função de autocorrelação (fac) residual do modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> com intervenção

hipótese de nulidade de que os resíduos são um ruído branco não deve ser rejeitada, concluindo-se assim, que o modelo proposto foi bem ajustado. De modo análogo, verificou-se que o modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> com intervenção foi bem ajustado, visto que o valor de  $Q_{40}$  (36,00) é menor do que o valor de qui-quadrado com 33 graus de liberdade (47,39).

Tabela 3: Valores de consumo médio de gasolina, observados e previstos, considerando o modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> sem intervenção

Mês/Ano	Valor Real	SARIMA(2,1,0)(0,1,1) <sub>12</sub> -SI	
		Valor Previsto	Erro Previsão
Nov/2011	514	480,31	18,16
Dez/2011	574	529,75	19,35
Jan/2012	502	483,02	21,09
Fev/2012	530	512,06	23,70
Mar/2012	534	526,59	25,27
Abr/2012	518	531,96	26,93

Tabela 4: Valores de consumo médio de gasolina, observados e previstos, considerando o modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> com intervenção.

Mês/Ano	Valor Real	SARIMA(2,1,0)(0,1,1) <sub>12</sub> -CI	
		Valor Previsto	Erro Previsão
Nov/2011	514	480,60	17,80
Dez/2011	574	529,76	19,23
Jan/2012	502	483,48	20,53
Fev/2012	530	512,68	23,28
Mar/2012	534	527,69	24,88
Abr/2012	518	533,27	26,37

Neste contexto, foram realizadas as previsões do consumo médio mensal de gasolina no Brasil no período de novembro de 2011 a abril de 2012 com seus respectivos erros de previsão, considerando os dois modelos. Esses resultados são apresentados nas Tabelas 3 e 4, e de modo geral, observou-se que houve uma aproximação entre os valores preditos e os reais e ocorreu uma

tendência a subestimar os valores reais.

Tabela 5: Critérios de escolha do melhor ajuste e melhor modelo de previsão.

Modelo	AIC	BIC	EQMP
SARIMA(2,1,0)(0,1,1) <sub>12</sub> -SI	2213,68	5,83	670,84
SARIMA(2,1,0)(0,1,1) <sub>12</sub> -CI	2202,12	5,84	664,73

Na Tabela 5 são apresentados os valores dos critérios AIC, BIC e o EQMP. Para a seleção do melhor modelo ajustado, observou-se qual deles apresentou o menor valor para esses critérios, e neste caso, verificou-se que o modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> com intervenção apresentou o menor AIC e EQMP, e portanto, foi o modelo escolhido para representar a série do consumo médio mensal de gasolina no Brasil.

Portanto, o modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> com suas respectivas estimativas é dado por:

$$Z_t = \frac{29,2}{1 + 0,7342B} x_{1,t} + \frac{31,2410}{1 + 0,6190} x_{2,t} + \frac{(1 - B^{12})(1 + 0,6766B^{12})}{(1 - B)(1 + 0,5906B + 0,3536B^2)} a_t,$$

em que:

$$x_{1,t} = \begin{cases} 0 & \text{se } x \neq 72 \\ 1 & \text{se } x = 72 \end{cases} \quad \text{e} \quad x_{2,t} = \begin{cases} 0 & \text{se } x \neq 254 \\ 1 & \text{se } x = 254 \end{cases}.$$

## Conclusões

Os modelos de séries temporais podem ser úteis para descrever a série do consumo médio mensal da gasolina em mil barris/dia no Brasil. Entre os modelos ajustados com e sem intervenção, verificou-se que o modelo SARIMA(2,1,0)(0,1,1)<sub>12</sub> com intervenção apresentou resultados satisfatórios e pode ser utilizado para prever o consumo nacional médio mensal da gasolina em mil barris/dia.

## Referências

ANDRADE, P. C. R. Estudo da série da taxa de desemprego na região metropolitana de Recife. *Revista da Universidade Vale do Rio Verde*, v. 9, n.1, p. 3-18, jan./jul. 2011.

BOX, G. P.; JENKINS, G. M. *Time series analysis, forecasting and control*. San Francisco: Holden-Day, 1976. 575p.

FERNANDES, R. A. S.; SANTOS, C. M.; PEIXOTO, S. L. Determinantes da demanda de gasolina C no Estado de Minas Gerais, 2002 a 2010. *Revista de Economia e Agronegócio*, v. 10, n.1, p. 109-128, jan./abr. 2012.

FIQUEIRAS, S. R.; BURNQUIST, H. L. Programas para álcool combustível nos Estados Unidos e possibilidades de Exportação o Brasil. *Agricultura em São Paulo*, v. 53, n.2, p. 5-18, jul./dez. 2006.

GONÇALVES, L. R.; SÁFADI, T. Modelagem de séries representativas do setor energético brasileiro. *Revista Brasileira de Estatística*, v. 69, n. 231, p. 33-67, jul./dez. 2008.

IPEA - INSTITUTO DE PESQUISA ECONÔMICA APLICADA. Disponível em: <[www.ipeadata.gov.br](http://www.ipeadata.gov.br)>. Acesso em: 20 jun. 2012.

- MARTINEZ, E. Z.; SILVA, E. A. S. Predicting the number of cases of dengue infection in Ribeirão Preto, São Paulo State, Brazil, using a SARIMA model. *Cadernos de Saúde Pública*, v. 27, n. 9, p. 1809-1818, set. 2011.
- MORETTIN, P. A; TOLOI, C. M. C. *Análise de séries temporais*. São Paulo: Edgard Blücher, 2006. 538 p.
- MURADÁSNETO, M. V.; CARVALHO, P. L. C.; SÁFADI, T. Análise preditiva e comparativa para séries de combustíveis no Município de Lavras. *Revista Científica Symposium*, v.6, n.1, p. 55-61, jan./jun. 2008.
- PRIESTLEY, M.B. *Spectral analysis and time series. volume1: Univariate series. volume 2: Multivariate series, Prediction and control*. New York : Academic Press. 1989. 890 p.
- SANTIAGO, F. S.; MATTOS, R. S.; PEROBELLI, F. S. Um modelo integrado econométrico + insumo-produto para previsão de longo prazo da demanda de combustível no Brasil. *Revista Nova Economia*, v. 21, n.3, p. 423-455, set./dez. 2011.
- SILVA, M. I. S.; GUIMARÃES, E. C.; TAVARES, M. Previsão da temperatura média mensal de Uberlândia, MG, com modelos de séries temporais. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 12, n.5, p. 480-485, jan. 2008.
- VILELA, T. M de M.; PINTO JÚNIOR, H. Q. Análise de sensibilidade do consumo de gasolina C entre julho de 2001 e dezembro de 2008: Política Tributária Estadual como instrumento de políticas energéticas e ambientais. *Revista Nova Economia*, v. 20, n.3, p. 403-426, set./dez. 2010.
- WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica e computadores pessoais. *Gestão e Produção*, v. 10, n. 1, p. 47-67, abril 2003.
- WOSCH, L. F. O. O desafio do etanol brasileiro no cenário mundial. *Revista Paranaense de desenvolvimento*, n.118, p. 7-40, jan./jun. 2010.