

Previsão e monitoramento fiscal: uma análise a partir de modelos preditivos e aplicativo *web* interativo para o Brasil

Resumo

Este artigo tem o propósito de apresentar as etapas da construção de um aplicativo desenvolvido para o monitoramento e previsão de indicadores fiscais selecionados. A proposta é automatizar a coleta, modelagem e previsão de indicadores relacionados ao tópico fiscal (dívida líquida, dívida líquida em proporção do PIB, dívida bruta, dívida bruta em proporção do PIB, necessidade de financiamento do setor público e necessidade de financiamento do setor público em proporção do PIB), entre dezembro de 2001 e o período atual. Em um primeiro momento é realizada a automatização do processo de coleta de dados, via Banco Central do Brasil (BCB). Na sequência são realizados testes estatísticos preliminares (linearidade, raiz unitária, entre outros) e, posteriormente, utiliza-se os modelos de Holt, Holt-Winters, ARIMA, *Threshold* e *Prophet* para prever esses indicadores. Por fim, utiliza-se o pacote Shiny do *software* R para criar um aplicativo *web* interativo. Os resultados mostraram que é possível acompanhar as contas públicas na forma de um monitor fiscal que apresenta as projeções desses dados, conforme proposto pelo relatório [Monitor e Outlook \(2020\)](#).

Palavras-chave: Contas públicas. Previsão. Aplicativo.

Abstract

This article has the purpose of presenting the steps of building an application developed for the monitoring and forecasting of selected fiscal indicators. The proposal is to automate the collection, modeling and forecasting of indicators related to the fiscal topic (net debt, net debt as a proportion of GDP, gross debt, gross debt as a proportion of GDP, the need for public sector financing and the need for public sector financing in proportion of GDP), between December 2001 and the current period. At first, the data collection process is automated through the Central Bank of Brazil (BCB). Subsequently, preliminary statistical tests (linearity, unit root, among others) are carried out and, subsequently, Holt, Holt-Winters, ARIMA, *Threshold* and *Prophet* models are used to predict these indicators. Finally, the Shiny package from *software* R is used to create an interactive web application. The results showed that it is possible to monitor public accounts in the form of a fiscal monitor that presents the projections of these indicators, as proposed by the report [Monitor e Outlook \(2020\)](#).

Keywords: Public Accounts. Forecast. App.

1 Introdução

Previsão econômica é o ingrediente chave para tomada de decisão tanto de agentes do setor público quanto privado. Governistas, consumidores, firmas, bancos, instituições financeiras baseiam muitas de suas decisões em expectativas de condições econômicas futuras ou na predição de indicadores de interesses específicos, tais como: crescimento da renda, inflação, taxa de desemprego, taxas de juros, taxa de câmbio, salários e preços do petróleo.

Infelizmente, como ressaltam Ghysels e Marcellino (2018), os resultados econômicos são realizações de um vasto, complexo, dinâmico e estocástico sistema, o que torna o exercício de realização de previsões mais árduo e sujeito a erros inevitáveis. No entanto, a precisão da previsão e a confiabilidade pode ser melhorada com o uso de métodos e modelos econométricos adequados.

Nesse sentido, o uso de modelos econométricos, sejam lineares ou não-lineares, é acompanhado de um roteiro comum, baseado na especificação, estimação, diagnóstico e, por fim, previsão do modelo ou série de tempo. Não pode deixar de ser destacado que cada etapa de modelagem apresentada acima está vinculada ao uso de alguns testes preliminares, tais como: normalidade residual, raiz unitária, estabilidade dos parâmetros, não-linearidade, entre outros.

Essa análise inicial será útil para identificar comportamentos característicos, classificar as séries (estacionárias, quebra estrutural ou ambas) e auxiliar no direcionamento da forma de estimação adequada para os modelos. Temos, por exemplo, que os modelos auto-regressivos e média móvel (ARMA) Gaussianos não são apropriados para dados que exibam súbitas alterações em períodos irregulares ou que exibam forte assimetria e achatamento. Nesse caso, recomenda-se o uso de modelos auto-regressivos *Threshold* (TAR), modelos auto-regressivos de transição-suave (STAR) ou algumas das suas extensões.

Esses modelos serão utilizados para realizar a previsão de indicadores fiscais do Brasil. A ideia é ter uma modelagem adequada ao comportamento dessas séries e, em um segundo momento, utilizar o pacote Shiny do *software* R para criar um aplicativo web interativo que apresente as projeções desses dados. O propósito é utilizar técnicas univariadas de séries temporais para analisar e prever indicadores relacionados ao tópico fiscal (dívida líquida, dívida líquida em proporção do PIB, dívida pública líquida), entre dezembro de 2001 e o período atual. Especificamente, pretende-se automatizar a coleta de dados a partir da API Quandl; realizar testes estatísticos preliminares (normalidade, raiz unitária, linearidade, dentre outros); utilizar os modelos de Holt, Holt-Winters, ARIMA, *Threshold* e *Prophet* para analisar e prever os indicadores fiscais selecionados e; utilizar o pacote Shiny do *software* R para criar um aplicativo web interativo.

No Brasil, a preocupação com o desempenho das contas públicas não é recente e ficou ainda mais evidente após a redução da atividade econômica, queda na arrecadação e crescimento das despesas devido à pandemia da Covid-19. Assim, o trabalho irá contribuir no acompanhamento das contas públicas na forma de um monitor fiscal que apresenta as projeções desses indicadores.

O Fundo Monetário Internacional (FMI) discute e acompanha o papel da política fiscal nos países membros e gera um relatório mensal que discute os dados consolidados e apresenta

projeções sobre esses, conforme descrito em [Monitor e Outlook \(2020\)](#). A colaboração em relação aos resultados apresentados pelo FMI é permitir a alteração do método de estimação, previsão e definição do número de períodos previstos fora da amostra.

Nesse sentido, é possível melhorar as projeções fiscais? Acreditamos que há uma relação entre as projeções e as características dos dados e esse fato deve ser levado em consideração no momento da análise. O público alvo deste estudo são os gestores públicos, acadêmicos e agentes do mercado acionário. Dentro desse contexto, o presente artigo insere-se numa tentativa de formular estudos prospectivos para orientar estratégias de desenvolvimento de médio e longo prazo.

Além desta introdução, o artigo apresenta quatro outras seções. Na seção seguinte são apresentados os objetivos. Logo após é apresentada uma descrição dos procedimentos metodológicos. A seção 4 apresenta a discussão dos resultados. Por fim, são tecidas as considerações finais deste trabalho.

2 Objetivos

Construir um aplicativo que realize a coleta, modelagem e previsão de dados associados ao tópico fiscal, tais como: dívida líquida, dívida líquida em proporção do PIB, dívida bruta, dívida bruta em proporção do PIB, necessidade de financiamento do setor público e necessidade de financiamento do setor público em proporção do PIB, conforme disponibilidade de dados. Este objetivo geral pode ser melhor entendido através dos seguintes objetivos específicos:

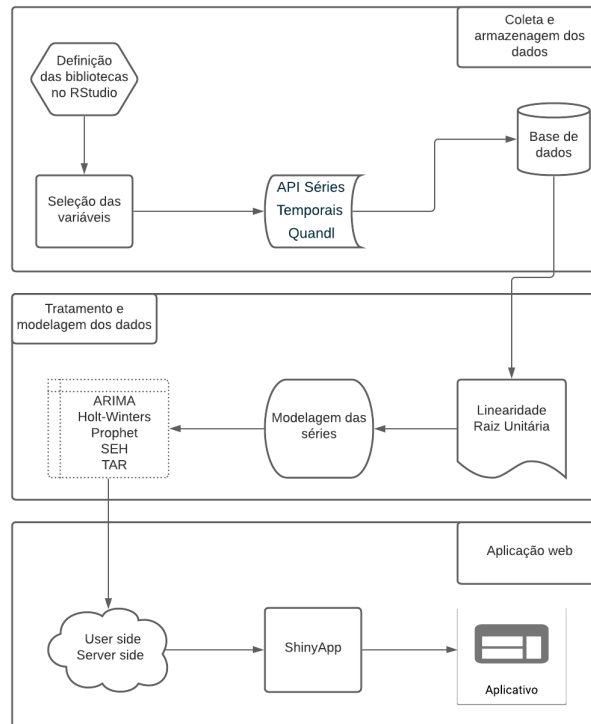
- Realizar testes estatísticos preliminares (linearidade e raiz unitária);
- Utilizar os modelos de Holt, Holt-Winters, ARIMA, *Threshold* e *Prophet* para analisar e prever os indicadores fiscais apresentados acima;

3 Metodologia

Os objetivos desta pesquisa serão alcançados através de três etapas principais. A primeira consiste na definição e levantamento de dados secundários via API do Quandl, sendo possível, por meio dessa, acessar e importar os dados selecionados.

A segunda etapa será direcionada para a análise individual das séries de tempo, por meio dos seguintes componentes: decomposição e suavização das séries; realização de testes de raiz unitária e não-linearidade. Dependendo dos resultados obtidos, a modelagem das séries temporais será dada a partir dos modelos AR(I)MA, modelos limiares ou *threshold* AR (TAR), entre outros. Discussões mais aprofundadas sobre esses temas podem ser encontradas em: [Hamilton \(1994\)](#), [Enders \(2008\)](#) e [Ghysels e Marcellino \(2018\)](#). A Figura 1 apresenta as etapas da construção do aplicativo e essas vão desde a coleta dos dados até a apresentação.

Figura 1 – Fluxograma do aplicativo



Por fim, a terceira etapa irá contemplar o desenvolvimento de aplicações em web, via pacote *Shiny*. Um aplicativo em *Shiny* (ou *Shiny app*) é gerado por um único *script* e tem três componentes: objeto com a interface do usuário (*user side*), responsável pelo controle do *layout* e aparência do aplicativo; a função *server()* (*server side*) é o servidor e; função *shinyApp()*. A ideia é automatizar a coleta, tratamento e projeções dos dados, permitindo que usuários externos possam interagir e realizar projeções para fora da amostra, conforme seu interesse.

3.1 Métodos de suavização e previsão das séries

Existem alguns métodos que são utilizados para retirar os componentes tendência e sazonalidade das séries, dentre esses, destaca-se: Suavização exponencial simples (SES), adequado para previsão de séries temporais sem tendência e sazonalidade; Suavização exponencial de Holt (SEH), recomendado para realizar previsões de séries que apresentam tendência; Suavização exponencial de Holt-Winters, este modelo busca capturar o efeito sazonal das séries, tal como descrito em Ferreira et al. (2018). O aplicativo irá levar em consideração os métodos de suavização e previsão SEH e Holt-Winters.

Conforme descrito em Ferreira et al. (2018), o modelo SEH pode definido como:

$$L_t = \alpha Z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (1)$$

e

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2)$$

em que, L_t representa o nível da série no tempo t , T_t estima a tendência no tempo t e α e β são, respectivamente, os parâmetros de suavização para o nível e a tendência, compreendendo os valores do intervalo entre 0 e 1.

A previsão da série temporal (\hat{y}_h) para h passos a frente é dada por:

$$\hat{y}_h = L_t + hT_t \quad (3)$$

nesse caso, a previsão leva em consideração a equação estimada para o nível, com valor estimado para a tendência multiplicada pelo número de passos à frente.

Já o modelo de HW, descrito em [Ferreira et al. \(2018\)](#), também leva em consideração o nível e a tendência da série, sendo adicionada a sazonalidade. Nesse caso, a estimativa da tendência é a mesma proposta na expressão (2) e modificações ocorrem em:

$$L_t = \alpha \left(\frac{Z_t}{S_{t-m}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (4)$$

e

$$S_t = \gamma \left(\frac{Z_t}{L_{t-1} + T_{t-1}} \right) + (1 - \gamma)S_{t-m} \quad (5)$$

para o caso descrito acima, γ representa o parâmetro de suavização da sazonalidade.

Nesse caso, a previsão é representada por:

$$\hat{y}_{t+h} = (L_t + hT_t)S_{t+h-m} \quad (6)$$

na equação (6) temos a previsão h passos a frente.

3.2 Modelos AR, MA, ARMA e ARIMA

Os primeiros quatro modelos - Auto-Regressivo (AR), Média-Móvel (MA), Auto-Regressivo de Médias Móveis (ARMA) e Auto-Regressivo Integrado de Médias Móveis (ARIMA) - são univariados e simples, pois consideram apenas a variável de interesse como endógena, ou seja, são modelados apenas em termos de seus próprios valores passados e um termo estocástico. Esses podem ser representados por:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-j}, \epsilon_t) \quad (7)$$

em que, y_t é a variável de interesse e suas defasagens; $f()$ é a forma funcional; ϵ_t é a estrutura do termo de erro, tal como descrito em [Enders \(2008\)](#).

Essa categoria de modelo é consolidada e disseminada na literatura de previsão e tida como base de comparação entre modelos. Existe uma vasta literatura que documenta esses efeitos, tendo como destaque: [Mohammadi e Su \(2010\)](#) e [Albuquerque et al. \(2018\)](#). Essa modelagem é dividida em três etapas: verificação da estacionariedade das séries, também definida como identificação, estimação e previsão.

Para o caso tratado neste artigo, será utilizada a função *auto.arima()*, em que essa retorna o melhor modelo ARIMA de acordo com o valor AIC, AICc ou BIC. A função realiza uma pesquisa sobre o modelo possível dentro das restrições de pedido fornecidas. Mais detalhes sobre essa função podem ser encontrados em Wang, Smith e Hyndman (2006) e Hyndman, Khandakar et al. (2007).

3.3 Modelo autoregressivo Threshold (TAR)

O modelo auto-regressivo *Threshold* (TAR), descrito por Enders (2008), é um processo auto-regressivo que permite duas ou mais ramificações controladas pelos valores de uma variável limiar (*threshold*), podendo ser representado por:

$$y_t = \begin{cases} \phi_1 y_{t-1} + \epsilon_{1,t} & \text{se } y_{t-1} > 0 \\ \phi_2 y_{t-1} + \epsilon_{2,t} & \text{se } y_{t-1} \leq 0 \end{cases} \quad (8)$$

também conhecido como modelo *threshold* básico. Outra variação comum do modelo TAR é obtida quando as variâncias dos termos de erro são iguais [$var(\epsilon_{1,t}) = var(\epsilon_{2,t})$]. Assim, a equação (8) pode ser expressa como:

$$y_t = \phi_1 I_t y_{t-1} + \phi_2 (1 - I_t) y_{t-1} + \epsilon_t \quad (9)$$

em que, I_t é uma função indicador, ou variável *dummy*, sendo $I_t = 1$ se $y_{t-1} > 0$ e $I_t = 0$ se $y_{t-1} \leq 0$. A estimação da equação (9) é dada por OLS, podendo ser representada, para o caso geral, por:

$$y_t = I_t \left[\phi_{10} + \sum_{i=1}^p \phi_{1i} y_{t-i} \right] + (1 - I_t) \left[\phi_{20} + \sum_{i=1}^p \phi_{2i} y_{t-i} \right] + \epsilon_t \quad (10)$$

em que, $I_t = 1$ se $y_{t-1} > \tau$ e $I_t = 0$ se $y_{t-1} \leq \tau$. Esse caso ilustra a situação em [$var(\epsilon_{1,t}) = var(\epsilon_{2,t})$] e τ conhecido e igual a zero. O uso desse tipo de modelo é recomendado na presença de não linearidade na série.

3.4 Prophet

Agora descrevemos o modelo de previsão de série temporal (Prophet) projetado para lidar com as características comuns das séries temporais e que foi projetado para ter parâmetros intuitivos que podem ser ajustados sem conhecer os detalhes do modelo subjacente, como descrito em Taylor e Letham (2018). Os autores realizam a decomposição da série temporal, conforme proposto por Harvey e Peters (1990), em três componentes: tendência, sazonalidade e feriados. Eles são combinados na seguinte equação:

$$y_t = g_t + s_t + h_t + \epsilon_t \quad (11)$$

em que, g_t é a função de tendência, s_t representa mudanças periódicas (sazonalidade semanal e anual), h_t representa os efeitos dos feriados e ϵ_t representa o termo de erro.

Essa especificação é semelhante a um modelo aditivo generalizado (GAM) descrito em [Hastie e Tibshirani \(1987\)](#), representando uma classe de modelos de regressão com suavizadores potencialmente não lineares aplicados aos regressores. A formulação GAM tem a vantagem de se decompor facilmente e acomodar novos componentes, conforme necessário. Para o caso descrito, a tendência pode ser descrita em um modelo de crescimento e um modelo linear por partes. Quanto a sazonalidade, esses especificam modelos de sazonalidade que são funções periódicas de t e utilizam uma série de Fourier para fornecer um modelo flexível desses efeitos periódicos, tal como proposto em [Harvey e Shephard \(1993\)](#); também é possível levar em consideração os feriados, específicos de cada país ou região. Para mais detalhes, é recomendada a leitura do artigo [Taylor e Letham \(2018\)](#).

3.5 Dados

A coleta de dados será automatizada e irá interagir diretamente com a API Quandl para importar os dados fiscais do Banco Central do Brasil (BCB), via *software* R. Mais detalhes sobre a API Quandl podem ser consultados em <https://www.quandl.com/docs/api>. Serão utilizadas as séries:

Tabela 1 – Descrição dos dados

Nome	Código	Descrição	Fonte
Dívida fiscal líquida	BCB/10825	Dívida fiscal líquida (saldos em R\$)	BCB
Dívida líquida (em %PIB)	BCB/10831	Dívida fiscal líquida (% PIB)	BCB
Dívida bruta do governo	BCB/13761	Abrange o total dos débitos de responsabilidade do Governo Federal, dos governos estaduais e dos governos municipais	BCB
Dívida bruta (em %PIB)	BCB/13762	Dívida bruta do governo geral (% PIB)	BCB
NFSP	BCB/5002	Necessidades de Financiamento do Setor Público incluem o Governo Federal, governos estaduais e municipais, as empresas estatais das três esferas de governo e o BCB.	BCB
NFSP (em %PIB)	BCB/5783	Necessidades de Financiamento do Setor Público (% PIB)	BCB

Fonte – Elaboração própria

Os dados têm periodicidade mensal, tendo como data inicial o mês de dezembro do ano de 2001 e a unidade padrão é R\$ (milhões) para as séries de dívida fiscal líquida, dívida bruta do governo e necessidades de financiamento do setor público e porcentagem (%) para as demais séries.

4 Resultados

Nesta seção será apresentado o aplicativo, bem como, as séries importadas e suas respectivas modelagens e estatísticas. Cabe ressaltar que os modelos de previsão que foram adotados nesta etapa levam em consideração a tendência da série (Holt), tendência e sazonalidade (Holt-Winters), processos autoregressivos, integrados e de médias móveis (ARIMA), modelos com duas ou mais

ramificações controladas pelos valores de uma variável limiar (TAR) e o modelo desenvolvido pelo Facebook para modelar séries com tendência e sazonalidade (Prophet). Ao acessar o link o usuário terá acesso às seguintes informações:

Figura 2 – Aba inicial do aplicativo

- (a) Apresentação dos objetivos e séries tratadas (b) Definição do roteiro da análise estatística

Apresentação

Previsão econômica é o ingrediente chave para tomada de decisão tanto de agentes do setor público quanto privado. Governistas, consumidores, firmas, bancos, instituições financeiras baseiam muitas de suas decisões em expectativas de condições econômicas futuras ou na predição de indicadores de interesses específicos. Este aplicativo tem o propósito de utilizar técnicas univariadas de séries temporais para analisar e prever indicadores relacionados ao tópico fiscal, tais como: dívida líquida (Código 10825), dívida líquida em proporção do PIB (Código 10831), dívida bruta (Código 4502), dívida bruta em proporção do PIB (Código 4537), necessidade de financiamento do setor público (Código 5002) e necessidade de financiamento do setor público em proporção do PIB (Código 5783).

Para mais detalhes, visite o site do Banco Central do Brasil ([BCB](#)).

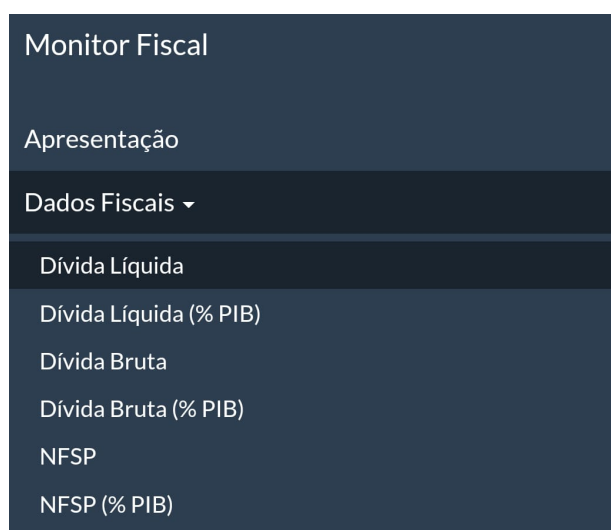
Definição

O uso de modelos econométricos, sejam lineares ou não-lineares, é acompanhado de um roteiro comum, baseado na especificação, estimação, diagnóstico e, por fim, previsão do modelo ou série de tempo. Não pode deixar de ser destacado que cada etapa de modelagem apresentada acima está vinculada ao uso de alguns testes preliminares, tais como: normalidade residual, raiz unitária, estabilidade dos parâmetros, não-linearidade, entre outros.

Para mais detalhes, veja o livro Applied Econometric Time [Series](#).

É importante ressaltar que para manter o anonimato do trabalho foram omitidos alguns trechos do aplicativo, entre eles, logomarcas e trechos associados aos idealizadores do projeto, sendo apresentadas apenas as informações gerais. A aba seguinte apresenta as opções de dados fiscais disponíveis, tais como expostos na Figura 3:

Figura 3 – Selecionando os dados fiscais



Como pode ser visto, nesta aba são mostradas as opções de escolha de análise das séries

de dívida líquida, dívida líquida (% PIB), dívida bruta, dívida bruta (% PIB), necessidade de financiamento do setor público e necessidade de financiamento do setor público (% PIB). Cabe ressaltar que outras séries podem ser incorporadas ao longo do tempo, conforme demanda. De forma ilustrativa, será selecionada a série da dívida líquida e serão apresentados os itens disponíveis para análise do usuário. Todas as séries possuem o mesmo padrão de apresentação e contemplam os mesmos itens: conceito, estatística descritiva, gráfico, modelos SEH, TAR, HW, ARIMA e Prophet, além dos testes de raiz unitária e linearidade.

Figura 4 – Explorando a série dívida líquida



Na aba conceito o usuário vai encontrar a definição econômica da série, periodicidade e *links* que dão acesso à página do BCB e a referência base adotada para os conceitos econômicos utilizados; na sequência é apresentado o gráfico da série, conforme disponibilidade dos dados no site do BCB. Em relação aos métodos de suavização e previsão das séries, destacamos o modelo de suavização exponencial de Holt. Na Figura 5 é possível perceber que os dados são importados (série em cor azul), modelados e previstos (série em cor preta), conforme período escolhido pelo usuário. Para o exemplo descrito acima foram selecionados 10 períodos previstos para fora amostra, em outras palavras, os dados do BCB estão disponíveis até agosto de 2020 e a previsão leva em consideração o período de setembro de 2020 a junho de 2021.

Figura 5 – Método de suavização exponencial de Holt

(a) Monitor de seleção de períodos previstos

Conceito Estatística descritiva Gráfico

SEH TAR HW ARIMA

Prophet Raiz Unitária

Testes de Lineariedade


Descrição

O modelo de suavização exponencial de Holt (SEH) permite realizar a previsão de séries que possuem tendência linear.

Fonte: Banco Central do Brasil.

Escolha o número de períodos previstos

(b) Previsão para fora da amostra



Cabe destacar que os demais modelos seguem a mesma lógica, tanto do ponto de vista de apresentação quanto de escolha de período de predição, do modelo de suavização exponencial de Holt. Assim, em razão da limitação de páginas, serão apresentados apenas aqueles modelos que possuem algum componente operacional distinto daqueles já descritos. Esse é o caso do modelo Prophet, descrito na Figura 6.

Figura 6 – Método de previsão Prophet

(a) Monitor de seleção de períodos previstos

Monitor Fiscal

Apresentação

Dados Fiscais ▾

Conceito Estatística descritiva Gráfico

SEH TAR HW ARIMA

Prophet Raiz Unitária

Testes de Lineariedade


Descrição

O Prophet foi desenvolvido pelo Facebook e projetado para realizar previsão de séries temporais com tendência e sazonalidade.

Janela de treino (meses):

Janela de previsão (meses):

(b) Previsão para fora da amostra



O modelo Prophet é um procedimento utilizado para prever dados de séries temporais com

base em um modelo aditivo em que a tendência pode ser não linear e ajustada com sazonalidade anual, semanal e diária, além dos efeitos de feriados. É importante ressaltar que o Prophet é robusto para dados ausentes e mudanças na tendência e, normalmente, lida bem com *outliers*.

Para esse caso, em específico, utilizamos modelos de aprendizagem de máquina. Em outras palavras, refere-se a criação e ao uso de modelos que são aprendidos a partir dos dados. No nosso caso, trabalhamos com a classe de modelos supervisionados, representando os modelos nos quais existe um conjunto de dados etiquetados com a resposta correta para a aprendizagem. Essa classe de modelo separa a base de dados em treinamento e teste, permitindo ao usuário escolher a janela de treino e o número de períodos que devem ser previstos para fora da amostra. A proposta inserida no aplicativo permite que o usuário escolha uma janela de treino que vai de 12 meses a 60 meses, além disso, é possível realizar previsão para um período de até 12 meses para fora da amostra.

5 Considerações finais

A crise sanitária da Covid-19 aumentou os desafios fiscais para o Brasil, deixando em evidência a importância do acompanhamento e supervisão dos desenvolvimentos fiscais desse país. Uma forma de colaborar com esse monitoramento foi a criação de um aplicativo, descrito como Monitor Fiscal, capaz de importar, modelar e realizar projeções fiscais de médio prazo, colaborando para que as tomadas de decisões políticas de alocação de recursos públicos sejam feitas em bases sustentáveis.

Este artigo ficou limitado a um conjunto de variáveis fiscais e, como uma perspectiva futura, pretende-se incluir outras variáveis fiscais e/ou ampliar a discussão para um Monitor Econômico, ao invés de uma discussão restrita ao tópico fiscal. Além disso, a inclusão de modelos multivariados pode proporcionar maior acurácia para as previsões e auxiliar na explicação dos resultados obtidos.

Referências

- ALBUQUERQUEMELLO, V. P. de et al. Forecasting crude oil price: Does exist an optimal econometric model? *Energy*, Elsevier, v. 155, p. 578–591, 2018.
- ENDERS, W. *Applied econometric time series*. [S.l.]: John Wiley & Sons, 2008.
- FERREIRA, P. G. C. et al. *Análise de Séries Temporais em R: curso introdutório*. [S.l.]: Rio de Janeiro: Elsevier, 2018.
- GHYSELS, E.; MARCELLINO, M. *Applied Economic Forecasting Using Time Series Methods*. [S.l.]: Oxford University Press, 2018.
- HAMILTON, J. D. *Time series analysis*. [S.l.]: Princeton university press Princeton, 1994. v. 2.
- HARVEY, A. C.; PETERS, S. Estimation procedures for structural time series models. *Journal of Forecasting*, Wiley Online Library, v. 9, n. 2, p. 89–108, 1990.

- HARVEY, A. C.; SHEPHARD, N. Structural time series models. In: NORTH HOLLAND. *Handbook of Statistics*. (edited by g.s. maddala, c.r. rao and h.d. vinod). Amsterdam: North Holland, 1993. Vol. 11:Econometrics, p. 261–302.
- HASTIE, T.; TIBSHIRANI, R. Generalized additive models: some applications. *Journal of the American Statistical Association*, Taylor & Francis, v. 82, n. 398, p. 371–386, 1987.
- HYNDMAN, R. J.; KHANDAKAR, Y. et al. *Automatic time series for forecasting: the forecast package for R*. [S.l.]: Monash University, Department of Econometrics and Business Statistics . . . , 2007.
- MOHAMMADI, H.; SU, L. International evidence on crude oil price dynamics: Applications of arima-garch models. *Energy Economics*, Elsevier, v. 32, n. 5, p. 1001–1008, 2010.
- MONITOR, F.; OUTLOOK, R. E. Special series on covid-19. *Policy*, 2020.
- TAYLOR, S. J.; LETHAM, B. Forecasting at scale. *The American Statistician*, Taylor & Francis, v. 72, n. 1, p. 37–45, 2018.
- WANG, X.; SMITH, K.; HYNDMAN, R. Characteristic-based clustering for time series data. *Data mining and knowledge Discovery*, Springer, v. 13, n. 3, p. 335–364, 2006.