

Orair, Rodrigo Octávio; Silva, Wesley de Jesus

Working Paper

Investimentos dos governos subnacionais no Brasil: Estimação e análise por modelos de espaço de estado

Texto para Discussão, No. 1771

Provided in Cooperation with:

Institute of Applied Economic Research (ipea), Brasília

Suggested Citation: Orair, Rodrigo Octávio; Silva, Wesley de Jesus (2012) : Investimentos dos governos subnacionais no Brasil: Estimação e análise por modelos de espaço de estado, Texto para Discussão, No. 1771, Instituto de Pesquisa Econômica Aplicada (IPEA), Brasília

This Version is available at:

<https://hdl.handle.net/10419/91089>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

INVESTIMENTOS DOS GOVERNOS SUBNACIONAIS NO BRASIL: ESTIMAÇÃO E ANÁLISE POR MODELOS DE ESPAÇO DE ESTADO

Rodrigo Octávio Orair
Wesley de Jesus Silva

INVESTIMENTOS DOS GOVERNOS SUBNACIONAIS NO BRASIL: ESTIMAÇÃO E ANÁLISE POR MODELOS DE ESPAÇO DE ESTADO*

Rodrigo Octávio Orair**

Wesley de Jesus Silva***

* Os autores gostariam de agradecer Hilberton Onofre, Wuarli Santos e demais colegas da Divisão de Sistemas da Coordenação-Geral de Modernização e Tecnologia da Informação do Ipea, que desenvolveram rotinas computacionais para extração em sítios eletrônicos dos relatórios orçamentários dos estados e milhares de municípios brasileiros. Agradecem ainda Aretha Soares, Ézio Leal, Wanderson Silva e Thaís Texeira, assistentes de pesquisa da Coordenação de Finanças Públicas da Diretoria de Estudos e Políticas Macroeconômicas (Dimac) do Ipea, que contribuíram na estruturação destas informações extremamente úteis para o trabalho.

** Técnico de Planejamento e Pesquisa da Coordenação de Finanças Públicas (CFP) da Diretoria de Estudos e Políticas Macroeconômicas (Dimac) do Ipea.

*** Assistente de pesquisa da Coordenação de Finanças Públicas (CFP) da Diretoria de Estudos e Políticas Macroeconômicas (Dimac) do Ipea.

Governo Federal

**Secretaria de Assuntos Estratégicos da
Presidência da República**
Ministro Wellington Moreira Franco

ipea Instituto de Pesquisa
Econômica Aplicada

Fundação pública vinculada à Secretaria de Assuntos Estratégicos da Presidência da República, o Ipea fornece suporte técnico e institucional às ações governamentais – possibilitando a formulação de inúmeras políticas públicas e programas de desenvolvimento brasileiro – e disponibiliza, para a sociedade, pesquisas e estudos realizados por seus técnicos.

Presidente

Marcelo Cortes Neri

Diretor de Desenvolvimento Institucional

Geová Parente Farias

Diretora de Estudos e Relações Econômicas e Políticas Internacionais

Luciana Acioly da Silva

Diretor de Estudos e Políticas do Estado, das Instituições e da Democracia

Alexandre de Ávila Gomide

Diretor de Estudos e Políticas Macroeconômicas, Substituto

Claudio Roberto Amitrano

Diretor de Estudos e Políticas Regionais, Urbanas e Ambientais

Francisco de Assis Costa

Diretor de Estudos e Políticas Setoriais de Inovação, Regulação e Infraestrutura

Carlos Eduardo Fernandez da Silveira

Diretor de Estudos e Políticas Sociais

Jorge Abrahão de Castro

Chefe de Gabinete

Fabio de Sá e Silva

Assessor-chefe de Imprensa e Comunicação, Substituto

João Cláudio Garcia Rodrigues Lima

Ouvidoria: <http://www.ipea.gov.br/ouvidoria>

URL: <http://www.ipea.gov.br>

Texto para Discussão

Publicação cujo objetivo é divulgar resultados de estudos direta ou indiretamente desenvolvidos pelo Ipea, os quais, por sua relevância, levam informações para profissionais especializados e estabelecem um espaço para sugestões.

© Instituto de Pesquisa Econômica Aplicada – **ipea** 2012

Texto para discussão / Instituto de Pesquisa Econômica Aplicada.- Brasília : Rio de Janeiro : Ipea , 1990-

ISSN 1415-4765

1. Brasil. 2. Aspectos Econômicos. 3. Aspectos Sociais.
I. Instituto de Pesquisa Econômica Aplicada.

CDD 330.908

As opiniões emitidas nesta publicação são de exclusiva e inteira responsabilidade do(s) autor(es), não exprimindo, necessariamente, o ponto de vista do Instituto de Pesquisa Econômica Aplicada ou da Secretaria de Assuntos Estratégicos da Presidência da República.

É permitida a reprodução deste texto e dos dados nele contidos, desde que citada a fonte. Reproduções para fins comerciais são proibidas.

JEL: C82, E69 e H72

SUMÁRIO

SINOPSE

ABSTRACT

1 INTRODUÇÃO	7
2 MODELO DE ESPAÇO DE ESTADO E SUAS EXTENSÕES PARA DESAGREGAÇÃO TEMPORAL E PREVISÃO CONTEMPORÂNEA.....	9
3 FONTES DE DADOS	19
4 DESAGREGAÇÃO TEMPORAL DOS INVESTIMENTOS DOS GOVERNOS SUBNACIONAIS	21
5 COMPONENTES ESTRUTURAIS DA FBCF DOS GOVERNOS SUBNACIONAIS	24
6 PREVISÃO CONTEMPORÂNEA	31
7 CONSIDERAÇÕES FINAIS.....	35
REFERÊNCIAS	36
ANEXOS	39

SINOPSE

A carência de séries agregadas de alta frequência e os problemas não triviais que devem ser enfrentados para estimação destas séries criam obstáculos à pesquisa aplicada nas finanças públicas subnacionais. Os modelos de espaço de estados (MEEs) fornecem um arcabouço para lidar com uma ampla gama destes problemas, e as técnicas que derivam desta abordagem, como a desagregação temporal e a previsão contemporânea, são utilizadas neste trabalho para estimar as séries mensais dos investimentos dos governos subnacionais no período 2002-2011. O arcabouço de MEE também provê um instrumento para análise destas séries. Entre os resultados encontrados, pode-se destacar a estimação endógena de componentes cíclicos coincidentes com os ciclos eleitorais, tanto nos investimentos do governo estadual quanto do governo municipal, provendo-se evidências empíricas para a literatura sobre ciclos políticos eleitorais, inéditas em séries agregadas de alta frequência das finanças públicas subnacionais. As técnicas utilizadas também podem ser facilmente adaptáveis às demais séries relevantes. O objetivo do trabalho é apresentar um arcabouço metodológico tanto para estimação de séries atualizadas em alta frequência quanto para análise do desenvolvimento das séries das finanças públicas subnacionais, fornecendo-se um instrumental útil para o monitoramento da política fiscal e para a pesquisa macroeconômica aplicada.

Palavras-chave: investimento público; modelo de espaço de estados; finanças públicas subnacionais.

ABSTRACTⁱ

There are many problems involved in estimating high frequency series for subnational governments. Space State Model (SSM) is a framework capable of handling some of these problems. The techniques that emerge from this approach (temporal disaggregation and nowcasting) are used to estimate monthly series for capital investments by subnational governments in Brazil during 2002-2011. SSM are also used to analyze the dynamic properties of time series. One of the most interesting

i. As versões em língua inglesa das sinopses (*abstracts*) desta coleção não são objeto de revisão pelo Editorial do Ipea.
The versions in English of the abstracts of this series have not been edited by Ipea's editorial department.

results is the newly evidence of electoral cycles on investments of both municipalities and states in Brazil. These techniques might be easily generalized for other relevant series. The main objective of this work is to present a methodological framework for estimating and analyzing the development of high frequency series for Brazilians subnational governments. It offers a useful instrument for monitoring fiscal policy and for applied macroeconomic research.

Keywords: public investment; space state model; subnational public finance.

1 INTRODUÇÃO

Os governos subnacionais representam uma parcela expressiva dos investimentos públicos, que alcançou R\$ 70,8 bilhões ou quase dois terços do montante de R\$ 104,9 bilhões investidos pelas administrações públicas no Brasil em 2010. Além da sua magnitude, a importância desta variável é reconhecida por quase todas as escolas de pensamento em economia e explorada em diversos estudos empíricos. Para citar alguns exemplos, Rodrigues e Teixeira (2010) investigaram as relações entre os gastos públicos das diferentes esferas de governo e o crescimento econômico brasileiro. A partir de informações anuais no período 1948-1998, estes autores chegaram à conclusão de que os maiores efeitos são exercidos pelos investimentos e, mais particularmente, aqueles executados pelo governo estadual. Sanches e Rocha (2010) mensuraram o impacto do investimento público dos governos estaduais sobre o investimento privado e encontraram forte relação de complementaridade, evidenciada na maior parte dos estados, a partir de dados anuais em painel para o período de 1991 a 2004. A importância dos investimentos dos governos subnacionais também é destacada nos trabalhos que exploram a existência de ciclos políticos eleitorais das despesas públicas, a exemplo de Nakaguma e Bender (2006), que utilizaram um painel dinâmico no período 1986-2004 para encontrar evidências de um ajuste fiscal pós-eleitoral nos investimentos dos governos estaduais, e Sakurai (2007), que não encontrou uma relação significativa entre investimentos públicos e ciclos eleitorais dos municípios brasileiros na maior parte do período 1989-2003.

É importante observar, entretanto, que tais estudos aplicados estão restritos às informações anuais que cobrem períodos longos, muitas vezes sujeitos a mudanças metodológicas e distorções do período hiperinflacionário brasileiro. Até onde se tem conhecimento, inexistem trabalhos empíricos sobre os investimentos dos governos subnacionais com séries agregadas de alta frequência. Esta lacuna na literatura pode ser atribuída, em grande medida, às dificuldades envolvidas na estimação das séries e que derivam de problemas nas informações primárias (conceitos não harmonizados aos demais sistemas estatísticos macroeconômicos, graus de abertura e de cobertura inadequados, inconsistência e irregularidade das informações etc.), que serão abordados na seção 3 deste trabalho. Infelizmente, não é incomum a situação na qual as séries agregadas das finanças públicas – e mais especificamente as séries de investimentos – estejam defasadas e disponíveis somente em baixa frequência (anual), ao mesmo tempo em que as séries mais atualizadas e de alta frequência (mensal ou bimestral) são exclusivas para uma amostra de municípios e estados ou constituem indicadores relacionados (não inteiramente compatíveis).

Os modelos de espaço de estados (MEEs), por sua vez, proveem um arcabouço unificado para lidar com uma ampla gama destes problemas, por meio de técnicas como desagregação temporal e previsão contemporânea (*nowcasting*), que serão discutidas na seção 2. O recurso a metodologias de desagregação temporal para construção de séries de alta frequência das receitas públicas municipais, com indicadores obtidos das informações de uma amostra de municípios do Brasil, já está presente em trabalhos como Orair *et al.* (2011) e Dias, Issler e Rodrigues (2010). Este último trabalho seguiu a metodologia de desagregação temporal por MEEs utilizada em Monch e Uhlig (2005), que é uma implementação da estrutura apresentada em Harvey (1989).

A seção 4 do presente trabalho aplica a mesma metodologia para estimar séries mensais dos investimentos dos governos subnacionais no período 2002-2010.¹ Além disto, o trabalho generaliza o uso dos MEEs na previsão contemporânea destas séries para o ano de 2011 e na estimação do modelo estrutural básico dos investimentos nos governos subnacionais, cujos resultados serão apresentados nas seções 5 e 6. A grande vantagem da técnica de previsão contemporânea é que fornece um indicador conjuntural para monitoramento da política fiscal. O modelo estrutural também se mostrou útil para análise da dinâmica e identificação dos fatos estilizados das séries de investimentos públicos que possuem componentes estruturais muito característicos (tendência, ciclos, sazonalidade etc.). Entre os resultados encontrados, pode-se destacar a estimação endógena de componentes cíclicos, tanto nos investimentos do governo estadual quanto do governo municipal, que apresentam frequência e comportamento coincidentes com os ciclos eleitorais. Oferecem-se evidências empíricas adicionais para a literatura que explora as relações entre ciclos políticos eleitorais e despesas públicas no Brasil.²

Tais evidências são inéditas em séries agregadas de alta frequência das finanças públicas subnacionais que possibilitam uma estimação mais precisa da dinâmica cíclica (e dos demais componentes estruturais) ao longo do tempo. Ainda que

1. Os autores gostariam de agradecer Emanuel Mönch e Harald Uhlig, que gentilmente se prontificaram a ceder rotina computacional em formato apropriado para o programa MatLab. Opta-se aqui por adaptar esta rotina para formato de *software* livre, compatível com a linguagem em *R*. Esta rotina e as séries estimadas neste trabalho podem ser disponibilizadas para quaisquer pesquisadores mediante contato por correio eletrônico com os autores.

2. Foge do escopo deste trabalho apresentar esta extensa literatura, que remonta pelo menos a Kalecki (1943). Uma resenha teórica pode ser consultada em Fialho (1999) e também nas teses de doutorado de Cossio (2002) e Sakurai (2007), que, adicionalmente, apresentam evidências empíricas de ciclos eleitorais nos governos subnacionais brasileiros utilizando painéis de dados com informações anuais desde a década de 1980.

restritas aos investimentos públicos, as técnicas utilizadas neste trabalho podem ser facilmente adaptáveis às demais séries relevantes. O trabalho apresenta, portanto, um arcabouço metodológico tanto para estimação de séries atualizadas em alta frequência quanto para análise do desenvolvimento das séries das finanças públicas subnacionais, fornecendo-se um instrumental útil para o monitoramento da política fiscal, que abre grandes perspectivas para a pesquisa macroeconômica aplicada.

2 MODELO DE ESPAÇO DE ESTADO E SUAS EXTENSÕES PARA DESAGREGAÇÃO TEMPORAL E PREVISÃO CONTEMPORÂNEA

O arcabouço de espaço de estados é bastante geral no sentido de que qualquer modelo linear de série temporal pode ser formulado por meio da representação ou forma de espaço de estado (FEE, ou, em inglês, *state space form* – SSF).³ A característica distintiva desta abordagem é que se admite que as séries temporais observadas, reunidas no vetor $\mathbf{y}_t$ para $t = 1, \dots, n$, são formadas por componentes diferenciados de tendência, sazonalidade, ciclo, componente irregular e outros componentes da regressão. Estes componentes estruturais são modelados separadamente e, em seguida, reunidos para formar um único modelo, denominado modelo de espaço de estados (MEE). A estrutura básica do MEE parte do pressuposto de que o desenvolvimento das séries temporais é determinado por uma série de vetores não observados α_t , que, em determinado período t , é denominado estado da série, em conjunto com a série de valores observados $\mathbf{y}_t$. A relação entre as séries observadas ($\mathbf{y}_t$) e os vetores não observados (α_t) é especificada pelo MEE segundo o sistema de equações a seguir.

$$\mathbf{y}_t = \mathbf{Z}_t' \alpha_t + \varepsilon_t \quad \varepsilon_t \sim \text{NID}(\mathbf{0}, \mathbf{H}_t) \quad (1)$$

$$\alpha_t = \mathbf{T}_t \alpha_{t-1} + \mathbf{R}_t \eta_t \quad \eta_t \sim \text{NID}(\mathbf{0}, \mathbf{Q}_t) \quad (2)$$

A equação (1) é denominada *equação de observação* e (2) é a *equação de estado* (ou equação de transição). A ideia subjacente ao modelo é relativamente simples:

3. O foco desta seção será sobre modelos lineares gaussianos, ainda que os avanços recentes dos MEEs sejam principalmente sobre modelos não lineares e não gaussianos. Uma discussão mais detalhada pode ser vista em Harvey (1989) e Durbin e Koopman (2001). Por sua vez, Commandeur e Koopman (2007) é uma referência mais didática.

o desenvolvimento das séries temporais é determinado pelo vetor de estados α_t de ordem $m \times 1$, que pode variar ao longo do tempo, já que possui uma estrutura autorregressiva de primeira ordem indicada na equação (2). Contudo, o vetor α_t não pode ser observado diretamente e a análise deve se basear nas p séries temporais observadas no vetor y_t de dimensão $p \times 1$, conforme estabelecido pela equação de observação em (1). O objetivo do MEE, portanto, é estudar o desenvolvimento do estado da série ao longo do tempo (α_t) utilizando os valores observados (y_t).

As matrizes Z_t e T_t são, respectivamente, as matrizes de observação e de transição, sendo Z_t de dimensão $p \times m$ e T_t $m \times m$. O vetor ε_t de ordem $p \times 1$ contém os p resíduos da equação de observação – que seguem os supostos usuais e sua estrutura de variância-covariância está representada na matriz H_t de ordem $p \times p$ – e formam o *componente irregular* dos MEEs. Os demais componentes estruturais da série temporal estão relacionados aos m elementos do *vetor de estados* (α_t), que podem incluir tendência, sazonalidade, ciclos e outros componentes.

Um exemplo que desempenha papel proeminente na abordagem de Harvey (1989) e que será utilizado mais adiante neste trabalho é o modelo estrutural básico. Nesta especificação, a série observada é formada por componentes aditivos de tendência (μ_t), sazonalidade (γ_t) e componente irregular (ε_t). Pode-se também adicionar outros elementos relevantes, como um componente cíclico (ψ_t). A equação de observação será descrita como se segue:

$$y_t = \mu_t + \gamma_t + \psi_t + \varepsilon_t \quad \varepsilon_t \sim \text{NID}(0, \sigma_\varepsilon^2) \quad (3)$$

Os componentes estruturais do estado da série são descritos pelo sistema de equações a seguir.

$$\begin{aligned} \mu_t &= \mu_{t-1} + v_{t-1} + \xi_t & \xi_t &\sim \text{NID}(0, \sigma_\xi^2) \\ v_t &= v_{t-1} + \zeta_t & \zeta_t &\sim \text{NID}(0, \sigma_\zeta^2) \\ \gamma_t &= -\gamma_{t-1} - \gamma_{t-2} + \omega_t & \omega_t &\sim \text{NID}(0, \sigma_\omega^2) \\ \psi_t &= \rho\psi_{t-1} \cos \lambda + \rho\psi_{t-1}^* \sin \lambda + \kappa_t & \kappa_t &\sim \text{NID}(0, \sigma_\kappa^2) \\ \psi_t^* &= -\rho\psi_{t-1} \sin \lambda + \rho\psi_{t-1}^* \cos \lambda + \kappa_t^* & \kappa_t^* &\sim \text{NID}(0, \sigma_{\kappa^*}^2) \end{aligned} \quad (4)$$

Nesse sistema admitem-se formulações simplificadas e uma frequência quadrimstral. O componente de tendência está modelado por um elemento de nível (μ_t) e sua inclinação (v_t). O componente sazonal (γ_t) está representado por $(s - 1)$ elementos, sendo s a periodicidade da série (neste exemplo, $s = 3$), e contém um termo de distúrbio de maneira a permitir que o padrão sazonal se modifique ao longo do tempo. Por fim, o componente cíclico (ψ_t) é modelado na forma de uma onda gerada por funções trigonométricas, em que λ é a frequência do ciclo medida em radianos, correspondente ao período do ciclo ($2\pi/\lambda$) com $0 < \lambda \leq \pi$, ρ é chamado fator de desconto (ou de amortecimento), ψ_t é o valor corrente do ciclo e ψ_t^* aparece por construção para formar ψ_t . Note-se que a periodicidade da sazonalidade é conhecida e normalmente inferior ao período do ciclo que é um parâmetro desconhecido a ser estimado.⁴

O modelo descrito no sistema de equações em (3) e (4) é apenas um caso particular da especificação geral do MEE em (1) e (2), como se pode deduzir após a definição dos escalares, vetores e matrizes apresentados a seguir.

$$y_t = y_t, \alpha_t = \begin{pmatrix} \mu_t \\ v_t \\ \gamma_t \\ \gamma_{t-1} \\ \psi_t \\ \psi_t^* \end{pmatrix}, \mathbf{z}_t = \begin{pmatrix} 1 \\ 0 \\ 1 \\ 0 \\ 1 \\ 0 \end{pmatrix}, \varepsilon_t = \varepsilon_t, H_t = \sigma_\varepsilon^2,$$

$$\mathbf{T}_t = \begin{pmatrix} 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & -1 & -1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \rho \cos \lambda & \rho \sin \lambda \\ 0 & 0 & 0 & 0 & -\rho \sin \lambda & \rho \cos \lambda \end{pmatrix},$$

$$\mathbf{R}_t = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}, \boldsymbol{\eta}_t = \begin{pmatrix} \xi_t \\ \zeta_t \\ \omega_t \\ \kappa_t \\ \kappa_t^* \end{pmatrix} \text{ e } \mathbf{Q}_t = \begin{pmatrix} \sigma_\xi^2 & 0 & 0 & 0 & 0 \\ 0 & \sigma_\zeta^2 & 0 & 0 & 0 \\ 0 & 0 & \sigma_\omega^2 & 0 & 0 \\ 0 & 0 & 0 & \sigma_\kappa^2 & 0 \\ 0 & 0 & 0 & 0 & \sigma_{\kappa^*}^2 \end{pmatrix}$$

4. Mais detalhes e formulações alternativas dos componentes no modelo estrutural básico podem ser vistos em Durbin e Koopman (2001, p. 40-42).

O MEE também permite a inclusão de outros componentes de regressão, a exemplo de variáveis explicativas e de intervenção ou componentes autorregressivos da série observada e dos seus resíduos. Para exemplificar, suponha-se o modelo univariado definido por

$$y_t = y_t, \quad \alpha_t = \begin{pmatrix} \mu_t \\ \beta_t \\ \theta \\ \phi \\ u_t \end{pmatrix}, \quad \mathbf{Z}_t = \begin{pmatrix} 1 \\ x_t \\ w_t \\ y_{t-1} \\ 1 \end{pmatrix}, \quad \mathbf{T}_t = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & \rho \end{pmatrix}, \quad \mathbf{R}_t = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \end{pmatrix},$$

$$\boldsymbol{\eta}_t = \begin{pmatrix} \xi_t \\ \zeta_t \\ \varepsilon_t \end{pmatrix} \text{ e } \mathbf{Q}_t = \begin{pmatrix} \sigma_\xi^2 & 0 & 0 \\ 0 & \sigma_\zeta^2 & 0 \\ 0 & 0 & \sigma_\varepsilon^2 \end{pmatrix}$$

Esta formulação considera um componente de tendência (μ_t), modelada por um elemento de nível, e um primeiro componente da regressão ($\beta_t x_t$), relacionado à inclusão no modelo de uma variável explicativa (x_t) e seu parâmetro associado (β_t), modelado na forma de um passeio aleatório. O terceiro componente capta o efeito de uma intervenção (θw_t), modelado por uma variável categórica (w_t), que assume valor 1 a partir do período τ , e 0 caso contrário, e representa uma mudança de magnitude θ no nível da equação de observação. Os dois últimos elementos do vetor de estados α_t são componentes autorregressivos de primeira ordem para a série observada (ϕy_{t-1}) e para os seus resíduos ($u_t = \rho u_{t-1} + \varepsilon_t$).

É importante observar que este MEE pode ser generalizado, por exemplo, pela inclusão de outras séries observadas (modelos multivariados) e variáveis explicativas ou pela combinação com os demais componentes estruturais representados no modelo estrutural básico em (3) e (4). A inclusão dos componentes estruturais, que têm correspondência com um ou mais elementos do vetor de estados α_t , exigirá equações adicionais em (2). O mais comum é que estas equações estejam na forma estocástica de um passeio aleatório, mas a modelagem admite outras representações ou elementos determinísticos. Independentemente da forma específica de cada representação, o aspecto central é que a equação de estado (2) considera explicitamente as dependências temporais das séries ao permitir que o estado no período t (α_t) seja uma função do estado no período anterior (α_{t-1}) e de um vetor $\boldsymbol{\eta}_t$ de distúrbios.

A delimitação dos elementos do vetor de estado α_t que serão processos estocásticos ou determinísticos dependerá da avaliação da estimativa da variância do distúrbio associado: valores próximos a zero indicam que deve ser tratado como determinístico (fixo ao longo do tempo) e, caso contrário, será estocástico (variável). As linhas não nulas da matriz de seleção R_t , de ordem $m \times r$ com $r \leq m$ colunas de uma matriz identidade de ordem m , indicam as r linhas da equação de estado que terão elementos estocásticos.⁵ O vetor η_t será formado pelos distúrbios destes elementos estocásticos que seguem os supostos usuais e suas respectivas variâncias (desconhecidas) estarão representadas na matriz Q_t de dimensão $r \times r$.

A estimação dos parâmetros em (1) e (2) é realizada por máxima verossimilhança via processo de atualização recursiva do filtro de Kalman, conforme as fórmulas apresentadas a seguir.

$$\begin{aligned} \mathbf{a}_{t+1} &= \mathbf{T}_t \mathbf{a}_t + \mathbf{K}_t \mathbf{v}_t \\ \mathbf{v}_t &= \mathbf{y}_t - \mathbf{Z}_t \mathbf{a}_t \end{aligned} \quad (5)$$

Em (5), $\mathbf{a}_t$ é o estado filtrado de Kalman no período t , e $\mathbf{v}_t$ é o erro de previsão um passo à frente, que é denominado inovação, uma vez que traz informações de uma nova observação do período corrente ($\mathbf{y}_t$). O objetivo do filtro de Kalman é encontrar valores ótimos da estimativa do estado filtrado no próximo período ($\mathbf{a}_{t+1}$) a partir das observações disponíveis até o período corrente t , que dependerá da estimativa no período anterior ($\mathbf{a}_t$) baseada nas observações passadas, mas será atualizada pela incorporação da inovação ($\mathbf{v}_t$). O grau de influência que a inovação exercerá sobre a estimativa $\mathbf{a}_{t+1}$ dependerá do termo $\mathbf{K}_t$, denominado ganho de Kalman, cujo valor será tão maior – e, portanto, a inovação terá maior influência sobre a estimativa do estado filtrado – quanto maior for o grau de incerteza da estimativa de estado em relação à incerteza das inovações.⁶

5. Se não houver elementos determinísticos, R_t será uma matriz identidade. Outro caso especial é quando a matriz R_t é nula e todos são determinísticos (fixos). Pode-se mostrar que este caso será equivalente à análise clássica de regressão linear e quaisquer dos seus modelos (multivariados, Arima etc.) podem ser representados por MEE, impondo-se a restrição de que todos os elementos do estado da série são determinísticos.

6. Os graus de incerteza são medidos pelas estimativas das variâncias dos erros de previsão um passo à frente e do estado filtrado.

Uma propriedade útil deste processo de estimação recursiva é que, na ausência de novas observações, a melhor previsão do estado filtrado no período $t + 1$ será simplesmente a estimativa filtrada do período anterior t ; isto é, os valores da inovação na equação (5) serão zero ($K_t v_t = \mathbf{0}$) e não haverá atualização ($\mathbf{a}_{t+1} = \mathbf{a}_t$). Deriva daí a flexibilidade do modelo para lidar com valores faltantes (*missing values*) e outras irregularidades nos dados. O suavizador e o filtro de Kalman são conduzidos normalmente e o modelo estimado pode inclusive ser utilizado para imputação de valores faltantes ou previsão.⁷

Em resumo, o que se entende como modelo estrutural de séries temporais é uma formulação bastante geral na qual cada um dos componentes estruturais é modelado explicitamente, considerando-se tanto os componentes usuais (tendência, ciclo, sazonalidade e irregular) quanto suas extensões multivariadas para explorar relações causais ou melhorar o ajuste do modelo. As técnicas que emergem desta abordagem são bastante flexíveis no sentido de aplicáveis a quaisquer modelos lineares e capazes de lidar com uma série de problemas relacionados às irregularidades nos dados. Para os propósitos mais imediatos deste trabalho, duas extensões são particularmente importantes: o uso dos MEEs para a desagregação temporal e previsão contemporânea (*nowcasting*).

Esses problemas ocorrem quando as informações em alta frequência de uma determinada série não estão disponíveis ou são disponibilizadas com defasagens, mas se pode dispor de uma ou mais séries correlacionadas e que estão na frequência desejada. A série original é conhecida como série de referência (*benchmark*), e as séries correlacionadas formam os indicadores relacionados. O objetivo é estimar as informações intra-período da série de referência (desagregação temporal) ou atualizá-la (previsão contemporânea) de modo a preservar o máximo possível os movimentos de curto prazo nos dados originais sob as restrições advindas da série de referência.

Mais precisamente, o tipo de problema que se procura solucionar com a desagregação temporal ocorre quando a série de referência y_τ , $\tau = 1, \dots, m$ é observada de maneira agregada temporalmente e se deseja uma série de maior frequência y_t , $t = 1, \dots, \delta m$, onde δ é o número de períodos em alta frequência que completam

7. As estimativas do estado da série (e das suas variâncias dos distúrbios) são utilizadas para prover estimativas da série temporal (e respectivos intervalos de confiança) para fins de imputação dos valores faltantes ou previsões. No caso da imputação normalmente se utiliza a estimativa suavizada do vetor de estados, na qual todas as observações são utilizadas (inclusive as informações futuras) e requer-se a aplicação adicional de um algoritmo recursivo para trás ao produto do filtro de Kalman, conhecido como suavizador.

o período de baixa frequência. O objetivo da desagregação temporal é estimar de maneira ótima a série de alta frequência y_t , sujeita à restrição de que a soma dos seus valores dentro de cada período se iguale à série de valores de referência y_t , normalmente fazendo-se uso das informações dos indicadores relacionados, $x_{it}, i = 1, \dots, k$ que são observados na frequência δ .⁸

Para que possa ser representada na forma de espaço de estados, considera-se uma nova série $y_t^+, t = 1, \dots, \delta m$, que contém os mesmos m elementos da série de referência y_t e os pontos intermediários são igualados a zero. Formalmente, define-se y_t^+ como em (6).

$$y_t^+ = \sum_{r=0}^{(\delta\tau-1)} y_{t-r} \quad \text{para } t = \delta\tau, \tau = 1, 2, \dots, m, \text{ e} \quad (6)$$

$$y_t^+ = 0 \quad \text{caso contrário.}$$

Suponha-se, por exemplo, que a série de frequência anual y_t seja observada durante o período de dez anos ($m = 10$) e se pretenda observar seus valores quadrimestrais. O objetivo é estimar a série y_t pelo período de trinta quadrimestres ($\delta m = 30$) e a série observada y_t^+ será:

$$y_t^+ = (0, 0, y_1 + y_2 + y_3, 0, 0, y_4 + y_5 + y_6, \dots, 0, 0, y_{28} + y_{29} + y_{30})$$

A lógica por trás da metodologia de desagregação temporal por MEE é relativamente simples. Primeiramente, pode-se definir a equação de observação por (6) que relaciona a série observada y_t^+ com a série não observada que se deseja estimar y_t . Esta equação de observação não contém um termo de distúrbio e a série observada y_t^+ é composta de valores não nulos que correspondem ao agregado dos valores da série não observada y_t dentro

8. A literatura direcionada para solucionar este tipo de problema é vasta, incluindo-se tanto as abordagens numéricas (não paramétricas) quanto as abordagens paramétricas, entre as quais, a utilização dos métodos por MEE tem sido frequente. O uso do MEE para desagregação temporal segue várias vertentes, cada uma dependendo da estrutura adotada. Harvey (1989) propôs inicialmente o uso de variáveis cumulantes, estrutura que, em seguida, foi adaptada em Harvey e Chung (2000) e Moauro e Savio (2005), de modo que a série de referência e os indicadores relacionados formam um vetor multivariado. Mais recentemente, trabalhos como Proietti (2006) e Monch e Uhlig (2005) revisaram as estruturas dinâmicas aplicadas em MEE, permitindo-se várias alternativas como os modelos com resíduos AR(1), resíduos em primeiras diferenças e, finalmente, modelos com estrutura dinâmica. O presente trabalho segue uma abordagem semelhante à de Monch e Uhlig (2005).

de cada período $t = \delta\tau$, tais que $\delta(\tau - 1) < t \leq \delta\tau$. Isto implica impor a restrição de que a soma dos valores y_t dentro de cada período seja exatamente igual ao valor da série de referência y_t^+ (por exemplo, o agregado dos quadrimestres será igual ao total observado no ano).

Em segundo lugar, os valores intermediários da série de alta frequência y_t (não observados) são incluídos no vetor de estados (α_t) em conjunto com outros componentes da regressão. É possível definir estruturas bastantes gerais para esta regressão que incluem indicadores relacionados ou termos autorregressivos. Um exemplo é o modelo dinâmico com resíduos autorregressivos de primeira ordem, como em (7).

$$\begin{aligned} y_t &= \phi y_{t-1} + \mu + \beta x_t + u_t \\ u_t &= \rho u_{t-1} + \varepsilon_t \end{aligned} \quad \varepsilon_t \sim NID(0, \sigma_\varepsilon^2) \quad (7)$$

Nesse modelo, admite-se que a variável a ser estimada y_t é uma função linear do indicador relacionado x_t e de componentes autorregressivos da própria série (ϕy_{t-1}) e dos resíduos ($u_t = \rho u_{t-1} + \varepsilon_t$).

A desagregação temporal para uma série-objetivo de frequência quadrimestral ($\delta = 3$) e utilizando a estrutura de modelo em (7) pode ser representada no formato geral do MEE a partir das definições a seguir.

$$y_t = y_t^+, \quad \alpha_t = \begin{pmatrix} y_t \\ y_{t-1} \\ y_{t-2} \\ \mu \\ \beta \\ u_t \end{pmatrix}, \quad Z_t = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 0 \\ 0 \\ 0 \end{pmatrix} \text{ para } t = 3\tau, \tau = 1, 2, \dots, m, \quad \text{e} \quad Z_t = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} \text{ caso}$$

contrário; $\varepsilon_t = 0$,

$$T_t = \begin{pmatrix} \phi & 0 & 0 & 1 & x_t & \rho \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & \rho \end{pmatrix}, \quad R_t = \begin{pmatrix} 1 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 1 \end{pmatrix} \text{ e } \eta_t = \begin{pmatrix} \varepsilon_t \\ \varepsilon_t \end{pmatrix}$$

Ressalta-se que este modelo de desagregação temporal pode ser generalizado para quaisquer frequências (não necessariamente quadrimestral) e para inclusão de mais de um indicador relacionado ou estruturas autorregressivas alternativas. Sobre este último aspecto, as estruturas de regressão detalhadas no quadro 1 e em Monch e Uhlig (2005) são obtidas pela imposição de diferentes restrições aos parâmetros ϕ e ρ na matriz de transição T_t . Uma vez especificada a estrutura do modelo, o objetivo da desagregação temporal é estimar a série não observada y_t , o que se faz pela inclusão dos seus valores intermediários no vetor de estados e estimação deste componente não observado do MEE.

QUADRO 1

Restrições dos parâmetros para definição dos principais modelos lineares

Modelo	ϕ	ρ
Modelo estático com resíduos NID	0	0
Modelo estático com resíduos AR(1)	0	Livre
Modelo estático com resíduos em primeira diferença	0	1
Modelo dinâmico com resíduos NID	Livre	0
Modelo dinâmico com resíduos AR(1)	Livre	Livre
Modelo dinâmico com resíduos em primeira diferença	Livre	1

Elaboração dos autores.

A segunda extensão de MEE que será abordada neste trabalho é o seu uso na previsão contemporânea que ocorre quando a série-objetivo $y_t^{(1)}$, para $t = 1, \dots, m$ é observada com certo atraso, mas existem $(p - 1)$ indicadores relacionados que dispõem de informações mais atualizadas $y_t^{(i)}$, com $t = 1, \dots, m, \dots, n$ e $i = 2, \dots, p$. Sua principal característica é a existência de uma irregularidade no extremo do período amostral, $t = m + 1, \dots, n$, ocasionada pela falta de sincronia na disponibilização das observações. Esta irregularidade é traduzida para um problema de valores faltantes, já que as observações estão restritas aos indicadores relacionados, que pode ser tratado facilmente no arcabouço dos MEEs.

O mais comum nesta situação é que se adote um modelo multivariado, que sintetiza a dinâmica conjunta da variável-objetivo e dos indicadores relacionados. Para ilustrar, suponha-se o seguinte modelo bivariado ($p = 2$) que, por simplicidade, contém somente um componente de nível:

$$y_t = \begin{pmatrix} y_t^{(1)} \\ y_t^{(2)} \end{pmatrix}, \quad \alpha_t = \begin{pmatrix} \mu_t^{(1)} \\ \mu_t^{(2)} \end{pmatrix}, \quad Z_t = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, \quad T_t = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, \quad R_t = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, \quad \varepsilon_t = \begin{pmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \end{pmatrix},$$

$$\eta_t = \begin{pmatrix} \xi_t^{(1)} \\ \xi_t^{(2)} \end{pmatrix}$$

$$H_t = \begin{pmatrix} \sigma_{\varepsilon^{(1)}}^2 & \text{cov}(\varepsilon^{(1)}, \varepsilon^{(2)}) \\ \text{cov}(\varepsilon^{(1)}, \varepsilon^{(2)}) & \sigma_{\varepsilon^{(2)}}^2 \end{pmatrix} \text{ e } Q_t = \begin{pmatrix} \sigma_{\xi^{(1)}}^2 & \text{cov}(\xi^{(1)}, \xi^{(2)}) \\ \text{cov}(\xi^{(1)}, \xi^{(2)}) & \sigma_{\xi^{(2)}}^2 \end{pmatrix}$$

Nesse componente, o sobrescrito representa se o elemento está vinculado à primeira ou à segunda série observada em $\mathbf{y}_t$. Este modelo pode ser generalizado para considerar p variáveis no vetor de séries observadas $\mathbf{y}_t$ ou outros componentes estruturais (ciclos, sazonalidade etc.).

O que é importante a ser destacado nos modelos multivariados é que cada uma das séries é modelada da mesma maneira que no caso univariado, mas podem estar inter-relacionadas por meio das correlações dos distúrbios que dirigem seus componentes estruturais implícitas nas matrizes $\mathbf{H}_t$ e $\mathbf{Q}_t$. Se as séries não estão relacionadas (distúrbios independentes), o modelo multivariado terá o mesmo resultado se for estimado por modelos univariados independentes. No caso mais geral, os componentes estruturais estarão correlacionados (por exemplo, $(\xi^{(1)}, \xi^{(2)}) \neq 0$), e estes modelos são conhecidos na literatura como *seemingly unrelated time series equations* (SUTSE). Outro caso especial é o modelo de componente ou fator comum que ocorre quando os componentes são (quase) perfeitamente correlacionados. Haverá uma única fonte de movimentos estocásticos e o componente estrutural de uma determinada série pode ser modelado como uma combinação linear de outro.⁹

9. O modelo de componente ou fator comum é análogo à análise de fatores principais. Sua generalização no arcabouço de MEE são os modelos de fatores dinâmicos que reduzem um grande número de componentes estruturais a um número reduzido de fatores comuns, possibilitando a estimação de modelos com centenas de séries observadas para um período amostral relativamente curto. Estes modelos são usualmente utilizados na previsão contemporânea de séries complexas como o PIB porque permitem a inclusão dos mais variados indicadores relacionados e que podem estar em frequências mistas (mensal, trimestral etc.). Contudo, o foco da exposição será sobre o modelo bivariado, mais apropriado para a aplicação na previsão dos investimentos dos governos subnacionais que somente dispõem de um indicador relacionado de elevada correlação com a série objetivo. O que não implica deixar de reconhecer a existência de uma ampla literatura sobre indicadores coincidentes e previsão contemporânea, que pode ser consultada em Bánbura, Giannone e Reichlin (2010). Por sua vez, Harvey e Chung (2000) utilizam um modelo bivariado para um problema semelhante.

Voltando ao problema da previsão contemporânea, espera-se que o modelo bivariado com a série-objetivo $y_t^{(1)}, t = 1, \dots, m$ e um indicador relacionado $y_t^{(2)}$ com informações mais atualizadas, $t = 1, \dots, m, \dots, n$, apresente elevadas correlações nos distúrbios dos seus componentes e que as informações de $y_t^{(2)}$ gerem ganhos potenciais na previsão de $y_t^{(1)}$. O modelo é estimado normalmente, não havendo atualização do filtro de Kalman para os valores faltantes, e o objetivo é estimar os valores da série-objetivo $y_t^{(1)}$ no final do período amostral, $t = m + 1, \dots, n$, considerando a própria estrutura dinâmica da série e, adicionalmente, as informações contemporâneas do indicador relacionado $y_t^{(2)}$.

Em suma, os MEEs proveem um arcabouço flexível para análise de séries temporais, no qual os parâmetros podem ser tratados como processos estocásticos que consideram explicitamente as dependências temporais das séries, e uma metodologia unificada para tratar uma ampla gama de problemas de irregularidades nos dados. Estas características são particularmente apropriadas para aplicação nas séries das finanças públicas dos governos subnacionais no Brasil, nas quais são frequentes os problemas de valores faltantes, séries agregadas temporalmente e desatualizadas, frequências mistas e outras irregularidades nos dados, além das constantes mudanças nas estruturas das séries e valores aberrantes. Outro aspecto a ser destacado é a presença muito marcante de componentes estruturais nestas séries, como o padrão sazonal e os ciclos eleitorais característicos, que fazem com que o arcabouço do MEE se mostre um instrumento útil para estimação e para análise dos investimentos dos governos subnacionais no Brasil, que serão realizadas nas próximas seções.

3 FONTES DE DADOS

As informações dos investimentos nos governos subnacionais são provenientes de duas fontes básicas. A primeira são os Relatórios Resumidos de Execução Orçamentária (RREOs), que, segundo a legislação, devem ser elaborados bimestralmente pelos governos dos três entes federados e disponibilizados em meios de amplo acesso público (no caso, o sítio da Secretaria do Tesouro Nacional). Contudo, existem sérias limitações quando se deseja estimar a formação bruta de capital fixo (FBCF) a partir das informações destes relatórios. Primeiramente, as informações de investimentos nos relatórios são apenas relacionadas e não inteiramente compatíveis com o conceito de FBCF das contas

nacionais.¹⁰ Em segundo lugar, as informações dos RREOs apresentam problemas não triviais de cobertura incompleta, irregularidade e inconsistência. Os relatórios proveem informações extremamente úteis, mas permitem no máximo construir indicadores relacionados da FBCF dos governos estaduais e de uma amostra dos governos municipais.

As demais informações foram fornecidas pela Coordenação de Finanças Públicas (CFP) do Ipea e advêm de uma pesquisa própria para estimar a FBCF dos governos subnacionais a partir de informações prestadas diretamente pelos contadores públicos, técnicos ou secretários de fazenda/planejamento estaduais e municipais.¹¹ As séries disponibilizadas compreendem informações anuais da FBCF das 27 Unidades da Federação (26 estados e o Distrito Federal, doravante UFs) e informações mensais da FBCF de uma amostra de 16 UFs e de municípios de grande porte, correspondentes a aproximadamente 74% da FBCF do governo estadual e 20% do governo municipal, respectivamente. Também foram disponibilizados valores bimestrais do agregado da FBCF do governo municipal obtidos por meio da metodologia apresentada em Orair *et al.* (2011).¹²

As séries da FBCF e indicadores relacionados que serão utilizados neste trabalho estão listados no quadro 2. O quadro também ilustra algumas das características mais comuns das séries de finanças públicas dos governos subnacionais: cobertura incompleta, valores faltantes, período irregular e frequência mista (mensal, bimestral ou anual). Sobre esta última característica, deve-se destacar que os relatórios orçamentários, que constituem a principal fonte oficial de informações das finanças públicas subnacionais em alta frequência, são divulgados com informações referentes aos bimestres, dificultando-se a pesquisa aplicada quando as demais séries são normalmente mensais ou trimestrais. Destaca-se ainda que a divulgação ocorre por meio de arquivos não estruturados

10. Os padrões contábeis que subsidiam os demonstrativos fiscais no Brasil atualmente não se encontram harmonizados com os demais sistemas estatísticos macroeconômicos. As principais causas das diferenças decorrem de: *i*) informações agregadas que não diferenciam as transferências de capital da FBCF propriamente dita; *ii*) foco sobre a execução orçamentária do exercício, seguindo o princípio estrito da anualidade, e negligenciando as execuções dos orçamentos de restos a pagar de exercícios anteriores; e *iii*) viés em prol da escrituração de fatos contábeis que apenas potencialmente irão afetar o patrimônio da entidade. Ver Gobetti (2007) e Santos *et al.* (2011) para uma discussão mais pormenorizada.

11. Ver Santos *et al.* (2011).

12. A metodologia de Orair *et al.* (2011) se baseia em dois procedimentos: *i*) complementação das informações do banco de dados anual FINBRA por imputação de valores faltantes de acordo com o comportamento da variável em grupos homogêneos de municípios em termos de nível de renda, tamanho e localização geográfica; e *ii*) desagregação temporal para a frequência bimestral fazendo-se uso de indicadores de 326 municípios selecionados por amostragem aleatória estratificada.

(em formato PDF) de cada bimestre das 27 UFs e 5.564 municípios do país. O uso das informações de literalmente dezenas de milhares de arquivos exigiu o desenvolvimento de rotinas computacionais para sua obtenção e conversão automática para formatos estruturados. Somente foi viável operacionalizar estas rotinas para o período desde 2006, após uma mudança no Sistema de Coleta de Dados Contábeis dos Entes da Federação (SISTN) e, por este motivo, o indicador dos investimentos dos 2.120 municípios com informações disponíveis cobre o período 2006-2011.¹³ Entretanto, foi possível complementar a série do indicador relacionado na esfera estadual para o período 2002-2005, obtendo-se individualmente as informações das 27 UFs.

QUADRO 2

Séries e indicadores relacionados da FBCF dos governos subnacionais

Conceito	Esfera	Frequência	Período	Cobertura
Indicador relacionado	Estadual	Bimestral	2002-2011	27 UFs
Indicador relacionado	Municipal	Bimestral	2006-2011	2.120 municípios com informações disponíveis nos RREOs
FBCF	Estadual	Mensal	2002-2010	16 UFs: Bahia, Ceará, Distrito Federal, Espírito Santo, Goiás, Maranhão, Mato Grosso, Mato Grosso do Sul, Pará, Pernambuco, Rio de Janeiro, Rondônia, Rio Grande do Sul, Santa Catarina, São Paulo e Tocantins
FBCF	Estadual	Anual	2002-2010	27 UFs
FBCF	Municipal	Mensal	2002-2010	Municípios de grande porte com informações de boa qualidade disponíveis: Rio de Janeiro/RJ, Salvador/BA, Florianópolis/SC, Belo Horizonte/MG, São Paulo/SP, Ananindeua/PA, Arapiraca/AL, Atibaia/SP, Blumenau/SC, Balneário Camboriú/SC, Boa Vista/RR, Campo Bom/RS, Corumbá/MS, Contagem/MG, Curitiba/PR, Cuiabá/MT, Itabira/MG, Juiz de Fora/MG, Lavras/MG, Maracanaú/CE, Porto Velho/RO, Porto Alegre/RS, Recife/PE, Santa Maria/RS, São Sebastião/SP, São José dos Pinhais/PR, São José do Rio Preto/SP, Serra/ES e Três Lagoas/MS
FBCF	Municipal	Bimestral	2002-2010	Série agregada estimada pela metodologia de Orais et al. (2011)

Elaboração dos autores.

4 DESAGREGAÇÃO TEMPORAL DOS INVESTIMENTOS DOS GOVERNOS SUBNACIONAIS

A técnica da desagregação temporal será utilizada neste trabalho para estimar séries mensais da FBCF dos governos subnacionais a partir da metodologia apresentada na seção 2 e dos indicadores da seção 3. Estes últimos correspondem a séries com conceitos relacionados (mas não inteiramente compatíveis à FBCF) e/ou informações das amostras de UFs e municípios. A desagregação temporal com indicadores construídos

13. Os relatórios estão disponíveis em: <http://www.tesouro.fazenda.gov.br/estados_municipios/sistn.asp>.

das informações de uma amostra tem sido um recurso comum em estudos das finanças públicas subnacionais, a exemplo dos trabalhos de Dias, Issler e Rodrigues (2010) e Orais *et al.* (2011) que estimaram séries agregadas da arrecadação dos principais tributos municipais no Brasil.¹⁴

No governo estadual, o objetivo é desagregar temporalmente a série anual da FBCF de onze UFs a partir de: *i*) indicador bimestral dos investimentos destas mesmas UFs; e *ii*) indicador mensal com a FBCF das demais quinze UFs (excluindo-se São Paulo).¹⁵ Foi realizado um pré-teste com intuito de selecionar, entre as diversas alternativas disponíveis, aqueles procedimentos que mais se adequam aos dados das finanças públicas subnacionais. O resultado está apresentado no anexo B e indicou que o melhor ajuste foi obtido pela desagregação temporal em duas etapas com o modelo estático de resíduos autorregressivos.

A desagregação temporal da FBCF das onze UFs tomou como base estes procedimentos, descritos com mais detalhes no anexo A, e os resultados podem ser visualizados no gráfico 1, juntamente com seus indicadores relacionados. Verifica-se que a dinâmica de curto prazo da série estimada seguiu de maneira muito mais próxima o comportamento do indicador relacionado aos investimentos destas mesmas onze UFs do que o indicador dos investimentos das demais UFs. A série mensal da FBCF do governo estadual, que será analisada na próxima seção, corresponde à soma desta série desagregada temporalmente das onze UFs com as séries mensais disponíveis para as demais UFs.

A desagregação temporal também foi utilizada para construir séries mensais da FBCF do governo municipal, tomando-se como indicador a série mensal da amostra de municípios de grande porte e seguindo a mesma estrutura de modelo adotada para os estados. A principal diferença é que a série bimestral da FBCF dos municípios já estava disponível, estimada através da metodologia de Orais *et al.* (2011), e o objetivo

14. Os métodos de estimação nestes trabalhos são distintos. No trabalho de Orais *et al.* (2011) são utilizados métodos de agrupamentos (*cluster*) e de amostragem aleatória estratificada para formar índices mensais de evolução da arrecadação por grupos homogêneos de municípios e, em seguida, a desagregação temporal é realizada pela evolução destes índices aos agregados de cada grupo homogêneo. Dias, Issler e Rodrigues (2010) realizaram a desagregação temporal por MEE em duas etapas: *i*) para frequência bimestral utilizando como covariável a arrecadação bimestral de uma amostra de municípios, não havendo referências sobre a composição da amostra; e *ii*) para frequência mensal a partir de indicadores como, por exemplo, as operações privadas de crédito e índices de preços da habitação para estimar a arrecadação mensal do IPTU.


15. Optou-se por excluir o estado de São Paulo do indicador devido a seu elevado peso na amostra (cerca de 20% do total da FBCF nos governos estaduais) e sua evolução temporal atípica caracterizada por picos elevados que poderiam enviesar o processo de estimação.

foi desagregá-la para a frequência mensal em uma única etapa. O gráfico 2 mostra a série mensal desagregada da FBCF do governo municipal e o seu indicador relacionado.

GRÁFICO 1

Série mensal desagregada temporalmente e indicadores da FBCF dos governos estaduais

(Em R\$ milhões)




Elaboração dos autores.

GRÁFICO 2

Série mensal desagregada temporalmente e indicador da FBCF do governo municipal

(Em R\$ milhões)



Elaboração dos autores.

5 COMPONENTES ESTRUTURAIS DA FBCF DOS GOVERNOS SUBNACIONAIS

Esta seção apresenta as séries estimadas da FBCF dos governos subnacionais e ajusta um modelo estrutural básico que decompõe seus componentes (tendência, ciclos e sazonalidade), permitindo-se uma descrição mais adequada do desenvolvimento subjacente da série temporal e facilitando a identificação dos seus fatos estilizados. A frequência das séries é mensal e o período amostral cobre os anos de 2002 a 2010, que totalizam 108 observações. As séries foram convertidas para reais de dezembro de 2011 pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA) e os modelos ajustados para os logaritmos dos valores em nível. As séries da FBCF dos governos subnacionais e seus componentes estruturais podem ser vistos nos gráficos 3 e 4.

Os parâmetros estimados e as estatísticas de teste dos modelos ajustados para a série da FBCF do governo estadual estão apresentados na tabela 1. O modelo inicial contém um único componente cíclico e está indicado na tabela como GE1. Os testes de diagnóstico do modelo mostraram indícios de não normalidade dos resíduos

e a detecção de um provável valor aberrante em janeiro de 2010. Foi estimado um segundo modelo GE2 com uma variável de intervenção que mostrou diagnósticos mais adequados. Com intuito de assegurar maior robustez aos resultados, os modelos GE3 e GE4 permitiram a presença de dois componentes cíclicos e apresentaram resultados semelhantes aos anteriores. O diagnóstico do modelo GE3 sugeriu não normalidade, além do mesmo valor aberrante identificado anteriormente, e o modelo GE4 foi estimado contendo uma variável de intervenção e forneceu resultados mais apropriados, apesar das evidências de certo grau de correlação serial e não normalidade dos resíduos.

Os parâmetros relacionados ao nível da tendência e à sazonalidade se mostraram determinísticos em todas as especificações. Os demais parâmetros são estocásticos, ainda que as variâncias relacionadas aos componentes cíclicos e à inclinação da tendência tenham se mostrado bastante reduzidas. Por isto, a estimação resultou em componentes de sazonalidade e ciclos muito regulares e um componente tendencial suave para a evolução da FBCF do governo estadual, como se pode observar no gráfico 3.

O componente tendencial no gráfico 3 sugere relativa estagnação dos investimentos do governo estadual no início do período e inflexão para uma tendência de expansão após 2005, que pode estar relacionada ao ciclo de flexibilização da política fiscal identificado por Schettini *et al.* (2011). O componente sazonal indica um padrão regular da execução orçamentária do investimento ao longo do ano, que inicia em patamares baixos e se acelera progressivamente, com forte concentração dos investimentos públicos nos últimos meses do ano e, sobretudo, no mês de dezembro. Este padrão sazonal reflete a própria lógica de execução orçamentária, segundo a qual as despesas discricionárias do ano-exercício (que coincide com o ano-calendário) tendem a ser efetivadas com certa defasagem em relação à arrecadação, e os cronogramas de liberação de limites da execução orçamentária pelos órgãos de planejamento são flexibilizados somente no final do ano.

Os resultados que mais chamam atenção na tabela 1 e no gráfico 3 estão relacionados à dinâmica dos componentes cíclicos que coincide com os ciclos eleitorais. Os modelos GE2 e GE4, que apresentaram diagnósticos mais apropriados, estimaram um ciclo aproximadamente bienal (período de 1,97 e 1,99 anos, respectivamente) que alcança o patamar mais elevado nos períodos imediatamente anteriores às eleições (segundo e terceiros trimestres dos anos pares). No período pós-eleitoral há uma desaceleração na execução dos investimentos até atingir o nível mais baixo em meados do ano seguinte, quando inicia novo período ascendente. O modelo GE4 também encontrou

evidências de um ciclo aproximadamente quadrienal (periodicidade estimada de 3,96 anos). O auge do ciclo coincide com o período das eleições de governadores (terceiros trimestres de 2002, 2006 e 2010) e a fase descendente persiste durante todo o primeiro ano de mandato do governo eleito, até ocorrer reversão cíclica ao final do segundo ano (terceiros trimestres de 2003 e 2007). O componente cíclico sugere, portanto, que a execução dos investimentos está sujeita às influências superpostas dos ciclos eleitorais dos governos estaduais (e até mesmo do governo federal) e dos governos municipais que resultam numa periodicidade bienal. Por outro lado, as evidências de um componente cíclico adicional de período quadrienal e de maior amplitude sugere que a relação com as eleições nos governos estaduais (e no governo federal) será mais pronunciada.

Os resultados dos modelos ajustados para a FBCF do governo municipal estão apresentados na tabela 2 e no gráfico 4 e foram obtidos a partir de uma estratégia semelhante à utilizada no governo estadual. Os modelos GM1 e GM3 foram estimados com um e dois componentes cíclicos, respectivamente, e apresentaram fortes evidências de não normalidade dos resíduos que podem ser atribuídas ao grande número de prováveis valores aberrantes e quebras estruturais. Isto pode ser parcialmente explicado pela menor qualidade da série estimada da FBCF do governo municipal, que está muito mais sujeita a problemas de incompletude e inconsistência das informações. Os modelos GM2 contendo um componente cíclico e GM4 com dois ciclos foram estimados incluindo variáveis de intervenção que possibilitaram melhor ajuste. Os parâmetros de todos os modelos se mostraram estocásticos, excetuando-se os parâmetros da inclinação da tendência que são determinísticos.

Os componentes estimados para a FBCF do governo municipal apresentaram resultados próximos aos obtidos no governo estadual, como se pode observar nos gráficos 3 e 4. A tendência da FBCF do governo municipal se mostrou mais irregular, mas também indicou inflexão após 2005. O período 2002-2005 foi caracterizado por relativo declínio dos investimentos e a segunda metade da década por sua retomada, apesar de indícios de relativa estabilidade no período mais recente. A sazonalidade mostrou o mesmo padrão regular de aceleração da execução orçamentária do investimento ao longo do ano, mas com amplitude crescente no decorrer dos anos e menor do que nos governos estaduais. Por fim, os modelos estimaram um ciclo aproximadamente bienal (2,04 anos e 2,08 anos nos modelos GM2 e GM4) com trajetória e amplitude bastante semelhantes aos dos governos estaduais.


Os resultados empíricos proveem evidências adicionais sobre a existência de ciclos políticos eleitorais nos governos subnacionais. A principal distinção é que no governo estadual foi encontrado um componente quadrienal, além do componente bienal, que

amplifica o caráter cíclico dos investimentos a cada quatro anos e sugere uma maior influência das eleições de governadores (e de presidente). Para o governo municipal não foram encontradas evidências deste componente diferencial e os resultados sugerem influências superpostas e de magnitudes semelhantes das eleições para as prefeituras (2004 e 2008) e de governadores e presidenciais (2002, 2006 e 2010) por meio de um componente bienal. O modelo GM4, que apresentou melhor ajuste entre os modelos com dois componentes cíclicos na tabela 2, estimou um ciclo de 5,33 anos que parece estar captando muito mais as oscilações na tendência – declínio dos investimentos nos anos 2002-2005 e inflexão do período 2005-2008 – do que um ciclo propriamente dito.

GRÁFICO 3

FBCF do governo estadual: logaritmo da série observada (LGE) e componentes estruturais de tendência, sazonalidade, ciclos e irregular

(Em R\$ milhões – dez. 2011)




Fonte: resultados do modelo GE4 apresentado na tabela 1.
Elaboração dos autores.

GRÁFICO 4

FBCF do governo municipal: logaritmo da série observada (LGM) e componentes estruturais de tendência, sazonalidade, ciclo e irregular

(Em R\$ milhões de dez. 2011)



Fonte: resultados do modelo GM2 apresentado na tabela 2.
Elaboração dos autores.

TABELA 1

Parâmetros e estatísticas de diagnóstico e ajuste dos modelos da FBCF do governo estadual (GE)

	Modelo	GE1	GE2	GE3	GE4
Parâmetros estimados	Nível	7.99941 [0.00000] ²	7.93944 [0.00000] ²	8.00347 [0.00000] ²	8.01572 [0.00000] ²
	Inclinação	0.01416 [0.14706] (0.00000444057)	-0.02691 [0.27603] (0.000120726)	0.01477 [0.01191] (2.22195e - 006)	0.01421 [0.02515] ¹ (2.67337e - 006)
	Irregular	(0.0137407)	(0.0129465)	(0.0167988)	(0.0134522)
	Sazonalidade				
	Janeiro	-1.00838 [0.00000] ²	-0.94778 [0.00000] ²	-0.99884 [0.00000] ²	-0.94352 [0.00000] ²
	Fevereiro	-0.51421 [0.00000] ²	-0.51803 [0.00000] ²	-0.50804 [0.00000] ²	-0.51561 [0.00000] ²
	Março	-0.08861 [0.04158] ¹	-0.09383 [0.01282] ¹	-0.08561 [0.04175] ¹	-0.09271 [0.01472]
	Abril	-0.20898 [0.00000] ²	-0.21555 [0.00000] ²	-0.20877 [0.00000] ²	-0.21533 [0.00000] ²
	Maiο	-0.04158 [0.33284]	-0.04922 [0.18517]	-0.04358 [0.29515]	-0.04955 [0.18629]
	Junho	-0.01657 [0.69875]	-0.02485 [0.50197]	-0.02011 [0.62815]	-0.02547 [0.49531]
	Julho	0.07217 [0.09418]	0.06383 [0.08666]	0.06785 [0.10444]	0.06309 [0.09322]
	Agosto	0.15490 [0.00046] ²	0.14713 [0.00013] ²	0.15056 [0.00045] ²	0.14633 [0.00016] ²

(Continua)

(Continuação)

	Modelo	GE1	GE2	GE3	GE4
	Setembro	0.18077 [0.00005] ²	0.17424 [0.00001] ²	0.17714 [0.00005] ²	0.17335 [0.00001] ²
	Outubro	0.16173 [0.00028] ²	0.15705 [0.00005] ²	0.15943 [0.00022] ²	0.15598 [0.00007] ²
	Novembro	0.26368 [0.00000] ²	0.26140 [0.00000] ²	0.26321 [0.00000] ²	0.25994 [0.00000] ²
	Dezembro	1.04507 [0.00000] ²	1.04560 [0.00000] ²	1.04676 [0.00000] ²	1.04350 [0.00000] ²
	Variáveis de intervenção – impulso		-0.56889 [0.00003] ² 2010(1)		-0.56949 [0.00003] ² 2010(1)
Parâmetros estimados	Ciclo				
	Variância dos distúrbios	0,00311549	3,41229E-10	6.55168e - 011	4.74984e - 005
	Variância do ciclo	0,03883	0,00811	0,00834	0,00886
	Período	43,53988	23,66371	24,2478	23,82997
	Período em anos	3,62832	1,97198	2,0207	1,98583
	Frequência	0,14431	0,26552	0,25912	0,26367
	Fator de amortecimento	0,95904	1,00000	1,0000	0,99731
Estatísticas de diagnóstico e ajuste	Ciclo 2				
	Variância dos distúrbios			3.98059e - 008	1,02471E-10
	Variância do ciclo			0,01990	0,02181
	Período			47,1227	47,53443
	Período em anos			3,9269	3,9612
	Frequência			0,13334	0,13218
	Fator de amortecimento			1,0000	1,00000
	Desvio padrão	0,14863	0,13255	0,13146	0,12234
	Teste de normalidade	9.6995 [0.0078] ²	5.0863 [0.0786]	9.8785 [0.0017] ²	6.7239 [0.0347] ²
	Teste de significância do efeito sazonal	1261.91439 [0.00000] ²	1475.12103 [0.00000] ²	1318.17678 [0.00000] ²	1473.00802 [0.00000] ²
	Teste para homoscedasticidade	1.7132 [0.1394]	1.01233 [0.9730]	1.6305 [0.1792]	1.02683 [0.9418]
	Coefficiente de determinação	0,69495	0,75992	0,76135	0,7955
	Critério de informação				
	Akaike (AIC)	-3,5534	-3,7637	-3,7989	-3,9242
	Bayesiano/Schwartz (BIC)	-3,2057	-3,3912	-3,4512	-3,5517
	Teste de correlação serial				
	Até 6 defasagens	2.2032 [0.3323]	1.3524 [0.5085]	2.0337 [0.1538]	1.5609 [0.2115]
	Até 12 defasagens	13.739 [0.0888]	11.717 [0.1643]	17.141 [0.0165] ¹	18.077 [0.0116] ¹
	Até 24 defasagens	17.92 [0.5927]	27.458 [0.1229]	24.849 [0.1656]	32.502 [0.0274] ¹
	Até 36 defasagens	23.692 [0.8553]	33.951 [0.3737]	32.54 [0.3909]	41.523 [0.0982]
	Teste para variável de intervenção	-3.90294 [0.00008]		-3.80276 [0.00012] ²	
	Componente irregular	2010(1)		2010(1)	

Elaboração dos autores.

Notas: ¹ Valores significativos ao nível de 5%.

² Valores significativos ao nível de 1%.

Obs.: os valores entre parênteses são estimativas das variâncias, e os valores entre colchetes são níveis de significância dos testes. Os valores dos parâmetros correspondem ao vetor de estado do período final. Detalhes sobre os testes de normalidade (estatística de Bowman-Shenton), homoscedasticidade e correlação serial dos resíduos (estatística de Box-Ljung) e dos testes para detecção de variáveis de intervenção podem ser vistos em Durbin e Koopman (2001, p. 33-35).

TABELA 2
Parâmetros e estatísticas de diagnóstico e ajuste dos modelos da FBCF do governo municipal (GM)

Modelo	GM1	GM2	GM3	GM4
Nível	7.97057 [0.00000] ² (0.00101567)	7.93868 [0.00000] ² (0.00448982)	7.92089 [0.00000] ² (0.00277507)	8.05888 [0.00000] ² (0.000804768)
Inclinação	0.00524 [0.15130]	0.00479 [0.46650]	0.00497 [0.34058]	0.00649 [0.03844] ¹
Irregular	(0.0000981871)	(0.00166771)	(0.0129465)	(0.00129515)
Sazonalidade	(0.0000336679)	(0.0000308724)	(0.0000583654)	(0.0000297752)
Janeiro	-0.36559 [0.00002] ²	-0.39927 [0.00000] ²	-0.42536 [0.00001] ²	-0.39123 [0.00000] ²
Fevereiro	-0.81025 [0.00000] ²	-0.72723 [0.00000] ²	-0.86152 [0.00000] ²	-0.72775 [0.00000] ²
Março	-0.12075 [0.13576]	-0.12817 [0.05291]	-0.14146 [0.09593]	-0.12402 [0.06734]
Abril	-0.11923 [0.13428]	-0.12346 [0.05655]	-0.11176 [0.17631]	-0.12254 [0.06510]
Mai	-0.00502 [0.94861]	-0.01721 [0.78367]	0.00361 [0.96402]	-0.01802 [0.77992]
Junho	-0.03159 [0.67997]	-0.04745 [0.43890]	-0.01318 [0.86601]	-0.05174 [0.41280]
Julho	0.15775 [0.03810] ¹	0.17084 [0.00506] ²	0.2052 [0.00791] ²	0.16510 [0.00856] ²
Agosto	0.17629 [0.01892] ¹	0.19645 [0.00105] ²	0.22598 [0.00278] ²	0.19021 [0.00210] ²
Setembro	0.11620 [0.11239]	0.12055 [0.03555] ¹	0.12946 [0.07234]	0.11758 [0.04784] ¹
Outubro	0.09620 [0.18177]	0.08460 [0.13063]	0.08658 [0.21578]	0.08653 [0.13659]
Novembro	0.44217 [0.00000] ²	0.42059 [0.00000] ²	0.42508 [0.00000] ²	0.42450 [0.00000] ²
Dezembro	0.46381 [0.00000] ²	0.44975 [0.00000] ²	0.47736 [0.00000] ²	0.45138 [0.00000] ²
Parâmetros estimados		0.4402 [0.00000] ² 2004(1)		0.4405 [0.00000] ² 2004(1)
	Variáveis de intervenção – impulso	-0.45971 [0.00000] ² 2005(2)		-0.44415 [0.00000] ² 2005(2)
		-0.44004 [0.00000] ² 2009(2)		-0.41641 [0.00001] ² 2009(2)
Ciclo				
Variância dos distúrbios	0,0132378	1,94E-08	3,26128E-05	0,00361137
Variância do ciclo	0,03890	0,00970	0,00232	0,01850
Período	97,90670	24,48140	7,91743	24,96442
Período em anos	8,15889	2,04012	0,65979	2,08037
Frequência	0,06418	0,25665	0,79359	0,25169
Fator de amortecimento	0,81220	1,00000	0,99294	0,89712
Ciclo 2				
Variância dos distúrbios			3,57012E-10	2,98911E-10
Variância do ciclo			0,00561	0,00864
Período			24,30144	63,99537
Período em anos			2,02512	5,33295
Frequência			0,25855	0,09818
Fator de amortecimento			1,00000	1,00000

(Continua)

(Continuação)

Modelo	GM1	GM2	GM3	GM4
Desvio padrão	0,14725	0,11062	0,13733	0,11191
Teste de normalidade	11.703 [0.0029] ²	4.4415 [0.1085]	11.676 [0.0029] ²	6.4477 [0.0398] ¹
Teste de significância do efeito sazonal	168.40183 [0.00000] ²	224.89665 [0.00000] ²	182.9727 [0.00000] ²	215.22741 [0.00000] ²
Teste para homoscedasticidade	1.79678 [0.1080]	1.17643 [0.6538]	1.99045 [0.0598]	1.15077 [0.6982]
Coefficiente de determinação	0,2835	0,60842	0,37682	0,59925
Critério de informação				
Akaike (AIC)	-3,5719	-4,0885	-3,7115	-4,0654
Bayesiano/Schwartz (BIC)	-3,2243	-3,6663	-3,3638	-3,6432
Teste de correlação serial				
Até 6 defasagens	5.8539 [0.0536]	5.1015 [0.0780]	6.4545 [0.0397] ¹	2.193 [0.1386]
Até 12 defasagens	13.084 [0.1090]	10.777 [0.2146]	13.172 [0.0680]	8.2832 [0.3083]
Até 24 defasagens	39.756 [0.0054] ²	28.512 [0.0978]	23.539 [0.2145]	25.642 [0.1405]
Até 36 defasagens	55.558 [0.0061] ²	37.336 [0.2372]	40.599 [0.1161]	32.783 [0.3795]
Teste para variável de intervenção				
Componente irregular	-3.03879 [0.00149] ² 2002(1)		3.40466 [0.00047] ² 2004(1)	
Componente irregular	3.22263 [0.00084] ² 2002(2)		-3.51116 [0.00033] ² , 2005(2)	
Componente irregular	3.36917 [0.00052] ² 2004(1)		-3.40849 [0.00046] ² 2009(2)	
Componente irregular	-3.21625 [0.00086] ² 2005(2)			
Componente irregular	-3.32988 [0.00059] ² 2009(2)			
Elemento de nível	3.03879 [0.00149] ² 2002(2)			
Elemento de inclinação	-3.03879 [0.00149] ² 2002(2)			

Estadísticas de diagnóstico e ajuste

Elaboração dos autores.

Notas: ¹ Valores significativos ao nível de 5%.

² Valores significativos ao nível de 1%.

Obs.: os valores entre parênteses são estimativas das variâncias e os valores entre colchetes são níveis de significância dos testes. Os valores dos parâmetros correspondem ao vetor de estado do período final. Detalhes sobre os testes de normalidade (estatística de Bowman-Shenton), homoscedasticidade e correlação serial dos resíduos (estatística de Box-Ljung) e dos testes para detecção de variáveis de intervenção podem ser vistos em Durbin e Koopman (2001, p. 33-35).

6 PREVISÃO CONTEMPORÂNEA

As séries da FBCF dos governos subnacionais estimadas e analisadas nas duas seções anteriores estão restritas ao período com informações anuais de referência (2002-2010), mas pode-se dispor de indicadores relacionados dos investimentos das 27 UFs no período 2002-2011 e de uma amostra com 2.120 municípios no período 2006-2011. É possível, assim, utilizar um modelo estrutural bivariado bastante simples, que

considera a estrutura dinâmica da própria série-objetivo e as informações mais atualizadas do indicador relacionado para realizar a previsão contemporânea da FBCF dos governos subnacionais para o ano de 2011.¹⁶ O modelo foi ajustado separadamente para o logaritmo dos valores nominais das séries de cada esfera de governo e contendo componentes estruturais de tendência e sazonalidade. Considera-se o período 2002-2011, que totaliza 120 meses, sendo que as séries-objetivo da FBCF do governo estadual e do governo municipal apresentam doze valores faltantes referentes ao ano de 2011 e o indicador dos investimentos municipais contém 48 valores faltantes no início do período (2002-2005).

Os resultados estão apresentados no anexo B e os componentes estruturais dos modelos bivariados podem ser visualizados nos gráficos 5 e 6. Conforme esperado, as séries-objetivo guardam forte correlação com os seus indicadores, como se pode concluir a partir da análise dos gráficos 5 e 6 e dos valores dos coeficientes de correlação apresentados no anexo, que indicam correlação quase perfeita nos distúrbios das equações de observação e elevado grau de correlação das inovações nos dois modelos. Estes modelos foram então utilizados para previsão contemporânea das séries-objetivo no ano 2011 por imputação dos valores faltantes, cujas estimativas e respectivas variâncias estão no anexo.

Estas estimativas também estão presentes no gráfico 7, que mostra os valores anualizados da FBCF do governo estadual e do governo municipal no período 2002-2011, incluindo-se tanto as estimativas mensais desagregadas temporalmente quanto as previsões contemporâneas no último ano. As estimativas indicam uma queda real de 26% nos investimentos estaduais entre 2010 e 2011 (R\$ 43,6 para R\$ 32,4 bilhões) e um crescimento de 12% nos investimentos municipais no mesmo período (R\$ 37,1 para R\$ 41,5 bilhões). Deve-se reconhecer que uma parcela considerável da queda dos investimentos estaduais era esperada em função do ciclo eleitoral abordado na seção anterior. A expansão dos investimentos municipais, por sua vez, parece estar fortemente


16. O indicador relacionado considerou a média mensal no bimestre para seus respectivos meses, uma vez que as informações disponíveis são referentes a valores acumulados em cada bimestre. Além disto, optou-se por excluir os investimentos do Rio de Janeiro tanto da série-objetivo quanto do indicador relacionado do governo municipal devido à presença de valores muito elevados em 2010 e 2011 que poderiam distorcer a previsão. Para exemplificar, as execuções de investimentos do orçamento do exercício saíram de uma média de R\$ 0,6 bilhão no período 2006-2009 para R\$ 1,4 bilhão em 2010 e novamente mais que dobram para R\$ 3,1 bilhões em 2011. Tal incremento atípico parece ser explicado por obras de infraestrutura de transportes e/ou relacionadas aos grandes eventos esportivos. A previsão contemporânea utilizou o indicador dos demais municípios que representam cerca de 50% do total da FBCF dos municípios e, posteriormente, os montantes investidos pelo município do Rio de Janeiro foram somados para formar a série final.

influenciada por grandes obras de infraestrutura de transportes e de urbanização, principalmente nas maiores cidades do país e que serão sedes dos grandes eventos esportivos (destacando-se o município do Rio de Janeiro). Sem entrar em grandes detalhes, o que deve ser destacado aqui é que a metodologia empregada pode contribuir para análises conjunturais e de monitoramento da política fiscal no período contemporâneo, uma vez que as séries anuais de referência nos governos subnacionais são disponibilizadas com quase um ano de defasagem.

GRÁFICO 5

Previsão contemporânea da FBCF do governo estadual: logaritmo da série-objetivo (LGE) e do indicador relacionado (indicador LGE) e componentes estruturais de tendência, sazonalidade e irregular

(Em R\$ milhões)




Fonte: resultados do modelo apresentado no anexo A.
Elaboração dos autores.

GRÁFICO 6

Previsão contemporânea da FBCF do governo municipal: logaritmo da série-objetivo (LGM) e do indicador relacionado (indicador LGM) e componentes estruturais de tendência, sazonalidade e irregular

(Em R\$ milhões)




Fonte: resultados do modelo apresentado no anexo A.
Elaboração dos autores.

GRÁFICO 7

FBCF do governo estadual e do governo municipal

(Em R\$ bilhões dez. – 2011, inflacionados pelo IPCA)



Elaboração dos autores.

7 CONSIDERAÇÕES FINAIS

A carência de séries agregadas de alta frequência e os problemas não triviais que devem ser enfrentados para estimação destas séries (conceitos não harmonizados aos demais sistemas estatísticos macroeconômicos, graus de abertura e de cobertura inadequados, inconsistência e irregularidade das informações etc.) criam obstáculos à pesquisa aplicada nas finanças públicas subnacionais. Os MEEs fornecem um arcabouço para lidar com uma ampla gama destes problemas, e as técnicas que derivam desta abordagem, como a desagregação temporal e a previsão contemporânea, foram utilizadas neste trabalho para estimar as séries mensais dos investimentos dos governos subnacionais. Tais resultados não excluem, entretanto, a necessidade de se compararem as *performances* dos MEEs em relação às alternativas disponíveis para lidar com os mesmos problemas. Esta será, sem dúvida, uma importante frente de avanços futuros do trabalho, além da sua generalização para aplicação em outras séries relevantes.

O arcabouço de MEE também provê um instrumento analítico para descrição do desenvolvimento de uma série temporal que se mostrou particularmente útil na análise dos investimentos dos governos subnacionais. Os resultados encontrados para

os governos estadual e municipal se assemelharam bastante, apesar das maiores irregularidades nas séries das finanças municipais, indicando uma inflexão na tendência dos investimentos após 2005, um padrão sazonal que concentra a execução dos investimentos nos últimos meses do ano e a existência de componentes cíclicos com trajetórias que coincidem com os ciclos eleitorais. A principal diferença nos resultados é que os investimentos no governo estadual parecem estar mais sujeitos às influências das eleições de governadores (e de presidente), por meio de um componente quadrienal, além do componente bienal, que amplifica o caráter cíclico dos investimentos a cada quatro anos. No governo municipal, foram encontradas evidências somente de um componente bienal, e os resultados sugerem influências superpostas e de magnitudes semelhantes das eleições municipais e de governadores.

As evidências de ciclos eleitorais nos investimentos públicos subnacionais foram encontradas por várias especificações econométricas e são bastante robustas. Estes resultados são interessantes, porque fornecem evidências empíricas inéditas que contribuem para a literatura sobre as relações entre ciclos políticos e variáveis macroeconômicas no Brasil. Até onde se tem conhecimento, os trabalhos aplicados que exploram a influência dos ciclos eleitorais sobre as despesas públicas subnacionais estavam restritos às análises de regressão por dados de painel com séries anuais e variáveis categóricas para os anos eleitorais, a exemplo de Cossio (2002) e Sakurai (2007). A principal vantagem do MEE aplicado às séries agregadas em alta frequência é que permite separar a influência do componente tendencial e estimar a trajetória cíclica com maior precisão. Por outro lado, as séries agregadas das finanças públicas subnacionais dificultam a análise de efeitos específicos nas unidades. De qualquer maneira, esta abordagem por MEE abre novas perspectivas para extensões futuras que permitam análises mais minuciosas dos componentes estruturais e dos determinantes dos investimentos públicos, por exemplo, ampliando-a para o governo federal e incluindo variáveis explicativas ou modelos multivariados.

REFERÊNCIAS

BÁNBURA, M.; GIANNONE, D.; REICHLIN, L. **Nowcasting**. Frankfurt am Main: European Central Bank, 2010. (Working Paper, n. 1275). Disponível em: <<http://www.ecb.int/pub/pdf/scpwps/ecbwp1275.pdf>>.

COMMANDEUR, J. J. F.; KOOPMAN, S. J. **An introduction to state space time series analysis**. New York: Oxford University Press, 2007.

COSSIO, F. A. B. **Ensaio sobre federalismo fiscal no Brasil**. Tese (Doutorado em Economia) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2002.

DIAS, V. P.; ISSLER, J. V.; RODRIGUES, C. Interpolação de variáveis fiscais brasileiras usando representação de espaço de estados. *In*: ENCONTRO BRASILEIRO DE ECONOMETRIA, 38., Salvador, dez. 2010.

DURBIN, J.; KOOPMAN, S. J. **Time series analysis by space state methods**. New York: Oxford University Press, 2001.

FIALHO, T. M. M. Ciclos políticos: uma resenha. **Revista de economia política**, v. 19, n. 2, 1999.

GOBETTI, S. W. **Estimativa dos investimentos públicos: um novo modelo de análise de execução orçamentária aplicado às contas nacionais**. Brasília: STN; Universidade de Brasília, 2007. (XI Prêmio Tesouro Nacional de Monografias em 2006)

HARVEY, A.; CHUNG, C. Estimating the underlying change in unemployment in the UK. **Journal of the royal statistical society**, v. 163, n. 3, 2000.

HARVEY, A. C. **Forecasting, structural time series and the Kalman filter**. Cambridge: Cambridge University Press, 1989.

KALECKI, M. Political aspects of full employment. **Political quarterly**, v. 14, 1943.

MOAURO, F.; SAVIO, G. Temporal disaggregation using multivariate structural time series models. **Econometrics journal**, v. 8, n. 2, 2005.

MONCH, E.; UHLIG, H. Towards a monthly business cycle chronology for the euro area. **Journal of business cycle measurement and analysis**, v. 2, n.1, 2005.

NAKAGUMA, M. Y.; BENDER, S. A emenda da reeleição e a lei de responsabilidade fiscal: Impactos sobre ciclos políticos e performance fiscal dos estados (1986-2002). **Revista de economia aplicada**, v. 10, n. 3, 2006.

ORAIR, R. O. *et al.* Uma metodologia de construção de séries de alta frequência das finanças municipais no Brasil com aplicação para o IPTU e o ISS (2004-2010). **Pesquisa e planejamento econômico**, v. 41, n. 3, 2011.

PROIETTI, T. Temporal Disaggregation by state space methods: dynamic regression methods revisited. **Econometrics journal**, v. 9, n. 3, 2006.

RODRIGUES, R. V.; TEIXEIRA, E. C. Gasto público e crescimento econômico no Brasil: uma análise comparativa dos gastos das esferas de governo. **Revista brasileira de economia**, v. 64, n. 4, 2010.

SAKURAI, S. N. **Ciclos eleitorais, reeleição e déficit fiscal nos municípios brasileiros: uma análise via dados em painel**. Tese (Doutorado) – Universidade de São Paulo, São Paulo, 2007.

SANCHES, N. G.; ROCHA, F. Investimentos estaduais públicos e privados: bens substitutos ou complementares? **Economia aplicada**, v. 14, n. 2, 2010.

SANTOS, C. H. M. *et al.* **Estimativas de alta frequência da formação bruta de capital fixo das administrações públicas brasileiras no período 2002-2010**. Brasília: Ipea, 2011. (Texto para Discussão, n. 1.660.)

SCHETTINI, B. P. *et al.* Resultado estrutural e impulso fiscal: uma aplicação para as administrações públicas no Brasil – 1997-2010. **Pesquisa e Planejamento Econômico**, v. 41, 2, 2011.

ANEXOS

ANEXO A

Pré-teste para a seleção de procedimentos da desagregação temporal

A técnica de desagregação temporal por MEE foi utilizada neste trabalho para desagregar temporalmente a série anual da FBCF de onze UFs a partir de: *i*) indicador bimestral dos investimentos destas mesmas UFs; e *ii*) indicador mensal com a FBCF das demais quinze UFs (excluindo-se São Paulo). Este procedimento pode ser conduzido por pelo menos dois caminhos: *i*) *estimação por uma etapa*: desagregando-se diretamente a série anual pelo indicador de frequência mensal; e *ii*) *estimação por duas etapas*: desagregando-se o indicador bimestral para a frequência mensal (com o indicador bimestral) e, em seguida, a série de referência anual para a frequência mensal utilizando os dois indicadores mensais. Também existem várias estruturas possíveis para o modelo de regressão, a partir de diferentes restrições aos parâmetros dos componentes autorregressivos, e, na prática, existem pelo menos doze alternativas para a desagregação temporal que estão listadas na tabela A.1.

Com intuito de avaliar estas alternativas, optou-se por realizar um pré-teste para seleção do procedimento que provê estimativas mais precisas. O teste consistiu em selecionar aleatoriamente uma subamostra de sete UFs entre as quinze UFs com informações mensais disponíveis e aplicar cada um dos procedimentos de desagregação temporal para as informações anuais da FBCF desta subamostra.¹ Os valores estimados via desagregação temporal foram então comparados com os valores mensais observados e calculada como estatística de ajuste do modelo a raiz quadrada do erro quadrático médio.

TABELA A.1

Estatística de ajuste para seleção dos procedimentos da desagregação temporal

Procedimento	Modelo estrutural	Estatística
Estimação em uma etapa	Estático com resíduos IID	124,36
	Estático com resíduos em primeira diferença	94,08
	Estático com resíduos AR(1)	124,37
	Dinâmico com resíduos IID	101,26
	Dinâmico com resíduos em primeira diferença	3.131,44
	Dinâmico com resíduos AR(1)	2.326,38

(Continua)

1. A subamostra selecionada é formada pelos estados do Espírito Santo, Maranhão, Mato Grosso do Sul, Rio Grande do Sul, Rondônia, Goiás e Rio de Janeiro.

(Continuação)

Procedimento	Modelo estrutural	Estatística
Estimação em duas etapas	Estático com resíduos IID	94,26
	Estático com resíduos em primeira diferença	79,56
	Estático com resíduos AR(1)	92,12
	Dinâmico com resíduos IID	104,50
	Dinâmico com resíduos em primeira diferença	3.129,60
	Dinâmico com resíduos AR(1)	158,59

Elaboração dos autores.

Obs.: a estatística de ajuste considera a raiz quadrada do erro quadrático médio.

Os valores calculados da estatística de ajuste estão mostrados na tabela A.1 e indicam um melhor ajuste da estimação em duas etapas em relação à estimação em uma etapa que sempre apresentou maiores valores da estatística de ajuste para modelos equivalentes. Os modelos estáticos também mostraram *performances* – quase sempre – superiores aos modelos dinâmicos equivalentes. Entre todas as alternativas, a estatística de teste indica que o modelo estático com resíduos em primeira diferença em duas etapas foi o que melhor se ajustou aos valores observados. Os resultados da desagregação temporal apresentados na seção 4 se basearam nesta estrutura que corresponde a estabelecer as restrições e na equação (7) da seção 2.

ANEXO B

Resultados dos modelos bivariados utilizados para previsão contemporânea

TABELA B.1

Modelo	Modelo bivariado - GE				Modelo bivariado - GM			
	LGE		Indicador LGE		LGM		Indicador LGM	
Nível	7,86465	[0.00000] ²	7,74963	[0.00000] ²	8,02399	[0.00000] ²	7,24121	[0.00000] ²
	(0.00862458)				(0.00892589)			
Inclinação	0,01026	[0.32918]	0,00837	[0.48464]	0,01022	[0.24287]	0,00823	[0.35042]
	(0.00000108034)							
Irregular	(0.00668304)		(5.40857e-008)		(0.00398071)		(1.02974e-009)	
Sazonalidade	(0.00000249275)		(7.83217e-012)		(0.0000320735)			
Janeiro	-1,02984	[0.00000] ²	-1,32237	[0.00000] ²	-0,31022	[0.00056] ²	-0,79586	[0.00000] ²
Fevereiro	-0,53597	[0.00000] ²	-1,30461	[0.00000] ²	-0,74074	[0.00000] ²	-0,82442	[0.00000] ²
Março	-0,08136	[0.05766]	-0,15625	[0.06023]	-0,13444	[0.11657]	-0,09746	[0.01834] ¹
Abril	-0,20087	[0.00001] ²	-0,16378	[0.04430]	-0,13166	[0.11975]	-0,12958	[0.00195] ²
Maio	-0,04029	[0.33812]	0,04193	[0.59566]	-0,00352	[0.96615]	0,04421	[0.27014]
Junho	-0,01694	[0.68505]	0,04038	[0.60109]	-0,03833	[0.63994]	0,01912	[0.62987]
Julho	0,07475	[0.07456]	0,21808	[0.00454] ²	0,15422	[0.05846]	0,18111	[0.00002] ²
Agosto	0,1577	[0.00024] ²	0,22641	[0.00261] ²	0,17367	[0.03134] ¹	0,17216	[0.00004] ²
Setembro	0,16445	[0.00013] ²	0,22693	[0.00198] ²	0,10606	[0.17874]	0,14139	[0.00058] ²
Outubro	0,14782	[0.00053] ²	0,22955	[0.00140] ²	0,07371	[0.34292]	0,15116	[0.00026] ²
Novembro	0,29085	[0.00000] ²	1,00106	[0.00000] ²	0,42938	[0.00000] ²	0,56312	[0.00000] ²
Dezembro	1,06971	[0.00000] ²	0,96267	[0.00000] ²	0,42187	[0.00000] ²	0,57505	[0.00000] ²
Desvio padrão	0,12718		0,14011		0,12888		0,093869	
Teste de normalidade	8,3667	[0.0038] ²	29,586	[0.0000] ²	1,6284	[0.2019]	28,151	[0.0000] ²
Teste de significância do efeito sazonal	1454,357	[0.00000] ²	681,032	[0.00000] ²	138,698	[0.00000] ²	1229,665	[0.00000] ²
Teste para homoscedasticidade	1,3156	[0.4212]	1,0309	[0.9288]	1,3111	[0.5606]	2,0350	[0.1304]
Coefficiente de determinação	0,78014		0,68633		0,73625		0,74845	
Inovação (erro de previsão)								
Variância-covariância	0,01617	0,01228	0,01963	0,01228	0,01661	0,00941	0,00881	0,00941
Coefficiente de correlação	0,68889		0,68889		0,77803		0,77803	
Componente irregular								
Variância-covariância	0,006683	-0,0006545	6,42E-05	-0,0006545	0,003981	3,18E-05	-0,0003556	3,18E-05
Coefficiente de correlação	-0,9996		-0,9996		-1,000		-1,000	
Teste de correlação serial								
Até 6 defasagens	9,7171	[0.0211] ¹			23,441	[0.0000] ²		
Até 12 defasagens	11,841	[0.2224]			29,925	[0.0005] ²		
Até 24 defasagens	15,881	[0.7763]			54,389	[0.0001] ²		
Até 36 defasagens	29,462	[0.6440]			58,731	[0.0038] ²		

(Continua)

(Continuação)

Modelo	Modelo bivariado - GE		Modelo bivariado - GM	
	LGE	Indicador LGE	LGM	Indicador LGM
Estimativas dos valores faltantes				
Jan./2011	6.77904 (0.0108595)		7.63617 (0.008089)	
Fev./2011	7.25483 (0.0100649)		7.23495 (0.008060)	
Mar./2011	7.65712 (0.0100306)		7.76684 (0.008059)	
Abr./2011	7.53858 (0.0100284)		7.80023 (0.008048)	
Mai./2011	7.68753 (0.0100314)		7.99262 (0.008048)	
Jun./2011	7.71229 (0.0100380)		7.98645 (0.008037)	
Jul./2011	7.80552 (0.0100442)		8.20031 (0.008037)	
Ago./2011	7.88203 (0.0100537)		8.22944 (0.008027)	
Set./2011	7.85904 (0.0100639)		8.13186 (0.008026)	
Out./2011	7.8499 (0.0100876)		8.09187 (0.008018)	
Nov./2011	8.11341 (0.0101528)		8.462 (0.008017)	
Dez./2011	8.93274 (0.0106897)		8.44665 (0.008027)	

Elaboração dos autores.

Notas: ¹ Valores significativos ao nível de 5%.² Valores significativos ao nível de 1%.

Obs.: os valores entre parênteses são estimativas das variâncias, e os valores entre colchetes são níveis de significância dos testes. Os valores dos parâmetros correspondem ao vetor de estado do período final. Detalhes sobre os testes de normalidade (estatística de Bowman-Shenton), homoscedasticidade e correlação serial dos resíduos (estatística de Box-Ljung) e dos testes para detecção de variáveis de intervenção podem ser vistos em Durbin e Koopman (2001, p. 33-35).

EDITORIAL

Coordenação

Cláudio Passos de Oliveira

Supervisão

Everson da Silva Moura

Marco Aurélio Dias Pires

Revisão

Andressa Vieira Bueno

Clícia Silveira Rodrigues

Hebert Rocha de Jesus

Idalina Barbara de Castro

Laeticia Jensen Eble

Leonardo Moreira de Souza

Luciana Dias

Olavo Mesquita de Carvalho

Reginaldo da Silva Domingos

Celma Tavares de Oliveira (estagiária)

Patrícia Firmina de Oliveira Figueiredo (estagiária)

Editoração eletrônica

Aline Rodrigues Lima

Andrey Tomimatsu

Danilo Leite de Macedo Tavares

Jeovah Herculano Szervinsk Junior

Leonardo Hideki Higa

Daniella Silva Nogueira (estagiária)

Capa

Luís Cláudio Cardoso da Silva

Projeto Gráfico

Renato Rodrigues Bueno

Livraria do Ipea

SBS – Quadra 1 - Bloco J - Ed. BNDES, Térreo.

70076-900 – Brasília – DF

Fone: (61) 3315-5336

Correio eletrônico: livraria@ipea.gov.br

Missão do Ipea

Produzir, articular e disseminar conhecimento para aperfeiçoar as políticas públicas e contribuir para o planejamento do desenvolvimento brasileiro.

