

Graduação    Pós-Graduação

## PREVISÕES ESTATÍSTICAS PARA O COMBATE DE CRIMES FISCAIS

**Danielle Velasquez Messias,**  
Universidade Federal de Mato Grosso do Sul,  
daniellemessias236@gmail.com

**Elisabeth Regina de Toledo,**  
Universidade Federal de Mato Grosso do Sul,  
erdtoledo@gmail.com

### RESUMO

Crimes fiscais são caracterizados pela ação ou omissão dolosa para impelir ou retardar o conhecimento da autoridade tributária competente em suprimir ou reduzir o valor do tributo devido, como o contrabando. Exemplo: produtos legais, mas importados de forma fraudulenta ou clandestina prejudicam empresas que trabalham corretamente. Retiram empregos formais, reduzem o recolhimento de tributos nos cofres públicos seriam convertidos em prestação de serviços à sociedade. Este trabalho teve com finalidade analisar a série histórica das apreensões realizadas pela Receita Federal do Brasil entre janeiro de 2012 e dezembro de 2018. A análise foi realizada através da linguagem de programação R (R, 2019) versão 3.6.1 para Windows. Foram ajustados diversos modelos e selecionado, através do critério de seleção Akaike (AIC), o modelo SARIMA(1,1,1)x(0,1,1)<sub>12</sub>, que explicou melhor os dados. Em seguida foram realizadas previsões com 95% de confiança para as apreensões mensais de 2019, que se aproximaram do real valor das apreensões efetuadas neste ano. Verificamos tendência crescente das apreensões no decorrer do ano, em especial nos últimos cinco meses, bem como um crescimento expressivo no volume de apreensões de um ano para outro. Tais informações poderão fornecer subsídios para tomadas de decisões no combate e prevenção aos crimes fiscais.

**Palavras-chave:** Crimes fiscais; Previsão; Séries temporais; Receita Federal.

## 1 INTRODUÇÃO

As séries temporais fazem parte da sociedade e estão presentes em vários estudos, desde previsões do tempo até vendas mensais de uma empresa. Chamamos de série temporal ou séries de tempo um conjunto de observações ordenadas no tempo (MORETTIN, 2006). O estudo de séries temporais visa observar acontecimentos passados, para prever eventos futuros, possibilitando chegar à melhor tomada de decisões.

No Brasil crimes fiscais como os de contrabando e descaminho são comumente praticados. De acordo com o Código Penal Brasileiro, o termo contrabando e descaminho estão respectivamente associados a mercadorias proibidas na importação/exportação e ao fato de se burlar o pagamento de impostos referentes aos tipos de produtos em seu consumo ou transporte, cujas práticas interferem diretamente na economia, pois comprometem a arrecadação de tributos e impostos. Causam desequilíbrio mercadológico em diversos setores da sociedade, pois impedem a criação anual de empregos que prejudicam a economia formal, além de representar concorrência desleal em relação às empresas e indústrias que honestamente recolhem em dia seus tributos e encargos sociais que possuem alto valor agregado a seu produto. (MOREIRA *et al.*, 2016).

Um dos objetivos deste trabalho é analisar, com base em séries históricas, a tendência das apreensões efetuadas pela Receita Federal, referentes a esses crimes, a fim de oferecer subsídios que poderão auxiliar o Estado e as autoridades fiscais no combate e repressão de crimes fiscais com operações destinadas a coibir delitos, contrabando, descaminho, tráfico de armas, entre outros. A análise de séries temporais no estudo das incidências de crimes fiscais, permite verificar a necessidade de a Receita Federal aprimorar sua atuação, além de fornecer informações para o planejamento de políticas públicas, que possibilitem a implementação de diversos tipos de fiscalização e repressão a tais práticas (CARVALHO *et al.*, 2019).

## 2 REVISÃO DA LITERATURA

Uma série temporal é composta por componentes que classificam umas das outras. São elas: tendência, sazonalidade ou estacionariedade e cíclicas. Uma série é dita contínua quando as observações são feitas continuamente no tempo. É dita discreta quando as observações são feitas em tempos específicos.

A tendência demonstra o crescimento (ou decrescimento), é um termo importante, pois envolve estudo e planejamento em longo prazo. A sazonalidade estuda o comportamento que tende a se repetir em um curto período, como por exemplo, fenômenos que ocorrem regularmente de ano em ano (mensalmente, bimestralmente, anualmente). Pode ser classificada em duas partes: aditiva e multiplicativa. A aditiva representa flutuações mais ou menos constantes já a multiplicativa representa o tamanho dessas flutuações dependendo do nível da série. Os procedimentos de previsão de séries temporais podem ser divididos em duas partes: automáticos e não automáticos. Os automáticos são aplicados diretamente, com a utilização de programas de computadores, esse procedimento que utilizaremos. E o não automático precisa-se de uma pessoa com capacidade para aplicar os dados e manusear os programas de computadores (FONSECA, 1985).

Dessa forma, a série temporal nos instantes  $t_1, \dots, t_n$ , possa ser decomposta por:

$$Z_{(t)} = T_{(t)} + C_{(t)} + S_{(t)} + a_{(t)}, \quad t = 1, \dots, n$$

sendo  $T_{(t)}$ : tendência em função do tempo;  $C_{(t)}$ : ciclo em função do tempo;  $S_{(t)}$ : componente sazonal em função do tempo;  $a_{(t)}$ : componente estritamente aleatório (ruído branco ou erro aleatório).

De um modo geral, tendências demográficas podem ser causadas por diversos fatores durante longos períodos de tempo, é um movimento “suave” do tempo  $t$ . Componente sazonal são registros mensais, trimestrais ou diários. Removendo-se os componentes  $T_{(t)}$  e  $C_{(t)}$  o que resta é o componente aleatório,  $a_{(t)}$ , o ruído branco, com média zero e variância constante.

Um dos propósitos na análise de séries temporais é eliminar a sazonalidade determinística. No entanto, é possível que, mesmo após eliminar essa componente sazonal, ainda reste a correlação significativa em (MORETTIN; TOLOI, 2004):

- i) “lags” de baixa ordem, indicando que os resíduos ainda estão correlacionados, podendo ajustá-los através de um modelo ARIMA, por exemplo;
- ii) “lags” sazonais, isto é, múltiplos períodos de  $s$ . Significa que há necessidade de se considerar uma sazonalidade estocástica, ou seja, ajustar à série original um modelo ARIMA sazonal (SARIMA).

O uso de softwares e pacotes estatísticos são de grande importância para a análise de séries temporais e a aquisição dos mesmos pode apresentar custos elevados. Dessa forma, atualmente é grande a procura e incentivo ao uso dos chamados softwares livres

(CHAMBERS, 2008). O R é uma linguagem de programação e ambiente gratuito, desenvolvido em Bell Laboratorier por John Chambers e colaboradores (R, 2019). Possui pacotes para fazer análise e simulação de dados, geração de gráficos, testes de hipóteses e modelagem estatística em geral, além de resolver problemas e operações matemáticas.

### 3 PROCEDIMENTOS METODOLÓGICOS

Os dados analisados neste trabalho são referentes às apreensões efetuadas pela Receita Federal no período de janeiro de 2012 a dezembro de 2018, disponíveis em seus relatórios de aduaneiros. A análise de séries temporais para modelagem e previsão das apreensões para o ano de 2019 foi executada utilizando a linguagem R (2019) de programação, versão 3.6.1 para Windows. Após a construção da série histórica das apreensões, foram verificadas a tendência, estacionariedade e sazonalidade da série, sugerindo o ajuste de um modelo SARIMA (Arima Sazonal Multiplicativo).

Isto sugere, como modelo preliminar, um SARIMA(1,1,1)x(1,1,1)<sub>12</sub>. Em seguida foi aplicado o Teste de Dickey-Fuller Aumentado (ADF) para testar a hipótese nula (H<sub>0</sub>) de existência de uma raiz unitária (não estacionariedade) contra a hipótese alternativa (H<sub>1</sub>) de estacionariedade da série transformada. Os resultados do teste apresentaram o valor crítico Dickey-Fuller de -8,47, com 5% de significância e o p-valor é baixo (< 5%), indicam que a hipótese de uma raiz unitária é rejeitada, em nível de 5%, o que nos diz que a série é estacionária.

O ajuste do modelo foi realizado através da função Arima do pacote forecast (R, 2019). As estimativas dos parâmetros do modelo ajustado foram obtidas pelo método de máxima verossimilhança (ML, Maximum Likelihood). Ao ajustar o modelo SARIMA(1,1,1)x(1,1,1)<sub>12</sub>, por exemplo, utilizam-se os dados originais. Porém, ao definir o argumento lambda igual a zero, permite que seja feita a transformação logarítmica da série. Além do mais, não é necessário diferenciar antecipadamente a série temporal, pois a própria função faz isso. Foi verificada a significância dos parâmetros do modelo através do teste t - pacote t\_teste e, com 95% de confiança, concluímos que o parâmetro AR Sazonal não era significativo e, portanto, deveria ser retirado do modelo proposto preliminar, resultando no modelo SARIMA(1,1,1)x(0,1,1)<sub>12</sub>.

Diversos modelos foram ajustados e foi selecionado o modelo que melhor descreveu os dados de apreensão através do critério de informação de Akaike (do

inglês Akaike information criterion, AIC). Por esse critério, o modelo ideal é o que minimiza o valor AIC calculado, ou seja, modelo com menor valor e AIC é considerado o modelo de melhor ajuste.

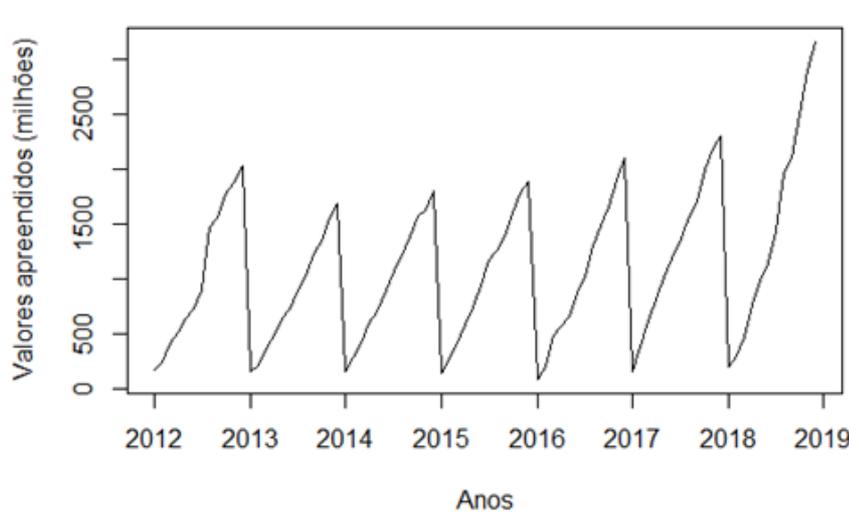
Em seguida foi efetuado o diagnóstico dos resíduos do modelo. Confirmada a ausência de autocorrelação nos resíduos pelo teste Box-Ljung e verificada a estacionariedade da variância através do teste Ljung&Box, foi testada a normalidade dos mesmos. A transformação logarítmica, entretanto, não foi eficiente para corrigir o problema da falta de normalidade, pois o teste de Jarque&Bera continua rejeitando a hipótese de distribuição Gaussiana (valor- $p < 0,01$ ). Como temos uma série com tamanho razoável ( $n = 84$ ), pudemos prosseguir mesmo sem esta hipótese estar satisfeita, pois verificamos que as previsões para o período de 2018 não foram fortemente afetadas neste caso, com estimativas mais próximas dos valores reais das encontradas por Carvalho *et al.* (2019). Através do pacote forecast foram realizadas as previsões com 95% de confiança.

Os resultados da análise de séries temporais do valor das apreensões, em milhões de reais, associados aos crimes fiscais, serão apresentados a seguir.

#### 4 DISCUSSÃO E ANÁLISE DOS DADOS

Inicialmente foi construída a série histórica das apreensões, apresentada na Figura 1.

**Figura 1: Série temporal mensal do volume de apreensões de mercadorias (em milhões) de janeiro de 2012 a dezembro de 2018.**

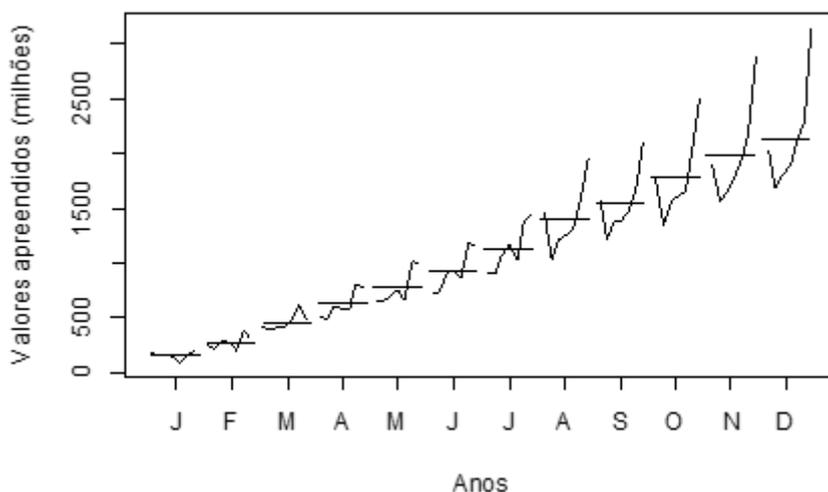


Através da Figura 1 verifica-se uma tendência crescente nos valores apreendidos pela Receita Federal. As oscilações de picos e vales podem estar relacionadas aos períodos de

férias, por exemplo. Essas oscilações ocorrem anualmente, revelando indícios de sazonalidade: os menores e maiores valores apreendidos foram, respectivamente, em janeiro de 2016 (R\$ 90 mil) e dezembro de 2018 (R\$ 3.155,3 milhões). O comportamento crescente ocorre durante o ano todo, porém é mais expressivo nos cinco meses finais do ano, cuja característica se repete anualmente. O aduaneiro da Receita Federal afirma que ao longo de 2018 foram realizadas 3.347 operações de vigilância e repressão aos crimes de contrabando e descaminho, representando um aumento de 5,22% em relação a 2017 sendo o melhor resultado registrado em dez anos (RECEITA FEDERAL DO BRASIL, 2018).

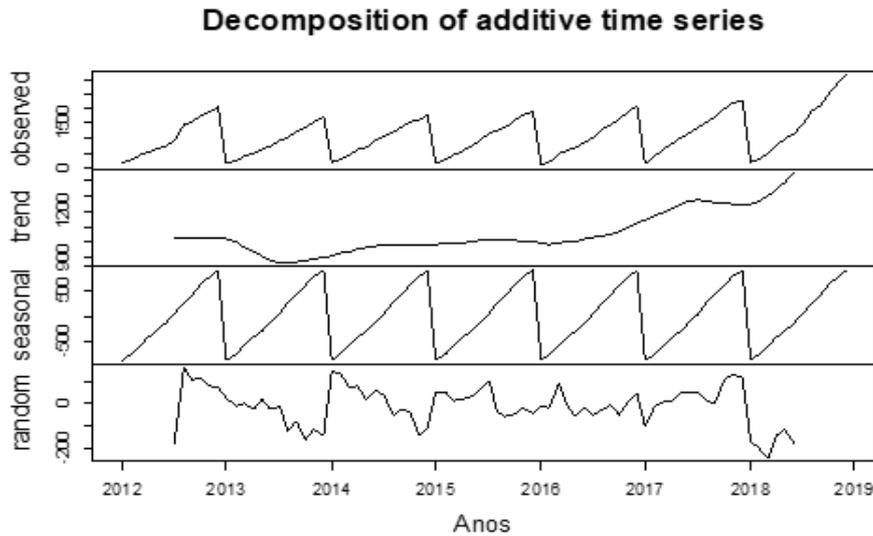
A Figura 2 apresenta a evolução do volume de apreensões de mercadorias por mês (em milhões de reais) de janeiro de 2012 a dezembro de 2018 em termos de média (traços horizontais) e variabilidade (traços verticais).

**Figura 2: Evolução do volume de apreensões de mercadorias por mês (em milhões) de janeiro de 2012 a dezembro de 2018.**



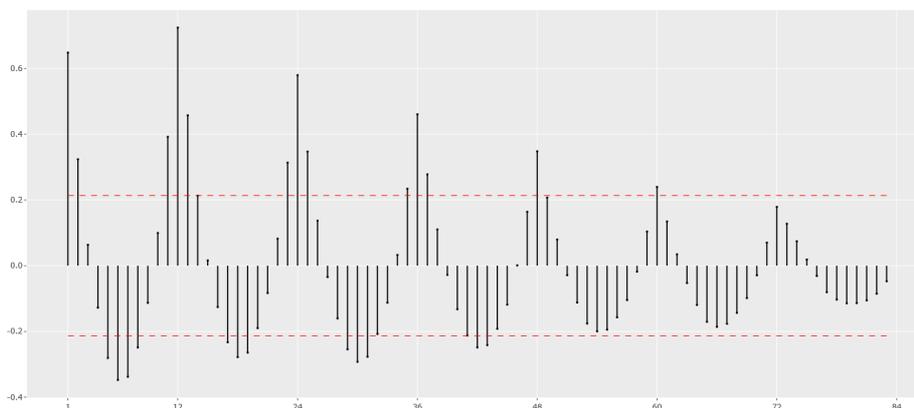
Observando a Figura 2, verifica-se um crescimento expressivo nos cinco meses finais dos anos, no valor médio em milhões de reais apreendidos pela Receita Federal (traços horizontais), tendo seu valor mínimo nos meses de janeiro e o máximo nos meses de dezembro (indício de sazonalidade). Analisando os traços verticais, podemos verificar um aumento contínuo no número de apreensões ano a ano (a série temporal apresenta média e variância não constantes), indícios de não estacionariedade na parte sazonal da série, que poderão ser melhor verificadas na Figura 3.

Figura 3: Decomposição da série de apreensões de mercadorias (em milhões).



A série decomposta das apreensões da Receita Federal (Figura 3) apresenta informações como sazonalidade, tendência e aleatoriedade. A sazonalidade indica uma componente periódica de 12 meses, cuja existência se reflete no comportamento senoidal do correlograma. (Figura 4) e indica a necessidade de se aplicar uma diferença sazonal de ordem 12, à série original, com o objetivo de eliminar essa componente. Verifica-se tendência crescente no valor das apreensões, com crescimento acentuado nas arrecadações a partir do ano de 2017.

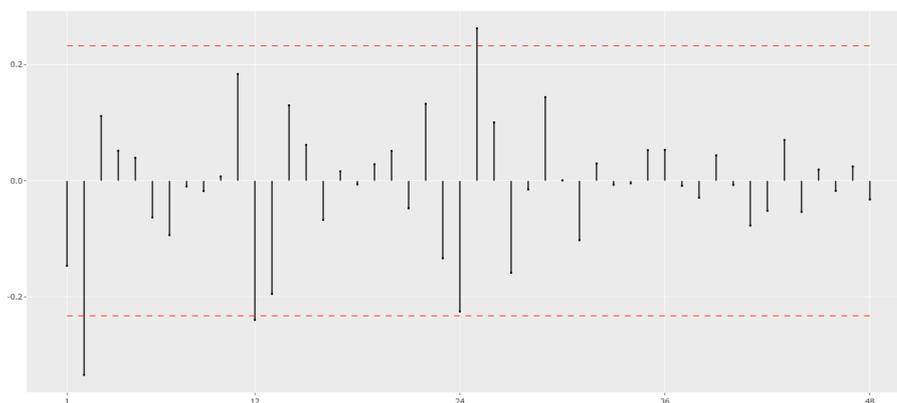
Figura 4: Correlograma com a função de autocorrelação das apreensões de mercadorias (em milhões).



A Figura 4 apresenta o correlograma com a função de autocorrelação (ACF), com seu respectivo intervalo de confiança. Analisando o comportamento da função de ACF das apreensões, parece haver a necessidade de efetuar diferença na série original, com o objetivo de torná-la estacionária. Verifica-se também um comportamento senoidal. Além disso, é

possível verificar a presença de correlações altas nos "lags" iniciais e, as demais auto correlações não significantes, indicando um comportamento estacionário da série com um comportamento sazonal, sugerindo o ajuste de um modelo SARIMA (Arima Sazonal Multiplicativo). Após efetuar transformações na série temporal mensal do volume de apreensões de mercadorias (em milhões de reais) de janeiro de 2012 a dezembro de 2018: Série da 1ª Diferença, 1ª Diferença + componente de sazonalidade:  $lag = 12$ , a série do logaritmo da 1ª Diferença + componente de sazonalidade:  $lag = 12$  e a série do logaritmo da 2ª Diferença + componente de sazonalidade:  $lag = 12$ , foram analisados o comportamento de suas funções de autocorrelação. Aplicando a primeira diferença, a série ficou estacionária na média, porém não estacionária na variância. Aplicando a segunda diferença, não houve mudança significativa no comportamento da primeira para a segunda diferença. No entanto, o comportamento entre as transformações 1ª diferença e logaritmo da diferença parece não alterar muito quando incorporado o parâmetro de sazonalidade,  $lag = 12$ . No entanto, a FAC da 2ª Diferença +  $lag = 12$  apresentou cortes bruscos nos lags 2, 12 e 25, porém não são significativos porque apresentam correlações baixas (-0,334, -0,24 e 0,263) e não apresentar decrescimentos lentos (Figura 5). O próximo passo foi testar estatisticamente as percepções levantadas.

**Figura 5: Função de correlação para os dados transformados pela 2ª Diferença do logaritmo das apreensões + componente de sazonalidade ( $lag = 12$ ).**



Através da Figura 5, verifica-se que a função de autocorrelação da segunda diferença +  $lag = 12$  apresentou cortes bruscos nos lags 2, 12 e 25, porém não são significativos porque apresentam correlações baixas (-0,334, -0,24 e 0,263) e não apresenta decrescimentos lentos, dando indícios de estacionariedade, sugerem o ajuste de um modelo SARIMA (Arima Sazonal Multiplicativo). A seleção do modelo que melhor se ajustou aos dados de apreensão foi através do critério de informação de Akaike (Tabela 1).

**Tabela 1: Avaliador AIC para a qualidade de ajuste dos modelos SARIMA das apreensões de mercadorias (em milhões).**

MODELO	AIC
SARIMA(0,0,0)x(0,1,1) <sub>12</sub>	-22,17
SARIMA(0,1,1)x(0,1,1) <sub>12</sub>	-70,83
SARIMA(1,1,1)x(1,1,1) <sub>12</sub>	-72,17
SARIMA(0,1,0)x(0,1,1) <sub>12</sub>	-67,88
SARIMA(0,2,0)x(0,1,1) <sub>12</sub>	-2,68
SARIMA(1,1,1)x(0,1,1) <sub>12</sub>	-72,68

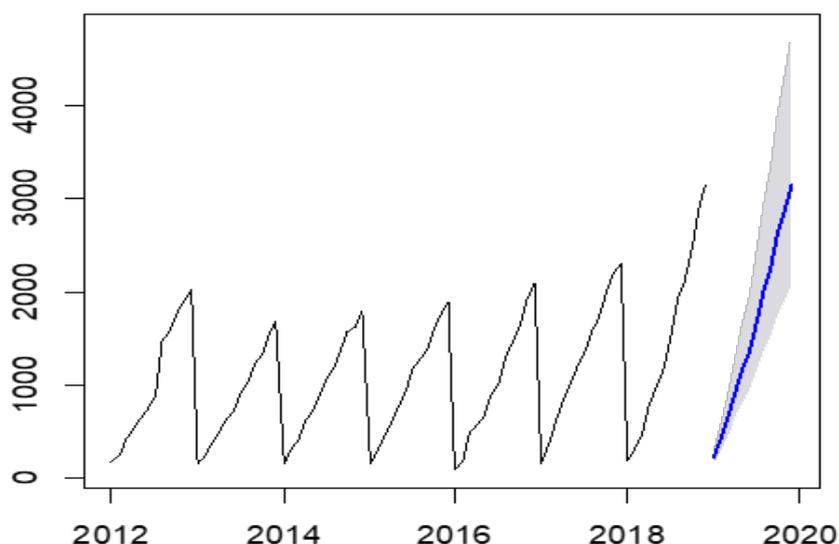
Pelo critério AIC de seleção, o modelo SARIMA(1,1,1)x(0,1,1)<sub>12</sub> ajustou melhor aos dados de apreensões. Após a verificação e seleção do modelo ideal, foram construídos os intervalos de previsão das apreensões para o ano de 2019, com 95% de confiança (Tabela 2, Figura 6).

**Tabela 2: Previsão das apreensões mensais de mercadorias (em milhões de reais) para o ano de 2019, com 95% de confiança, considerando o modelo ajustado SARIMA(1,1,1)x(0,1,1)<sub>12</sub> versus valor aproximado das apreensões mensais efetuadas pela Receita Federal em 2019.**

Ano de 2019	Estimação pontual (em milhões)	Limite Inferior LI	Limite Superior LS	Apreensões RFB (R\$ milhões)
Janeiro	232,2979	179,9415	299,8881	180,00
Fevereiro	404,7996	297,5755	550,6595	430,00
Março	674,8482	483,6347	941,6614	690,00
Abril	915,9112	646,035	1298,526	950,00
Mai	1132,171	789,1845	1624,224	1290,00
Junho	1361,413	939,6641	1972,454	1550,00
Julho	1651,867	1130,115	2414,502	1750,00
Agosto	2039,37	1383,766	3005,588	2100,00
Setembro	2261,324	1522,312	3359,094	2300,00
Outubro	2602,158	1738,392	3895,107	2600,00
Novembro	2908,321	1928,388	4386,217	2950,00
Dezembro	3154,664	2076,273	4793,158	3256,75

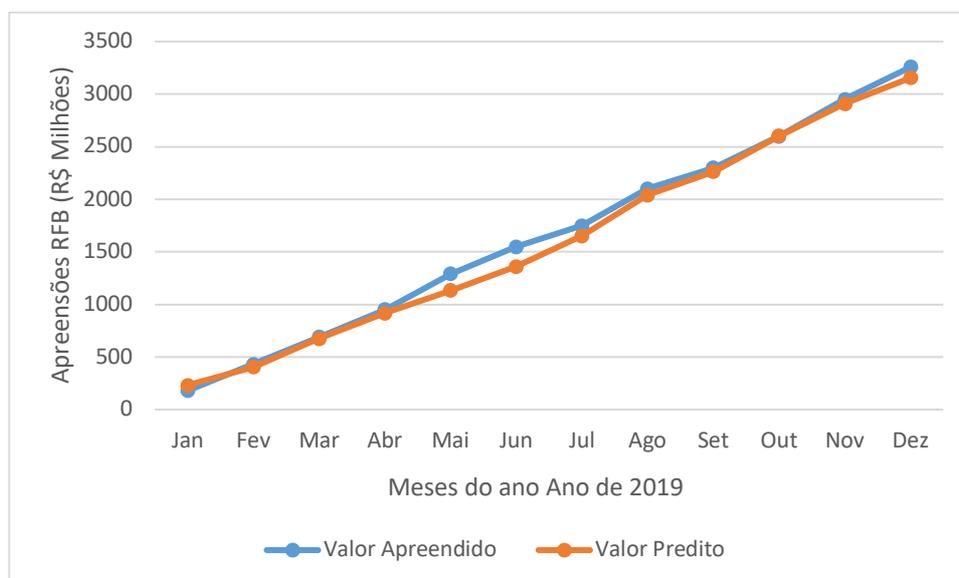
Fonte: Aduaneiro Receita Federal do Brasil, 2020.

**Figura 6: Intervalos de previsão das apreensões para 2019, com 95% de confiança.**



O intervalo de previsão apresenta sombra em torno dos valores médios estimados para o período. Apresenta tendência crescente de apreensões, corroborando com o crescimento significativo nas apreensões efetuadas pela Receita Federal. A comparação dos valores preditos e observados (apreendidos) para o anos de 2019 poderá ser verificada na Figura 7:

**Figura 7: Previsão das apreensões mensais de mercadorias (em milhões de reais) para o ano de 2019, com 95% de confiança, considerando o modelo ajustado SARIMA(1,1,1)x(0,1,1)<sub>12</sub> versus valor aproximado das apreensões mensais efetuadas pela Receita Federal em 2019.**



Fonte: Aduaneiro Receita Federal do Brasil, 2020.

A partir dos resultados apresentados na Tabela 2 e na Figura 7 podemos verificar a proximidade entre os valores preditos (previsões com 95% de confiança) dos valores reais

(apreendidos, em R\$, pela Receita Federal) para o ano de 2019, uma vez que os intervalos construídos contemplaram os valores observados neste ano (Tabela 2) e, graficamente, os valores preditos e reais ficaram praticamente justapostos no decorrer do ano, exceto nos meses de maio a julho, cujas estimativas de previsão foram levemente subestimadas, porém confirmando a tendência de crescimento, reiterando que o modelo selecionado se ajustou adequadamente aos dados analisados. Tais resultados poderão fornecer subsídios para auxiliar as autoridades interessadas a reforçarem sua atuação no combate de crimes fiscais como o contrabando e o descaminho, para o aprimoramento na repressão a esses ilícitos e poderão contribuir no planejamento e gerenciamento de recursos públicos.

## 5 CONCLUSÕES

A análise de séries temporais pode ser aplicada em qualquer área do conhecimento, sendo útil para a previsão de acontecimentos futuros. Este trabalho teve como objetivo avaliar a série histórica das apreensões realizadas pela Receita Federal do Brasil no período de janeiro de 2012 a dezembro de 2018, associada a crimes fiscais.

Os dados analisados na tabela 2 demonstram os índices de apreensões efetuadas pela Receita Federal, nos crimes de contrabando e descaminho. As previsões apontam limite superior e limite inferior no ano de 2019 de janeiro a dezembro, onde podemos fazer uma previsão com 95% de confiança que o número previsto será crescente no ano 2019.

A análise foi realizada através da linguagem de programação R (R, 2019) versão 3.6.1 para Windows, através da qual foram ajustados diversos modelos e selecionado, pelo critério de seleção Akaike (AIC), o modelo SARIMA(1,1,1)x(0,1,1)<sub>12</sub>, que explicou melhor os dados avaliados. Após a seleção do modelo ideal, foram realizadas previsões estatísticas com 95% de confiança para as apreensões mensais a serem efetivados durante o ano de 2019, baseando-se nos dados avaliados. As informações obtidas a partir da análise de séries temporais permitem constatar uma tendência de crescimento no valor das apreensões em âmbito nacional, isto é, o aumento nas apreensões no decorrer do ano, em especial nos últimos cinco meses de cada ano (R\$ 232,3 mil em janeiro e R\$ 3.154,6 em dezembro de 2019), bem como um crescimento expressivo no volume de apreensões de um ano para outro. Tais informações poderão fornecer aos órgãos competentes subsídios para tomadas de decisões que auxiliem as autoridades no combate e prevenção aos crimes fiscais, uma vez que as apreensões realizadas pela Receita Federal se revelam de fundamental importância para a proteção do Brasil,

evitando efeitos danosos à sociedade. A previsão do valor das apreensões da Receita Federal poderá contribuir no planejamento e gerenciamento dos recursos públicos.

## AGRADECIMENTO

Agradecemos à UFMS e à Receita Federal pelo fornecimento dos dados para a análise estatística

## REFERÊNCIAS

BUENO, Rodrigo De Losso da Silveira. **Econometria de séries temporais**. São Paulo, SP: Cengage Learning, 2008.

CARVALHO, L.A.O.; SILVA, A.L.F.; TOLEDO, E.R. **Uma análise das Apreensões Efetuadas pela Receita Federal na Fronteira Brasil/Bolívia e em nível nacional**. Revista GeoPantanal, Corumbá, v.13, n.25, 2019. p. 1

FERREIRA, Pedro Guilherme Costa (Org.). **Análise de séries temporais em R: curso introdutório**. Rio de Janeiro, RJ: Elsevier, 2018. xiv, 249 p.

FONSECA, Jairo Simon; MARTINS, Gilberto de Andrade; TOLEDO, Geraldo Luciano. **Estatística aplicada**. 2.ed. São Paulo, SP: Atlas, 1985.

MELLO, Márcio Pupin de; PETERNELLI, Luiz Alexandre. **Conhecendo o R: uma visão mais que estatística**. Viçosa, MG: Ed. UFV, 2013.

MOREIRA, D.K.A. *et al.* **Impacto do contrabando e descaminho na economia brasileira**. Revista Unilado, 2016.

MORETTIN, P.A.; TOLOI, C.M. **Análise de Séries Temporais**. São Paulo, Blucher, 2006.

MORETTIN, P.A.; TOLOI, C.M. **Séries temporais**. 2. ed. São Paulo, SP: Atual, 1987. 136 p. (Métodos Quantitativos).

MORETTIN, Pedro Alberto. **Econometria financeira: um curso em séries temporais financeiras**. São Paulo, SP: Blucher, 2008. 319 p.

PEREIRA, Basílio de Bragança. **Séries temporais multivariadas**. Rio de Janeiro, RJ: UFRJ, Instituto de Matemática, 1984. 219 p.

R DEVELOPMENT CORE TEAM (2019). **R: a language and environment for statistical computing**. R Foundation for Statistical Computing. Vienna: R Foundation for Statistical, 2019. Disponível em: <<http://www.r-project.org>>. Acesso em: 07 de julho de 2019.

RECEITA FEDERAL DO BRASIL. Balanço Aduaneiro. Brasília, DF, 2018.

RECEITA FEDERAL DO BRASIL. Balanço Aduaneiro. Brasília, DF, 2020.

SILVA, Elio Medeiros da; SILVA, Ermes Medeiros da. **Matemática e estatística aplicada.** São Paulo, SP: Atlas, 1999. 167 p.