

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE CIÊNCIAS ECONÔMICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA**

GIOVANI BAGGIO

**ESTIMANDO O PIB MENSAL DO RIO GRANDE DO SUL:
UMA ABORDAGEM DE ESPAÇO DE ESTADOS**

**Porto Alegre
2017**

GIOVANI BAGGIO

**ESTIMANDO O PIB MENSAL DO RIO GRANDE DO SUL:
UMA ABORDAGEM DE ESPAÇO DE ESTADOS**

Dissertação submetida ao Programa de Pós-Graduação em Economia da Faculdade de Ciências Econômicas da UFRGS, como requisito parcial para obtenção do título de Mestre em Economia, com ênfase em Economia Aplicada.

Orientador: Professor Dr. Marcelo Savino
Portugal

**Porto Alegre
2017**

CIP - Catalogação na Publicação

Baggio, Giovani

Estimando o PIB mensal do Rio Grande do Sul: uma abordagem de espaço de estados / Giovani Baggio. -- 2017.

49 f.

Orientador: Marcelo Savino Portugal.

Dissertação (Mestrado) -- Universidade Federal do Rio Grande do Sul, Faculdade de Ciências Econômicas, Programa de Pós-Graduação em Economia, Porto Alegre, BR-RS, 2017.

1. PIB do Rio Grande do Sul. 2. Modelo em espaço de estados. 3. Interpolação. 4. Nowcasting. 5. Ciclos econômicos do Rio Grande do Sul. I. Portugal, Marcelo Savino, orient. II. Título.

GIOVANI BAGGIO

**ESTIMANDO O PIB MENSAL DO RIO GRANDE DO SUL:
UMA ABORDAGEM DE ESPAÇO DE ESTADOS**

Dissertação submetida ao Programa de Pós-Graduação em Economia da Faculdade de Ciências Econômicas da UFRGS, como requisito parcial para obtenção do título de Mestre em Economia, com ênfase em Economia Aplicada.

Aprovada em: Porto Alegre, 29 de janeiro de 2018.

BANCA EXAMINADORA:

Dr. André Francisco Nunes de Nunes
FIERGS

Dr. Igor Alexandre Clemente de Morais
UNISINOS

Dr. Sabino da Silva Porto Júnior
UFRGS

RESUMO

Considerando a importância de uma medida de alta frequência para o PIB do Rio Grande do Sul, o principal indicador de atividade econômica do estado, este trabalho foi dividido em três objetivos. O primeiro foi a estimação de uma série com frequência mensal para o PIB real do Rio Grande do Sul entre janeiro de 2002 e março de 2017, dado que o mesmo só é contabilizado em frequência trimestral. Para tanto, foi utilizado um modelo em espaço de estados que permite a estimação e *nowcast* do PIB mensal, utilizando séries coincidentes como fonte de informação para a interpolação dos dados trimestrais do PIB, em linha com Bernanke, Gertler e Watson (1997), Mönch e Uhlig (2005) e Issler e Notini (2016). O segundo objetivo foi comparar a série estimada com um indicador de atividade calculado pelo Banco Central do Brasil para o estado, o Índice de Atividade Econômica Regional (IBCR-RS), tanto em termos metodológicos como na capacidade em antecipar as variações do PIB trimestral antes de sua divulgação (*nowcasting*). O terceiro objetivo foi estabelecer a cronologia dos ciclos de expansão e recessão da economia gaúcha com o uso do algoritmo de Bry e Boschan (1971). Após a etapa de seleção das séries coincidentes e da estimação de diversos modelos de interpolação, foi escolhido para gerar a série mensal do PIB o modelo que utiliza somente a produção industrial como variável auxiliar, tendo este apresentado o melhor ajuste. A comparação do PIB mensal interpolado com o IBCR-RS mostrou que, além da vantagem computacional a favor do método proposto neste trabalho, a imposição da disciplina de que as variações do PIB mensal estimado devem ser exatamente iguais às do PIB trimestral faz com que a dinâmica de curto e longo prazo das variáveis sejam idênticas, o que não ocorre com o IBCR-RS. A cronologia dos pontos de inflexão da atividade econômica apontou três períodos recessivos na economia gaúcha desde janeiro de 2002: jun/2003 a abr/2005 (23 meses e queda acumulada de 8,79%); abr/2011 a abr/2012 (13 meses e queda acumulada de 9,47%); e jun/2013 a nov/2016 (42 meses e queda acumulada de 10,41%), sendo o encerramento deste último apontado somente com a inclusão dos resultados estimados pelo modelo para o segundo trimestre de 2017. Finalmente, os resultados do exercício de *nowcasting* do PIB mostraram desempenho superior do método proposto frente ao IBCR-RS em termos de antecipação do resultado do PIB de um trimestre a frente, tomando como base as medidas de MAE (erro absoluto médio, em inglês) e MSE (erro quadrático médio, em inglês), comumente usadas nesse intuito.

Palavras-chave: PIB do Rio Grande do Sul. Modelo em espaço de estados. Interpolação. *Nowcasting*. Ciclos econômicos do Rio Grande do Sul.

ABSTRACT

Giving the importance of a high frequency measure for Rio Grande do Sul's GDP, the main indicator of economic activity of the state, this work was divided into three objectives. The first one was the estimation of monthly frequency series for Rio Grande do Sul's real GDP between January/2002 and March/2017, since it is only accounted in quarterly basis. Therefore, we used a State-Space model that enables to estimate and nowcast the monthly GDP, using coincident series as a source of information for the interpolation of quarterly GDP data, in line with Bernanke, Gertler e Watson (1997), Mönch e Uhlig (2005) and Issler e Notini (2016). The second objective was to compare the estimated series with an activity indicator calculated by the Central Bank of Brazil for the state, the Regional Economic Activity Index (IBCR-RS), both in methodological terms and in the capability to anticipate the quarterly GDP release (*nowcasting*). The third objective was to establish the chronology of the cycles of expansion and recession of the economy of Rio Grande do Sul using the algorithm of Bry e Boschán (1971). After the selection of the coincident series and the estimation of several interpolation models, the chosen model to generate the monthly GDP series uses only the industrial production as an auxiliary variable, and this one presented the best fit. The comparison of the monthly GDP interpolated with the IBCR-RS showed that, in addition to the computational advantage in favor of the method proposed in this work, the imposition of the discipline that the estimated monthly GDP changes must be exactly the same as the quarterly GDP makes the short-term and long-term dynamics of the variables are identical, which is not the case with IBCR-RS. The chronology of the turning points of the economic activity pointed to three recessive periods in the economy of Rio Grande do Sul since January 2002: June/2003 to April/2005 (23 months and accumulated drop of 8.79%); April/2011 to April/2012 (13 months and accumulated fall of 9.47%); and June/2013 to November/2016 (42 months and 10.41% accumulated decrease), with the latter one closing only with the inclusion of the results estimated by the model for the second quarter of 2017. Finally, results for GDP's nowcasting showed superior performance of the proposed method compared to the IBCR-RS in terms of anticipating quarter-to-quarter GDP results, based on the measures of MAE (absolute mean error) and MSE (mean square error), commonly used for this purpose.

Keywords: Rio Grande do Sul's GDP. State-space models. Interpolation. Nowcasting. Business cycles of Rio Grande do Sul.

SUMÁRIO

1	INTRODUÇÃO	7
2	CICLOS ECONÔMICOS E INDICADORES DE ATIVIDADE	9
2.1	Indicadores coincidentes e antecedentes	9
2.2	Modelos para interpolação	11
3	METODOLOGIA	14
3.1	Representação em espaço de estados	14
3.2	Filtragem e suavização	15
3.3	Estimação	17
3.4	<i>Nowcasting</i>	17
3.5	Modelo global para interpolação	18
3.6	Qualidade do ajustamento para modelos interpolados	21
3.7	Algoritmo de datação de ciclos: Bry e Boschan (1971)	21
4	RESULTADOS EMPÍRICOS	23
4.1	Dados	23
4.2	Testes para seleção das séries coincidentes	25
4.3	Resultados da interpolação	28
4.4	Comparação do PIB mensal com o IBCR-RS	29
4.5	Datação dos ciclos econômicos	33
4.6	<i>Nowcasting</i> do PIB	36
5	CONSIDERAÇÕES FINAIS	39
	REFERÊNCIAS	41
	APÊNDICE A – TABELAS E GRÁFICOS ADICIONAIS	44

1 INTRODUÇÃO

Saber o estado atual de sua atividade econômica é importante para qualquer sociedade. A percepção quanto ao ritmo da economia e, além disso, as perspectivas de como ela se comportará em um futuro próximo têm influência fundamental em qualquer tomada de decisão dos agentes econômicos. Empresários, por exemplo, consideram o desempenho econômico como uma das variáveis de decisão para a implementação de projetos de investimento. Da mesma forma, o bem-estar dos consumidores está diretamente ligado ao estado atual da economia, influenciando em suas decisões de consumo, poupança e investimento. Ademais, os governos também se interessam por esse tipo de informação para aprimorar a execução e planejamento de seus orçamentos, além de aumentar a eficiência da gestão pública.

A abordagem empírica da medição do estado da economia teve como ponto de partida o artigo seminal de Burns e Mitchell (1946), onde os autores analisaram as características dos ciclos de negócios da economia dos Estados Unidos. A partir de então, diversas metodologias surgiram com o objetivo de criar indicadores que possam aproximar, e até antecipar, os movimentos da atividade econômica. Estes indicadores são conhecidos na literatura como coincidentes e antecedentes, respectivamente.

Há vários indicadores que expressam o estado em que o ciclo econômico se encontra. No entanto, conforme afirmam Stock e Watson (1999), se tivéssemos que optar por uma única variável que represente o estado atual da economia, a melhor escolha seria o Produto Interno Bruto (PIB). Portanto, quanto maior a frequência e menor a defasagem temporal na divulgação das medições do PIB, mais precisa e rápida será a aferição do ritmo de atividade econômica atual.

Entretanto, na maioria dos países, inclusive no Brasil – e também nas Unidades da Federação, como no Rio Grande do Sul –, as estimativas para o PIB são divulgadas apenas com frequência trimestral e possuem um período considerável de defasagem na publicação, que vai de 2 a 6 meses após o término do trimestre de referência. Dessa forma, por exemplo, podemos estar em março ou abril de um determinado ano e ainda não conhecer o resultado da atividade econômica de outubro do ano anterior.

Uma boa estratégia para termos estimativas de maior frequência do PIB é combinar suas observações trimestrais com séries que tenham alta correlação com o ciclo de negócios. Em outras palavras, utilizar séries coincidentes da atividade econômica para estimar os valores mensais do PIB que não são observados. Dentre os estudos que se propuseram a fazer isto, destaca-se um recentemente feito para o Brasil por Issler e Notini (2016), cujos resultados mostraram-se bastante satisfatórios.

São três os objetivos principais deste estudo. O primeiro é a construção de uma série com frequência mensal para o PIB do Rio Grande do Sul, tendo como base um modelo geral de interpolação, que usa uma abordagem em espaço de estados em

linha com Bernanke, Gertler e Watson (1997), Mönch e Uhlig (2005) e Issler e Notini (2016). Para tanto, serão utilizados os dados observados do PIB trimestral e séries coincidentes com frequência mensal que servirão como suporte para as estimativas mensais, não observáveis. As séries coincidentes, quando postas em bases trimestrais, devem ser altamente correlacionas com o PIB.

O segundo objetivo é comparar a série de PIB mensal estimada com o indicador de atividade calculado e divulgado mensalmente pelo Banco Central do Brasil (BCB) para a economia do estado: o Índice de Atividade Econômica Regional do Rio Grande do Sul (IBCR-RS). Nessa etapa, as projeções dentro e fora da amostra (*nowcast*) do modelo de interpolação aqui proposto serão confrontadas com os indicadores do BCB, com o intuito de identificar qual das séries melhor antecipa as variações do PIB trimestral.

Por fim, o terceiro objetivo é estabelecer a cronologia dos ciclos de expansão e recessão para a economia do Rio Grande do Sul, agora com base em uma série mensal do PIB, permitindo a identificação exata dos pontos de inflexão da atividade econômica. Essa etapa utilizará o algoritmo proposto por Bry e Boschan (1971) para detecção dos picos e vales da série estimada.

2 CICLOS ECONÔMICOS E INDICADORES DE ATIVIDADE

O estudo dos ciclos de negócios é praticamente coexistente com a Macroeconomia de curto prazo e tem estreita relação com as teorias de crescimento, moeda, inflação e o papel das expectativas em uma economia. Os primeiros estudos nessa área remontam ao século XIX, quando a instabilidade de períodos recessivos despertava o interesse dos estudiosos. Inicialmente, as causas eram atribuídas a fatores exógenos, como secas e guerras, passando mais adiante para explicações endógenas, como a dinâmica dos investimentos e inovações (ZARNOWITZ, 1992).

Nas palavras de Burns e Mitchell (1946), os ciclos de negócios seriam assim descritos:

Business Cycles are a type of fluctuation found in the aggregate economic activity of nations that organize their work in business enterprises. A cycle consists of expansion occurring at about the same time in many economic activities, followed by similarly general recessions, contractions, and revivals which merge into the expansion phase of the next cycle; this sequence of changes is recurrent but not periodic; in duration business cycles vary from more than one year to ten or twelve years (BURNS; MITCHELL, 1946).

A partir da análise teórica dos ciclos de negócios, a extensão da pesquisa para o campo empírico exigia a capacidade de mensuração das variáveis que influenciam o comportamento cíclico da atividade econômica. Os desenvolvimentos nesse sentido foram aprofundados com a criação do *National Bureau of Economic Research* (NBER) em 1920, nos Estados Unidos.

2.1 Indicadores coincidentes e antecedentes

A análise empírica e de construção de indicadores que condensam as características dos ciclos de negócios começou a entrar na pauta dos pesquisadores a partir do artigo seminal de Burns e Mitchell (1946), incluído em um ciclo de estudos mais amplo do NBER. Os indicadores que procuram representar os movimentos correntes da atividade econômica foram chamados de indicadores coincidentes, enquanto os que objetivam antecipar a ocorrência das fases do ciclo de indicadores antecedentes.

As primeiras tentativas de elaboração desses indicadores, ocorridas no *Department of Commerce* dos Estados Unidos, e posteriormente adotadas pelo NBER, calculavam índices através de médias móveis ponderadas de diversas séries macroeconômicas. Portanto, nessas análises iniciais, não eram empregados modelos probabilísticos para captar o comportamento estocástico dos choques a que essas variáveis estão sujeitas.

Uma nova classe de modelos surgiu com o trabalho de Stock e Watson (1988) para a economia americana, onde os autores propuseram um modelo com fundamento estatístico baseado no princípio de que o comportamento dinâmico das variáveis pode

ser representado por um componente não observado comum a elas. Essa metodologia de extração de um componente cíclico para transformá-lo em um índice coincidente, o qual representa o estado da economia, ficou conhecida como Modelo de Fator Dinâmico. A formulação linear da abordagem de Stock e Watson (1988) permite a utilização do filtro de Kalman para sua estimação, o que é feito com a representação em espaço de estados das equações básicas do modelo.

Posteriormente, Stock e Watson (1989) estenderam seu modelo inicial para extrair um indicador antecedente, capaz de expressar o comportamento futuro da atividade econômica. O conjunto de trabalhos de Stock e Watson (1988), Stock e Watson (1989), Stock e Watson (1991) e Stock e Watson (1993) foi o ponto de partida para uma série de artigos que se propuseram a medir a situação atual e projetar o comportamento futuro de economias mundo a fora, como Forni et al. (2000), Forni et al. (2001), Diebold e Rudebusch (1996) e Chauvet (1998).

A metodologia de fator dinâmico também foi utilizada em diversos trabalhos aplicados para o Brasil. Spacov (2001) estimou um indicador coincidente e um antecedente para a atividade econômica brasileira através de um modelo com mais de um componente comum, uma combinação das metodologias empregadas em Forni et al. (2000), Forni et al. (2001) e Issler e Vahid (2006). Já Picchetti e Toledo (2002) aplicaram a mesma abordagem para a produção industrial. Chauvet (2000), por sua vez, criou um indicador antecedente para a inflação brasileira medida pelo IPCA, com a inclusão de mudança de regime markoviana no modelo de fator dinâmico, objetivando capturar assimetrias nos ciclos de alta e baixa do índice de preços.

Aplicações dos modelos de Stock e Watson foram feitas em dois trabalhos para a economia do Rio Grande do Sul. Primeiramente, Moraes e Portugal (2007) construíram um índice coincidente para a atividade econômica da indústria de transformação do Estado. Os dados utilizados foram extraídos da pesquisa Indicadores Industriais da FIERGS/CNI e abrangiam o período de janeiro de 1992 a março de 2003. Os resultados encontrados foram comparados ao Índice de Desempenho Industrial (IDI/RS), construído pela FIERGS através da metodologia de Análise de Componentes Principais. Outra aplicação da metodologia de fator dinâmico foi feita por Torres (2014) para o comércio varejista gaúcho com a criação de um índice coincidente para a atividade econômica do setor.

Uma alternativa à modelagem de Stock e Watson para a criação de indicadores coincidentes e antecedentes é utilizar a metodologia do *The Conference Board* (TCB), uma entidade privada e sem fins lucrativos dos Estados Unidos. Os indicadores do TCB, calculados para treze países atualmente, são médias móveis ponderadas de séries representativas para a economia de cada país. Para o índice coincidente da economia americana são ponderadas apenas quatro séries (emprego, renda, produção industrial e vendas), enquanto que para o Brasil, onde o cálculo é realizado em parceria com a

Fundação Getúlio Vargas, são seis (produção industrial, consumo de energia industrial, volume de vendas no varejo, emprego, renda e expedição de papelão ondulado).

Apesar da simplicidade do método, os indicadores cíclicos do TCB têm mostrado uma boa aderência aos movimentos da atividade econômica agregada dos países abordados, conforme apontam os relatórios mensais divulgados. Uma aplicação da metodologia TCB para a indústria brasileira foi feita por Hollauer, Issler e Notini (2009), onde os autores encontraram desempenho superior desse método em relação ao de Stock e Watson na detecção de pontos de inflexão da atividade industrial.

Por fim, uma outra abordagem é utilizada pela Organização para a Cooperação e Desenvolvimento Econômico (OCDE) na construção dos chamados indicadores antecedentes compostos, onde diversas técnicas estatísticas são empregadas na escolha do melhor modelo. Entre elas estão a Análise de Componentes Principais, Análise Fatorial e Análise de Cluster (NARDO et al., 2005). Aplicações da metodologia da OCDE podem ser encontradas em Gallardo e Pedersen (2007), trabalho no qual os autores criaram indicadores antecedentes para a América Latina, e também em Morais (2013), onde a proposta foi aplicada à economia do Rio Grande do Sul.

2.2 Modelos para interpolação

Um dos grandes problemas enfrentados por pesquisadores e formuladores de políticas públicas é a baixa periodicidade das séries econômicas disponíveis, o que se torna um empecilho na implementação de modelos estatísticos para a criação de indicadores. Ao invés de criar índices coincidentes para a atividade econômica com as metodologias descritas acima, que muitas vezes ignoram informações importantes em função da indisponibilidade de dados em alta frequência – como por exemplo, o PIB real que, na maioria dos países, possui contabilização trimestral –, uma alternativa é aproveitar as informações em baixa frequência e transformá-las em séries de frequência maior com o uso de modelos de interpolação.

Uma grande variedade de métodos para interpolação já foram propostos na literatura. Entre eles, há os que buscam estimar uma representação em alta frequência de séries temporais que somente são encontradas em baixa frequência, fazendo o uso de modelos puramente matemáticos e que utilizam apenas as informações da própria série, como nos trabalhos de Boot, Feibes e Lisman (1967), Jacobs (1994) e Wei e Stram (1990). Por outro lado, uma outra classe de modelos leva em conta informações contidas em séries relacionadas, para assim realizar a interpolação através de um modelo de regressão. O trabalho aqui proposto encaixa-se na segunda classe, de modo que serão estimadas séries mensais para o PIB do Brasil e do Rio Grande do Sul com base em indicadores economicamente relacionados que possuam frequência mensal.

Um dos métodos de interpolação mais utilizados, sendo o primeiro a buscar informações em séries correlacionadas que possuam a frequência desejada, relaci-

onando variáveis de fluxo e estoque em um único modelo, foi proposto por Chow e Lin (1971). Nessa abordagem, os autores consideram que as observações da série de alta frequência foram geradas por um modelo de regressão linear, com as séries relacionadas como variáveis explicativas e os resíduos com autocorrelação de primeira ordem. Através do estimador proposto, os problemas de interpolação, distribuição, e extrapolação de uma série temporal com o uso de séries relacionadas podem ser resolvidos de maneira unificada.

A especificação do melhor modelo de regressão a ser empregado deve atentar para as características próprias do conjunto de séries em questão. Para incorporar o atributo de não-estacionariedade presente em diversas séries de dados, principalmente as macroeconômicas, Fernández (1981) sugeriu uma modificação no modelo de Chow e Lin (1971), inserindo a primeira diferença das variáveis no modelo de regressão.

Uma formulação mais geral foi utilizada nos trabalhos de Salazar, Smith e Weale (1997), Salazar et al. (1998) e Mitchell e Jones (2005), onde os autores empregam modelos dinâmicos através da incorporação de observações defasadas da série a ser interpolada na equação de regressão.¹

Uma abordagem que unifica os três métodos descritos acima foi desenvolvida por Bernanke, Gertler e Watson (1997) e aplicada para a obtenção de estimativas mensais para o PIB americano e seus componentes, tendo como base os dados observados trimestrais do PIB e séries coincidentes auxiliares, como a produção industrial. Os autores utilizaram um modelo geral em formato de espaço de estados, o qual permite que se chegue a seis modelos diferentes através de restrições simples nos parâmetros a serem estimados. A mesma abordagem foi utilizada por Mönch e Uhlig (2005) para estimar o produto agregado mensal dos países da Zona do Euro, sendo que o objetivo final foi estimar uma trajetória mensal para o PIB da área comum europeia como um todo.

A configuração proposta por Bernanke, Gertler e Watson (1997) foi aplicada por Issler e Notini (2016) para a estimação do PIB mensal brasileiro entre 1980 e 2012. A formulação em espaço de estados proposta nos modelos dessa linha impõem a restrição de que a soma das respectivas estimativas mensais para o PIB se igualem ao valor observado no trimestre. Uma dificuldade encontrada pelos autores foi a escassez de séries econômicas mensais para um período longo de tempo no país. Após etapas de filtragem e testes com algumas séries coincidentes para a economia brasileira, as que se mostraram mais adequadas como covariáveis na interpolação foram a produção industrial e a expedição de papelão ondulado. As demais séries testadas foram: demanda por energia, produção de aço, produção de cimento e produção de veículos. Mesmo com apenas duas séries auxiliares, a soma das três projeções mensais feitas para o PIB antes de sua verdadeira observação trimestral, ou seja, o

¹ Para mais métodos de interpolação e detalhes teóricos ver Di Fonzo (2003) e Proietti (2006).

exercício de *nowcasting* do PIB, teve uma melhor performance em antecipar o resultado trimestral em relação ao Índice de Atividade Econômica do Banco Central (IBC-BR), conhecido como prévia do PIB.

Segundo Issler e Notini (2016), destacam-se três vantagens em se usar a configuração em espaço de estados proposta por Bernanke, Gertler e Watson (1997). A primeira é a consistência na agregação temporal, ou seja, a soma ponderada do PIB dos três respectivos meses do trimestre é exatamente igual ao valor observado trimestral. A segunda é testar diversos métodos de interpolação com pequenas restrições no modelo. Por fim, a terceira vantagem é que as estimativas mensais de *nowcasting* são feitas com a disciplina de se somarem às observações trimestrais observadas na amostra, o que produz um comportamento superior na antecipação dos movimentos de curto prazo da atividade econômica.

O presente trabalho seguirá as abordagens de Bernanke, Gertler e Watson (1997), Mönch e Uhlig (2005) e Issler e Notini (2016) para a estimação do PIB mensal para o Rio Grande do Sul. Através de um modelo geral em espaço de estados serão estimados seis diferentes modelos de interpolação, sendo escolhido o que apresentar melhor ajuste conforme os critérios que serão detalhados na próxima seção. Com a série mensal em mãos, é possível proceder com o exercício de *nowcasting*, utilizando-se das séries coincidentes da atividade econômica, as quais serão selecionadas com base em critérios como correlação e cointegração com o PIB. Além disso, será possível (re)estabelecer os ciclos de recessão e expansão da economia, tendo como referência uma série de maior frequência e os resultados do algoritmo de Bry e Boschan (1971).

A aplicação desta abordagem traz duas contribuições importantes no contexto do PIB do Rio Grande do Sul. A primeira é a construção de uma série mensal para o PIB gaúcho que não encontra-se disponível, contribuindo para estudos e todos os tipos de trabalhos aplicados à economia estadual. A segunda é a construção de um modelo que poderá ser usado para estimar mensalmente o resultado do PIB antes mesmo de sua divulgação, através de séries coincidentes disponíveis.

3 METODOLOGIA

Nesta seção será apresentada uma breve descrição dos modelos em formato de espaço de estados e como eles são estimados com o uso do filtro de Kalman. Para maiores detalhes teóricos, pode-se ver Hamilton (1994) e Harvey (1989). Além disso, será exposto o modelo para a interpolação que será usado na estimação do PIB mensal do Rio Grande do Sul, conforme proposto por Bernanke, Gertler e Watson (1997). Uma boa apresentação e aplicação dessa metodologia também pode ser encontrada em Mönch e Uhlig (2005).

3.1 Representação em espaço de estados

O formato de espaço de estados (*state-space*) é uma maneira particular de representar um sistema dinâmico que torna possível a utilização do filtro de Kalman para sua estimação. O filtro de Kalman, por sua vez, é um algoritmo que, dados os valores iniciais, atualiza sequencialmente as projeções lineares de um sistema dinâmico.

Considere y_t um vetor ($n \times 1$) de variáveis observáveis no período t ; ξ_t um vetor ($r \times 1$) de variáveis não-observáveis no período t ; e x_t um vetor ($k \times 1$) de variáveis pré-determinadas ou exógenas no período t . No presente trabalho, y_t será o PIB trimestral observado; ξ_t será o PIB mensal a ser estimado; e x_t serão as séries coincidentes auxiliares de onde serão extraídas informações para a construção do PIB mensal, como por exemplo, a produção industrial, vendas do varejo, etc.

Os modelos em espaço de estados são compostos por duas equações vetoriais que explicitam a relação existente entre estes três vetores (y_t , ξ_t e x_t), levando em conta a relação dinâmica entre eles. A primeira equação, denominada *equação de estado* ou *de transição*, representa a dinâmica do vetor de estados ξ_t – que é não observável e será estimado pelo filtro – e sua relação com o vetor de variáveis exógenas x_t . A segunda equação vetorial, chamada de *equação de medida* ou *das observações*, relaciona o vetor que contém as observações (y_t) com o vetor de estado (ξ_t).

A representação em espaço de estados de y_t para $t = 1, \dots, T$, onde T é o número de observações da amostra, é dada pelo seguinte sistema de equações vetoriais:

$$\xi_t = F\xi_{t-1} + Ax_t + v_t \quad (3.1)$$

$$y_t = H\xi_t + w_t \quad (3.2)$$

onde F , A e H são matrizes dos parâmetros de dimensões $(r \times r)$, $(r \times k)$ e $(n \times r)$, respectivamente, as quais não variam com o tempo nessa exposição simplificada, mas podem ser variantes no tempo em formulações mais gerais. De fato, esse é o caso do modelo de interpolação que será aplicado nesse trabalho, onde H será uma matriz tempo-variante para a construção das séries mensais do PIB.

As equações (3.1) e (3.2) possuem termos de erro v_t e w_t , respectivamente, que são assumidos como ruído branco com distribuição Normal multivariada para fins de estimação, da seguinte forma:

$$\begin{pmatrix} v_t \\ w_t \end{pmatrix} \sim \mathcal{N} \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} Q & 0 \\ 0 & R \end{pmatrix} \right) \quad (3.3)$$

onde Q e R são as matrizes de variância-covariância de v_t e w_t , respectivamente. Além disso, os distúrbios são assumidos como sendo não correlacionados em todos os *lags*, ou seja:

$$E(v_t w_\tau') = 0 \quad \text{para todo } t \text{ e } \tau. \quad (3.4)$$

Essa formulação torna (3.1) e (3.2) um sistema linear Gaussiano condicional no qual a estimação e previsão das equações do modelo podem se basear. As matrizes de coeficientes F , A e H , além das matrizes de variância-covariância, Q e R , podem ser estimadas de forma consistente pela maximização condicional da função de log-verossimilhança do sistema. Basta, para tanto, dar as condições iniciais para o vetor de estados ($\xi_{1|0}$) e para sua matriz de variância-covariância, denotada $P_{1|0}$, conforme será apresentado em seguida. Por ora, vamos assumir que os valores particulares de tais matrizes são conhecidos.

3.2 Filtragem e suavização

Considere que foram observados os valores amostrais do PIB trimestral para o período $t = 1, \dots, T$, (y_1, y_2, \dots, y_T) , bem como das variáveis auxiliares, (x_1, x_2, \dots, x_T) . Um dos objetivos dessa abordagem é usar as informações observadas para estimar os valores do vetor de estados (ξ_t), que é não observável e representa o PIB mensal, em cada instante do tempo. Seja \mathcal{I}_{t-1} o conjunto de informação das séries observadas $y_1, x_1, y_2, x_2, \dots, y_{t-1}, x_{t-1}$ até o período $t - 1$. Ainda, denote a previsão condicional do vetor de estados usando as informações até $t - 1$ por:

$$\hat{\xi}_{t|t-1} = \hat{E}[\xi_t | \mathcal{I}_{t-1}] \quad (3.5)$$

O filtro de Kalman calcula as projeções lineares para o vetor de estados recursivamente, gerando $\hat{\xi}_{1|0}, \hat{\xi}_{2|1}, \dots, \hat{\xi}_{T|T-1}$. Associada a cada uma dessas projeções está uma matriz de erro quadrático médio (EQM), representada pela seguinte matriz ($r \times r$):

$$P_{t|t-1} = E \left[(\xi_t - \hat{\xi}_{t|t-1})(\xi_t - \hat{\xi}_{t|t-1})' \right] \quad (3.6)$$

A recursão começa com o cálculo da média e variância incondicional de ξ_1 , que são expressas, respectivamente, pelas equações:

$$\hat{\xi}_{1|0} = E(\xi_1) \quad (3.7)$$

$$\mathbf{P}_{1|0} = E \{ [\hat{\xi}_1 - E(\xi_1)][\hat{\xi}_1 - E(\xi_1)]' \} \quad (3.8)$$

onde, tipicamente, estas são dadas por $\xi_{1|0} = \mathbf{0}$ e $\text{vec}(\mathbf{P}_{1|0}) = [\mathbf{I}_{r^2} - (\mathbf{F} \otimes \mathbf{F}) - (\mathbf{A} \otimes \mathbf{A})]^{-1} \times \text{vec}(\mathbf{Q})$, segundo Hamilton (1994). Então, com os valores iniciais em mãos, começa o processo iterativo através das equações a seguir, conhecidas como equações de previsão do filtro:

$$\hat{\xi}_{t|t-1} = \mathbf{F}\hat{\xi}_{t-1|t-2} + \mathbf{A}\mathbf{x}_{t-1} + \mathbf{F}\mathbf{P}_{t-1|t-2}\mathbf{H}'(\mathbf{H}\mathbf{P}_{t-1|t-2}\mathbf{H}' + \mathbf{R})^{-1}(\mathbf{y}_{t-1} - \mathbf{H}\hat{\xi}_{t-1|t-2}) \quad (3.9)$$

$$\mathbf{P}_{t|t-1} = \mathbf{F}[\mathbf{P}_{t-1|t-2} - \mathbf{P}_{t-1|t-2}\mathbf{H}'(\mathbf{H}\mathbf{P}_{t-1|t-2}\mathbf{H}' + \mathbf{R})^{-1}\mathbf{H}\mathbf{P}_{t-1|t-2}]\mathbf{F}' + \mathbf{Q} \quad (3.10)$$

O valor $\hat{\xi}_{t|t-1}$, denota a melhor previsão para $\xi_{t|t-1}$ baseada em duas constantes e uma função linear de $(\mathbf{y}_{t-1}, \mathbf{y}_{t-2}, \dots, \mathbf{y}_1)$. A matriz $\mathbf{P}_{t|t-1}$ mostra o EQM desta previsão. Já a projeção para \mathbf{y}_t , com base no conjunto de informação até o período $t - 1$ (\mathcal{I}_{t-1}), o que inclui a previsão feita pela equação (3.9), ou seja, $\hat{\xi}_{t|t-1}$, é dada por:

$$\hat{\mathbf{y}}_{t|t-1} = \hat{E}(\mathbf{y}_t|\mathcal{I}_{t-1}) = \mathbf{H}\hat{\xi}_{t|t-1} \quad (3.11)$$

onde o EQM associado a (3.11) é:

$$E[(\mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1})(\mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1})'] = \mathbf{H}\mathbf{P}_{t|t-1}\mathbf{H}' + \mathbf{R} \quad (3.12)$$

A cada passagem do filtro, com a observação do \mathbf{y}_t , procede-se ao cálculo do erro de projeção, ou seja, a diferença entre o verdadeiro valor de \mathbf{y}_t e o previsto pela equação (3.11). Isso vale para os períodos de tempo, $t = 1, 2, \dots, T - 1$. Em seguida, a previsão feita para o vetor de estados ($\hat{\xi}_{t|t-1}$) com as equações (3.9) e (3.10) é atualizada para levar em conta a chegada da observação de \mathbf{y}_t . O processo ocorre através das seguintes equações, chamadas de equações de atualização:

$$\hat{\xi}_{t|t} = \hat{\xi}_{t|t-1} + \mathbf{P}_{t|t-1}\mathbf{H}'(\mathbf{H}\mathbf{P}_{t|t-1}\mathbf{H}' + \mathbf{R})^{-1}(\mathbf{y}_t - \mathbf{H}\hat{\xi}_{t|t-1}) \quad (3.13)$$

$$\mathbf{P}_{t|t} = \mathbf{P}_{t|t-1} - \mathbf{P}_{t|t-1}\mathbf{H}'(\mathbf{H}\mathbf{P}_{t|t-1}\mathbf{H}' + \mathbf{R})^{-1}\mathbf{H}\mathbf{P}_{t|t-1} \quad (3.14)$$

sendo que a equação (3.14) é o EQM associado à equação (3.13). Com o vetor de estados atualizado, a próxima projeção de \mathbf{y}_t será melhorada.

O processo é repetido iterativamente ao longo de toda a amostra, retornando ao final as estimativas dos parâmetros contidos nas matrizes \mathbf{F} , \mathbf{A} , \mathbf{H} , \mathbf{Q} e \mathbf{R} , além da posição do vetor de estados (ξ_t) em cada instante do tempo.

Quando o objetivo é estimar o vetor de estados (ξ_t), há dois modos de proceder utilizando o filtro de Kalman: (i) usando somente as observações disponíveis até o período $t - 1$ ($\mathbf{y}_1, \mathbf{x}_1, \mathbf{y}_2, \mathbf{x}_2, \dots, \mathbf{y}_{t-1}, \mathbf{x}_{t-1}$), chamada de estimativa filtrada de ξ_t ; ou (ii) usando todo o conjunto de observações disponível ($\mathbf{y}_1, \mathbf{x}_1, \mathbf{y}_2, \mathbf{x}_2, \dots, \mathbf{y}_T, \mathbf{x}_T$), que é chamada de estimativa suavizada. A etapa de suavização consiste em repetir o

processo iterativo descrito acima, porém de forma retroativa, onde os valores iniciais dessa etapa são os finais da primeira passagem do filtro ($\hat{\xi}_{T|T}$ e $P_{T|T}$). Em outras palavras, o filtro será passado de trás para frente. Ambos os modos de estimação são representados, respectivamente, por:

$$\hat{\xi}_{t|t-1} = \hat{E} [\xi_t | \mathbf{y}_1, \mathbf{x}_1, \dots, \mathbf{y}_{t-1}, \mathbf{x}_{t-1}] \quad (3.15)$$

$$\hat{\xi}_{t|T} = \hat{E} [\xi_t | \mathbf{y}_1, \mathbf{x}_1, \dots, \mathbf{y}_T, \mathbf{x}_T] \quad (3.16)$$

3.3 Estimação

Assumindo que os erros $\begin{pmatrix} v_t \\ w_t \end{pmatrix}$ possuem uma distribuição Normal multivariada, como explicitado na equação (3.3), pode-se encontrar uma forma funcional bem definida para a função de verossimilhança do sistema. Dessa forma, através da maximização da função de verossimilhança, é possível obter estimativas consistentes e eficientes dos parâmetros contidos nas matrizes F , A e H , e também para as duas matrizes de variância-covariância Q e R . A suposição de normalidade faz com que a distribuição condicional de $\mathbf{y}_t | \mathcal{I}_{t-1}$ também possua uma distribuição normal, a qual pode então ser usada para a montagem da função de verossimilhança amostral. Para facilitar a maximização, utiliza-se uma transformação logarítmica conforme a representação abaixo:

$$\begin{aligned} \sum_{t=1}^T \ln(f_t) &= \sum_{t=1}^T \ln[f_{\mathbf{y}_t | \mathcal{I}_{t-1}}(\cdot)] \\ &= \sum_{t=1}^T -\frac{n}{2} \ln(2\pi) - \frac{1}{2} \ln |\mathbf{H} \mathbf{P}_{t|t-1} \mathbf{H}' + \mathbf{R}| \\ &\quad - \frac{1}{2} (\mathbf{y}_t - \mathbf{H} \xi_{t|t-1})' (\mathbf{H} \mathbf{P}_{t|t-1} \mathbf{H}' + \mathbf{R})^{-1} (\mathbf{y}_t - \mathbf{H} \xi_{t|t-1}) \end{aligned} \quad (3.17)$$

onde $f_{\mathbf{y}_t | \mathcal{I}_{t-1}}(\cdot)$ representa a função de densidade condicional de $\mathbf{y}_t | \mathcal{I}_{t-1}$. As expressões para $\xi_{t|t-1}$ e $P_{t|t-1}$ são dadas por (3.9) e (3.10), respectivamente.

3.4 Nowcasting

Com a maximização da função de log-verossimilhança amostral, dada pela equação (3.17), teremos em mãos as estimativas dos parâmetros das matrizes F , A , H , Q e R , além das observações de \mathbf{y}_t e \mathbf{x}_t para o período $t = 1, 2, \dots, T$, as quais foram usadas na maximização. Conforme já argumentado, há um período considerável de atraso nas divulgações do PIB e, além disso, sua frequência é apenas trimestral. Assim, quando obtemos os dados do PIB trimestral em T (englobando os meses $T-2$, $T-1$ e T), pelo calendário já estamos três meses ou mais à frente, ou seja, em $T+3$ ou além.

No entanto, já existem séries mensais coincidentes disponíveis da atividade econômica referentes a esse período em que o PIB é contabilizado pelos órgãos responsáveis. Portanto, conforme destacado por Issler e Notini (2016), embora estimar o PIB com base nas séries coincidentes disponíveis seja referido como um problema de *nowcasting* em função do tempo do calendário, do ponto de vista econométrico, o que se faz é uma previsão fora da amostra com base em algumas realizações das séries em x_t .

Para se iniciar o procedimento de *nowcasting*, o ponto de partida é o vetor de estados suavizado no final da amostra, $\hat{\xi}_{T|T}$. Com isso, através da equação (3.1), temos que:

$$\hat{\xi}_{T+1|T} = F\hat{\xi}_{T|T} + Ax_{T+1} \quad (3.18)$$

Agora, pode se fazer a previsão para y_{T+1} usando a projeção para $\xi_{T+1|T}$ feita em (3.18). Com base na equação (3.11):

$$E[\hat{y}_{T+1}|\mathcal{I}_T] = H\hat{\xi}_{T+1|T} \quad (3.19)$$

Assim, (3.18) e (3.19) completam as previsões um passo a frente. A partir de então, novas observações dos x 's estarão disponíveis, mas as informações de y ainda se manterão em $t = T$. A estrutura recursiva dada pelas equações (3.9), (3.10) e (3.11) pode então ser usada para produzir *nowcasts* para $T + 2$:

$$E[\hat{y}_{T+2}|\mathcal{I}_T] = H\hat{\xi}_{T+2|T} \quad (3.20)$$

$$\begin{aligned} \hat{\xi}_{T+2|T+1} = & F\hat{\xi}_{T+1|T} + Ax_{T+2} + FP_{T+1|T}H' (HP_{T+1|T}H' + R)^{-1} \\ & \times \left(E[\hat{y}_{T+2}|\mathcal{I}_T] - H\hat{\xi}_{T+2|T} \right) \end{aligned} \quad (3.21)$$

sendo que $P_{T+1|T}$ pode ser obtido por (3.10):

$$P_{T+1|T} = F \left[P_{T|T-1} - P_{T|T-1}H' (HP_{T|T-1}H' + R)^{-1} HP_{T|T-1} \right] F' + Q \quad (3.22)$$

mostrando que, dada a estimativa no final da amostra $P_{T|T-1}$, pode se obter imediatamente $P_{T+1|T}$ desde que se possua estimativas de F , H , Q e R . O mesmo procedimento feito para $T + 2$ pode ser feito para $T + h$, com $h = 3, 4, \dots$, enquanto estiverem disponíveis as observações de x_t até $T + h$, sendo h o número de observações adicionais de x_t com relação ao PIB mensal. Dessa forma, o problema de *nowcasting* está completo.

3.5 Modelo global para interpolação

Em primeiro lugar, cabe aqui uma observação de cautela quanto ao uso do termo *interpolação*, a qual foi feita por Harvey (1989) ao abordar os problemas relacionados a séries com intervalos temporais distintos, como distribuição, interpolação e agregação

temporal. A estimação de pontos entre observações é denominada de *interpolação* quando trabalhamos com variáveis de *estoque*, isto é, que podem ser medidas em um particular ponto do tempo. Como o PIB é uma variável de *fluxo*, ou seja, que envolve um intervalo de tempo, o que faremos será uma *distribuição* dos valores observados entre os meses do trimestre, utilizando para isso séries coincidentes auxiliares. Apesar desta distinção técnica, conforme destacado por Issler e Notini (2016), diversos autores ainda usam o termo *PIB interpolado* para se referir à construção de uma série mensal com base nos valores trimestrais observados do PIB. Portanto, esse termo já está integrado à literatura e também será usado neste trabalho.

A metodologia de interpolação que será usada aqui foi proposta por Bernanke, Gertler e Watson (1997) e envolve um modelo geral em espaço de estados que engloba diversas modelos de interpolação, como Chow e Lin (1971), Fernández (1981) e Mitchell e Jones (2005), por exemplo. A mesma abordagem foi usada por Mönch e Uhlig (2005) para construir um PIB mensal para a Zona do Euro e será usada como ponto de partida para a descrição a seguir.

Considere o seguinte modelo de regressão dinâmico:

$$\begin{aligned} (1 - \phi(L))y_t^+ &= x_t\beta + u_t \\ u_t &= \rho u_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \mathcal{N}(0, \sigma^2) \end{aligned} \quad (3.23)$$

onde y_t^+ representa o PIB mensal não observado; $\phi(L)$ é um polinômio de defasagem de ordem p ; x_t são as observações de um conjunto de séries mensais coincidentes relacionadas; e u_t é o termo de erro que é assumido como um processo AR(1). As covariáveis no modelo de regressão contidas em x_t , quando colocadas em bases trimestrais, devem ter uma alta correlação com o série do PIB que será interpolada, pois grande parte do comportamento desta vem dessas séries auxiliares. Algumas candidatas a serem testadas são a produção industrial e as vendas no varejo, por exemplo.

É imposto aqui que o PIB trimestral (denotado por y_t), que só é observado nos meses $t = 3, 6, 9, 12, \dots, T$, é a soma dos três valores mensais não observados correspondentes ao trimestre. Para os outros valores de t ele é nulo. Formalmente:

$$y_t = \begin{cases} \sum_{i=0}^2 y_{t-i}^+, & t = 3, 6, 9, 12, \dots, T \\ 0, & \text{caso contrário.} \end{cases} \quad (3.24)$$

Vale destacar que escrever $y_t = 0$ para os meses em que não observamos o PIB é uma forma de tornar o PIB trimestral observável na frequência mensal. A agregação do PIB mensal também pode ser feita através da média dos y_t^+ 's, isto é, $y_t = \frac{1}{3} \sum_{i=0}^2 y_{t-i}^+$. Independente da forma utilizada, até o período T , todas as estimativas para os valores mensais do PIB são obtidas com a restrição de que a soma dos três meses devem igualar o valor observado no trimestre. Observe que não há termo de erro na equação (3.24).

Nos modelos que utilizam o filtro de Kalman para trabalhar com séries de diferentes frequências, um valor fictício geralmente é assumido para as observações faltantes, sendo que zero é a escolha mais frequente. O passo crucial, segundo Issler e Notini (2016), é determinar que esse valor fictício tenha uma variância muito grande, de modo que seja descontado e sobrescrito pelo filtro. Foi dessa maneira que os trabalhos de Bernanke, Gertler e Watson (1997), Mönch e Uhlig (2005) e, posteriormente, Issler e Notini (2016) procederam.

Assumindo que o polinômio $(1 - \phi(L))$ é de ordem 1, ou seja, $p = 1$, e possui coeficiente ϕ , a forma em espaço de estados do problema é dada por:

$$\xi_t = \begin{pmatrix} y_t^+ \\ y_{t-1}^+ \\ y_{t-2}^+ \\ u_t \end{pmatrix} = \begin{pmatrix} \phi & 0 & 0 & \rho \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & \rho \end{pmatrix} \begin{pmatrix} y_{t-1}^+ \\ y_{t-2}^+ \\ y_{t-3}^+ \\ u_{t-1} \end{pmatrix} + \begin{pmatrix} x_t \beta \\ 0 \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} \varepsilon_t \\ 0 \\ 0 \\ \varepsilon_t \end{pmatrix} \quad (3.25)$$

$$y_t = \mathbf{H}_t \xi_t \quad (3.26)$$

onde (3.25) e (3.26) representam as equações de estado e de observações, respectivamente, ou seja, são análogas a (3.1) e (3.2), e a matriz \mathbf{H}_t varia com o tempo, assumindo o seguinte formato:

$$\mathbf{H}_t = \begin{cases} \begin{bmatrix} 1 & 1 & 1 & 0 \end{bmatrix}, & t = 3, 6, 9, 12, \dots, T \\ \begin{bmatrix} 0 & 0 & 0 & 0 \end{bmatrix}, & \text{caso contrário.} \end{cases} \quad (3.27)$$

Um outro problema surge na definição dos valores iniciais para os parâmetros β , ρ , e também para a variância de u_t , que são necessários no procedimento do filtro de Kalman. A solução proposta por Mönch e Uhlig (2005) foi agregar as variáveis presentes em x_t da frequência mensal para a trimestral e, posteriormente, rodar uma regressão por mínimos quadrados (OLS) de y_t contra seus valores defasados (*lags*) e x_t na frequência trimestral, conforme a equação (3.23). Essa regressão produziria valores iniciais objetivos desejados para β , ϕ e para a variância de u_t . Com uma nova regressão entre os resíduos e seus valores defasados, isto é, u_t e u_{t-1} , é possível obter uma estimativa para ρ .

Conforme já mencionado, uma das grandes vantagens do método proposto por Bernanke, Gertler e Watson (1997) é englobar diversos modelos de interpolação que são baseados em espaço de estados. Através de simples restrições impostas aos parâmetros das equações (3.25) e (3.26), chegamos a seis modelos diferentes a serem testados, os quais estão listados na Tabela 1¹.

¹ Os modelos presentes na Tabela 1 serão estimados no *software R* (R Core Team, 2017) com a utilização do pacote MARSS (HOLMES; WARD; WILLS, 2014).

Tabela 1 – Modelos resultantes como função de ϕ e ρ na equação (3.25)

Modelo	Descrição	ϕ	ρ
M1	Estático em nível com resíduos IID	0	0
M2	Estático em nível com resíduos AR(1) (CHOW; LIN, 1971)	0	livre
M3	Estático em 1ª diferença com resíduos IID (FERNÁNDEZ, 1981)	0	1
M4	Dinâmico em nível com resíduos IID (MITCHELL; JONES, 2005)	livre	0
M5	Dinâmico em 1ª diferença com resíduos IID	livre	1
M6	Dinâmico em nível com resíduos AR(1)	livre	livre

Fonte: Mönch e Uhlig (2005, p. 64).

Elaboração: autor.

3.6 Qualidade do ajustamento para modelos interpolados

Para testar a qualidade do ajustamento do modelo de interpolação, Bernanke, Gertler e Watson (1997) propuseram o uso de duas medidas de R^2 . Seja $\widehat{y_{t|T}^+}$ a estimativa suavizada do PIB mensal, $\widehat{u_{t|T}}$ a estimativa suavizada para o termo de erro u_t , e $VAR(\cdot)$ a variância. Os autores definiram as seguintes estatísticas:

$$R_{\text{nível}}^2 = \frac{VAR(\widehat{y_{t|T}^+})}{VAR(\widehat{y_{t|T}^+}) + VAR(\widehat{u_{t|T}})} \quad (3.28)$$

$$R_{\text{dif}}^2 = \frac{VAR(\Delta\widehat{y_{t|T}^+})}{VAR(\Delta\widehat{y_{t|T}^+}) + VAR(\Delta\widehat{u_{t|T}})} \quad (3.29)$$

Segundo Bernanke, Gertler e Watson (1997), é mais informativo reportar o R^2 em primeira diferença pois a mesma estatística em nível fica sempre próxima à unidade em função das tendências positivas das séries. Assim, serão testados todos os modelos listados na Tabela 1 e comparados com base em seus respectivos R^2 's, escolhendo-se aquele que melhor se ajustar. Todos as especificações serão estimadas através da Maximização da Verossimilhança usando o filtro de Kalman. Para cada modelo, a estimativa suavizada de ξ_t será a sequência interpolada do PIB mensal.

3.7 Algoritmo de datação de ciclos: Bry e Boschan (1971)

Criado a pedido do NBER, o algoritmo de Bry e Boschan (1971) é um dos métodos mais usados para se determinar picos (máximos locais) e vales (mínimos locais) em séries temporais individuais. Exemplos de sua aplicação podem ser encontrados em Hollauer, Issler e Notini (2009), Morais (2013), Mönch e Uhlig (2005) e Duarte, Issler e Spacov (2004). O procedimento pode ser resumido em seis passos:

1. Determinação e substituição de *outliers*;

2. Determinação de *turning points* (TPs) numa curva de média móvel de 12 meses;
3. Refinamento dos TPs determinados no item 2 com o uso da Curva de Spencer;
4. Refinamento dos TPs no passo 3 com o uso de uma série de médias móveis cujo número de meses é determinado pelo critério de “Meses de Dominância Cíclica”;
5. Identificação de máximos e mínimos locais na série original (sem suavização);
6. Restrições de duração (15 meses para um ciclo completo e 5 meses para uma fase de ciclo).

Através do algoritmo descrito acima serão determinados os pontos de inflexão do PIB com frequência mensal e com isso os ciclos de expansão e recessão para a economia do Rio Grande do Sul.

4 RESULTADOS EMPÍRICOS

4.1 Dados

Um dos passos fundamentais no processo de interpolação é a escolha das séries coincidentes que serão utilizadas, pois elas serão a fonte de informação que dará a estimativa do PIB nos meses em que ele não é observado. De acordo com Issler e Notini (2016), as séries devem atender a dois requisitos para entrar no modelo:

1. Estar disponíveis na frequência desejada para o PIB interpolado, que neste trabalho é mensal, e serem divulgadas em tempo hábil, ou seja, com pouca defasagem após o término do período de referência.
2. Ter alta correlação com o PIB.

O primeiro passo foi buscar séries que cumpram o primeiro requisito e que estejam disponíveis para o período desejado, para depois verificar se as mesmas guardam alta correlação com o PIB. A escassez de séries de dados longas e de alta frequência dificulta os trabalhos aplicados com séries temporais no Brasil, ainda mais quando o objeto de análise são as Unidades da Federação. A pesquisa envolveu séries mensais que englobam o período entre janeiro de 2002 e junho de 2017, dado que o PIB trimestral do RS, calculado pela Fundação de Economia e Estatística do Rio Grande do Sul (FEE) em parceria com o IBGE, está disponível no momento do 1ºT/2002 ao 1ºT/2017. Vale ressaltar que as séries coincidentes que excedem o período de observação do PIB, ou seja, relacionadas aos meses de abril, maio e junho de 2017, serão utilizadas para o exercício de *nowcasting*, trazendo uma estimativa para o resultado do segundo trimestre antes da divulgação do verdadeiro valor.¹

Além da frequência e disponibilidade temporal, as séries candidatas devem ser divulgadas de forma tempestiva, ou seja, pouco tempo após o encerramento do trimestre de referência. Caso contrário, uma das vantagens do método proposto, que é ter uma estimativa do PIB antes de sua divulgação, perde o sentido. Como critério, foram descartadas séries com defasagem de divulgação de mais de 60 dias. Portanto, a fim de antecipar o resultado do PIB gaúcho do segundo trimestre de 2017 (abr-mai-jun), os dados mensais considerados para a interpolação serão os divulgados até o final de agosto.

As séries pré-selecionadas que atendem ao primeiro requisito encontram-se na Tabela 2. Todas elas são séries coincidentes relacionadas com o ciclo de negócios do Rio Grande do Sul. São sete variáveis relativas à atividade industrial (*pro_ind*, *IDI_ind*, *fat_ind*, *emp_ind*, *hor_ind*, *uci_ind* e *com_ind*), uma referente ao comércio varejista

¹ Esse trabalho foi redigido no final do mês de agosto de 2017 e a divulgação do PIB trimestral do RS para o 2ºT/2017 está prevista para o dia 13 de setembro de 2017, de acordo com a FEE.

(ven_var), duas de comércio internacional (exp_tot e imp_tot), uma de emprego formal (empf_tot) e uma de arrecadação de ICMS do governo estadual (arr_icms). No Anexo A, o Gráfico A.1 mostra a série do PIB trimestral do Rio Grande do Sul, enquanto o Gráfico A.2 apresenta as séries pré-selecionadas a entrarem no modelo de interpolação.

Tabela 2 – Variáveis pré-selecionadas para o modelo de interpolação

Sigla adotada	Descrição da variável	Fonte	Tempestividade (em dias) ⁽¹⁾
pro_ind	Produção industrial	IBGE	35
IDI_ind	Índice de desempenho industrial	FIERGS	30
fat_ind	Faturamento real da indústria	FIERGS	30
emp_ind	Nível de emprego industrial	FIERGS	30
hor_ind	Horas trabalhadas na produção da indústria	FIERGS	30
uci_ind	Utilização da capacidade instalada da indústria	FIERGS	30
com_ind	Compras industriais reais	FIERGS	30
ven_var	Volume de vendas no comércio varejista	IBGE	45
exp_tot	Exportações totais em US\$ correntes	MDIC ⁽²⁾	10
imp_tot	Importações totais em US\$ correntes	MDIC ⁽²⁾	10
empf_tot	Nível de emprego formal	MTb	20
arr_icms	Arrecadação de ICMS	MF	30

Elaboração: autor.

(1): Defasagem de publicação após o término do mês de referência.

(2): Dados tabulados e divulgados pela FIERGS.

Cabem aqui algumas considerações sobre as séries pré-selecionadas que são candidatas a entrarem como auxiliares no modelo:

- 1. Indústria:** Das sete séries referentes ao setor industrial, cinco foram extraídas da pesquisa Indicadores Industriais produzida mensalmente pela Federação das Indústrias do Rio Grande do Sul (FIERGS), em parceria com a Confederação Nacional da Indústria (CNI): fat_ind, emp_ind, hor_ind, uci_ind e com_ind. Além destas, outra variável utilizada oriunda da FIERGS é o Índice de desempenho industrial (IDI_ind), um indicador construído pela técnica de Análise de Componentes Principais (ACP) que utiliza as cinco séries listadas acima e também a Massa Salarial real da indústria para sintetizar o desempenho do setor, sendo uma espécie de termômetro acerca dos múltiplos aspectos que se verificam nas operações correntes das empresas industriais do estado². Por fim, a série de produção é extraída da Pesquisa Industrial Mensal de Produção Física (PIM-PF), do IBGE.

² A série de Massa Salarial real tem início em 2006, motivo de sua não inclusão nas investigações deste trabalho.

2. **Vendas no varejo:** a série do volume de vendas no comércio varejista do Rio Grande do Sul (ven_var) foi extraída da Pesquisa Mensal do Comércio (PMC), do IBGE. Os dados referem-se ao varejo restrito e, diferentemente da série de varejo ampliado, não incluem as vendas de materiais de construção, veículos, motos e peças³.
3. **Comércio exterior:** os dados de exportações (exp_tot) e importações (imp_tot) para o total da economia gaúcha, em sua forma bruta, tem como fonte primária o Ministério do Desenvolvimento, Indústria e Comércio Exterior (MDIC), que disponibiliza as informações no Sistema Alice Web. O trabalho de tabulação e agregação dos dados em diversas aberturas, como por exemplo por setores de atividade (CNAE 2.0), categorias de uso e agronegócio, é feito pela FIERGS.
4. **Emprego formal:** a variável de emprego formal foi construída com a utilização de duas bases de dados do Ministério do Trabalho (MTb): (i) a Relação Anual de Informações Sociais (RAIS), que contém informações sobre o estoque de vínculos com carteira assinada em dezembro de cada ano; e (ii) o Cadastro Geral de Empregados e Desempregados (CAGED), que registra mensalmente as movimentações (admissões e desligamentos) dos vínculos regidos pela Consolidação das Leis do Trabalho (CLT). Assim, o nível mensal de emprego formal para o total da economia do RS (emp_tot) é a atualização do estoque de vínculos obtido na RAIS pelo saldo das movimentações – diferença entre admissões e desligamentos – verificado no CAGED.
5. **Arrecadação de ICMS:** a série de arrecadação do governo estadual com o Imposto sobre Circulação de Mercadorias e Serviços (ICMS), arr_icms, foi obtida junto ao Sistema Gerenciador de Séries Temporais (SGS) do Banco Central, tendo como fonte dos dados o Conselho Nacional de Política Fazendária (COTEPE), órgão do Ministério da Fazenda. Os valores foram deflacionados pelo IPCA da Região Metropolitana de Porto Alegre.

4.2 Testes para seleção das séries coincidentes

Após a pré-seleção das variáveis, o próximo passo foi testar se as séries candidatas possuem alguns requisitos estatísticos desejados. Seguindo as etapas de Issler e Notini (2016), os critérios utilizados para a escolha das séries foram: (i) ter a mesma ordem de integração que o PIB; (ii) ter alta correlação com o PIB; e (iii) possuir uma relação de longo prazo com o PIB (cointegração). Primeiramente, antes de qualquer avaliação, todas as séries coincidentes foram transformadas em número índice com base fixa na média de 2002 e ajustadas sazonalmente pelo método X13-ARIMA-SEATS,

³ A série de varejo ampliado para o Rio Grande do Sul tem início em 2004.

utilizando como controle adicional na dessazonalização o número de dias úteis de cada mês (U.S. Census Bureau, 2015).

Em seguida, foram aplicados testes de raiz unitária para verificar se as séries possuem a mesma ordem de integração que o PIB. Os resultados dos testes de Dickey-Fuller Aumentado (ADF) aplicados nas séries em logaritmo estão reportados na Tabela 3. Como pode ser observado, em nível, todas as séries apresentam evidências a favor da não rejeição da hipótese nula de raiz unitária em ao menos uma especificação do teste ADF, indicando que são não-estacionárias. Já para os testes aplicados às primeiras diferenças, os resultados apontam para a rejeição da hipótese nula de raiz unitária em todas as séries, indicando a estacionariedade das mesmas e, portanto, que são integradas de primeira ordem $I(1)$. Desse modo, todas as séries pré-selecionadas possuem a mesma ordem de integração que o PIB, ou seja, são $I(1)$, em ao menos uma especificação do teste ADF.

Tabela 3 – Testes de raiz unitária ADF

Variável	Em nível			Em 1ª diferença		
	Constante e tendência	Constante	None	Constante e tendência	Constante	None
PIB	-1,38	-1,34	1,46	-7,19***	-7,08***	-6,77***
pro_ind	-2,18	-2,09	-0,33	-5,61***	-5,49***	-5,53***
IDI_ind	-2,59	-1,97	-0,52	-4,95***	-4,86***	-4,85***
fat_ind	-2,12	-1,70	-0,92	-4,51***	-4,57***	-4,48***
emp_ind	-2,44	-2,37	-0,39	-4,39***	-3,93***	-3,95***
hor_ind	-2,37	-1,41	-0,84	-4,54***	-4,33***	-4,32***
uci_ind	-3,52**	-2,67*	-0,40	-5,22***	-5,28***	-5,28***
com_ind	-3,73**	-2,50	-0,23	-5,99***	-5,8***	-5,84***
ven_var	-1,51	-0,73	1,85	-3,72**	-3,75***	-3,36***
exp_tot	-2,16	-2,66*	1,39	-6,51***	-6,26***	-6,07***
imp_tot	-1,30	-2,34	0,86	-4,83***	-4,45***	-4,37***
empf_tot	-1,22	-1,71	1,04	-3,49**	-2,85*	-2,12**
arr_icms	-2,50	-1,24	1,80	-7,52***	-7,52***	-6,99***

Elaboração: autor.

Notas: (i) Todas as séries são em log e com ajuste sazonal. (ii) As defasagens foram selecionadas com base no Critério de Informação de Schwars (BIC). (iii) Os asteriscos indicam a rejeição da hipótese nula de raiz unitária a 1% (***), 5% (**) e 10% (*) de significância.

Dando sequência aos testes estatísticos, foram computados os coeficientes de correlação de Pearson entre as séries candidatas e o PIB⁴. As correlações foram aplicadas para as variáveis em nível, em 1ª diferença e para os ciclos das séries extraídas do filtro Hodrick-Prescott (HP). Como o objetivo aqui é encontrar séries que guardem relação cíclica com o PIB, as correlações em 1ª diferença e dos ciclos do

⁴ Antes de proceder aos testes de correlação e cointegração, vale destacar que as séries mensais foram agregadas para a frequência trimestral pela média dos três respectivos meses.

filtro HP são mais informativas, conforme sugerem Issler e Notini (2016). Os resultados estão reportados na Tabela 4.

Tabela 4 – Coeficientes de correlação de Pearson entre o PIB e as séries coincidentes

Variável	Nível	1ª diferença	Ciclo extraído do filtro HP
pro_ind	0,1651**	0,476***	0,7220***
IDI_ind	-0,1187**	0,449***	0,6684***
fat_ind	-0,1627**	0,424***	0,6982***
emp_ind	0,1080**	0,2994**	0,4807***
hor_ind	-0,3485***	0,4233***	0,5677***
uci_ind	-0,3297***	0,5107***	0,5666***
com_ind	-0,2009**	0,2996**	0,5598***
ven_var	0,9643***	0,2077**	0,5017***
exp_tot	0,8696***	0,3638***	0,5421***
imp_tot	0,7967***	0,1205**	0,5112***
empf_tot	0,9723***	0,3294**	0,5384***
arr_icms	0,9550***	0,1583**	0,3179**

Elaboração: autor.

Nota: Os asteriscos indicam correlação significativa a 1% (***), 5% (**) e 10% (*).

Em ambas as especificações – 1ª diferença e ciclo do filtro HP –, todas as variáveis apresentaram correlação significativa pelo teste de Pearson, sendo que os maiores coeficientes foram encontrados entre o PIB e as variáveis da indústria, as quais se destacam a produção industrial (pro_ind), o faturamento real (fat_ind), o índice de desempenho industrial (IDI_ind), a utilização da capacidade instalada (uci_ind) e as horas trabalhadas (hor_ind).

Por fim, foram realizados testes de cointegração de Johansen (1991) para verificar a existência de uma relação de longo prazo entre cada série e o PIB. Três especificações do teste foram realizadas: sem constante e sem tendência (None), somente com constante, e somente com tendência. Os resultados encontram-se na Tabela A.1, no Apêndice A. Entre as doze séries candidatas a entrarem no modelo de interpolação, seis apresentaram uma relação de cointegração significativa em alguma especificação: faturamento real da indústria (fat_ind), utilização da capacidade instalada da indústria (uci_ind), compras industriais reais (com_ind), vendas no comércio varejista (ven_var), nível de emprego formal (empf_tot) e arrecadação de ICMS (arr_icms).

Portanto, com base nas três etapas de testes descritas acima, foram escolhidas as séries que serão utilizadas nos modelos de interpolação. Além das seis variáveis que cumpriram os três requisitos – mesma ordem de integração que o PIB, correlação significativa pelo teste de Pearson e cointegração –, optou-se por incluir nas avaliações dos modelos de interpolação a série de produção industrial (pro_ind), em função dos coeficientes expressivos nos testes de correlação (1ª diferença: 0,476; ciclo do HP:

0,722) e por ser uma tradicional série coincidente muito utilizada em análises de ciclos de negócios, a despeito da não cointegração com o PIB.

Dessa forma, as sete séries que passarão às estimações são: produção industrial (pro_ind), faturamento real da indústria (fat_ind), utilização da capacidade instalada da indústria (uci_ind), compras industriais reais (com_ind), vendas no comércio varejista (ven_var), nível de emprego formal (empf_tot) e arrecadação de ICMS (arr_icms).

4.3 Resultados da interpolação

Nesta seção serão apresentados os resultados dos modelos de interpolação estimados com o filtro de Kalman para se obter uma série mensal para o PIB do RS. Também serão expostos os critérios de ajuste para a seleção do melhor modelo.

Com o objetivo de encontrar o modelo que melhor descreva o PIB mensal, foram avaliadas algumas combinações entre as variáveis oriundas das etapas anteriores. A primeira especificação testada incluiu todas as sete séries selecionadas na etapa anterior como auxiliares no modelo apresentado na seção 3.5 – que estima seis diferentes modelos de interpolação –, a qual foi chamada de Combinação C1 de variáveis. Em seguida, para as estimações posteriores foram selecionadas apenas as variáveis que se mostraram estatisticamente significativas a 10% em ao menos um dos seis modelos estimados, que foram a produção industrial (pro_ind) e utilização da capacidade instalada (uci_ind), as quais foram combinadas das três maneiras possíveis. Portanto, as combinações de variáveis testadas foram:

- **Combinação C1:** pro_ind, uci_ind, fat_ind, com_ind, ven_var, empf_tot e arr_icms.
- **Combinação C2:** pro_ind e uci_ind
- **Combinação C3:** pro_ind
- **Combinação C4:** uci_ind

Os resultados das estatísticas de ajuste R_{dif}^2 para os seis modelos (M1-M6) e as quatro especificações testadas (C1-C4), totalizando vinte e quatro estimações, estão na Tabela 5. Essa medida foi sugerida por Bernanke, Gertler e Watson (1997) como medida de acurácia da interpolação e sua forma de cálculo está descrito na seção 3.6.

Como pode ser observado na Tabela 5, somente uma estimacão, a M1 da Combinação C4, apresentou medida de ajuste menor que 0,5, indicando uma boa acurácia de praticamente todos os modelos. Para todas as combinações de variáveis, o modelo que apresentou o maior R_{dif}^2 foi o M5 que, conforme a Tabela 1, é um modelo dinâmico em 1ª diferença com resíduos IID, o qual é obtido com a imposição de $\rho = 1$ e deixando o ϕ ser estimado livremente na equação 3.25 (equação de estado).

Tabela 5 – Medidas de ajuste R_{dif}^2 dos modelos testados

Modelo	C1	C2	C3	C4
M1	0,558	0,694	0,621	0,485
M2	0,620	0,721	0,713	0,669
M3	0,714	0,709	0,712	0,674
M4	0,598	0,643	0,619	0,603
M5	0,757	0,726	0,765	0,678
M6	0,651	0,627	0,614	0,600

Elaboração: autor.

Entre os modelos M5, as combinações que revelaram os maiores valores de R_{dif}^2 foram a C3 com 0,765, que inclui como série auxiliar somente a produção industrial (pro_ind), e a C1 com 0,757, com as séries que cointegraram com o PIB e também a produção industrial. Como os valores são muito próximos, uma outra estatística que pode ser útil na avaliação dos modelos é o critério de informação de Akaike (AIC), que em sua forma de cálculo penaliza a verossimilhança para que um modelo mais parcimonioso seja selecionado, isto é, o modelo que envolva o mínimo de parâmetros possíveis a serem estimados e que explique bem o comportamento da variável resposta. Dessa forma, o modelo com menor valor de AIC é considerado o de melhor ajuste. Para os modelos em questão, o AIC para a Combinação C1 foi de 326,65, enquanto que para C3 foi um pouco menor: 322,23.

Portanto, tanto pelo critério de maior R_{dif}^2 quanto de menor AIC, o modelo M5 da Combinação C3 se mostrou o melhor para interpolação do PIB mensal do RS. A Tabela A.2 contém os parâmetros e os coeficientes estimados para os seis modelos considerando a produção industrial (C3) como série auxiliar na interpolação do PIB. Já o Gráfico 1 retrata a série do PIB trimestral observado e do PIB mensal estimado, mostrando que a evolução dos valores estimados é muito próxima aos valores observados. Cabe lembrar que, por construção do método, as variações trimestrais são exatamente iguais.

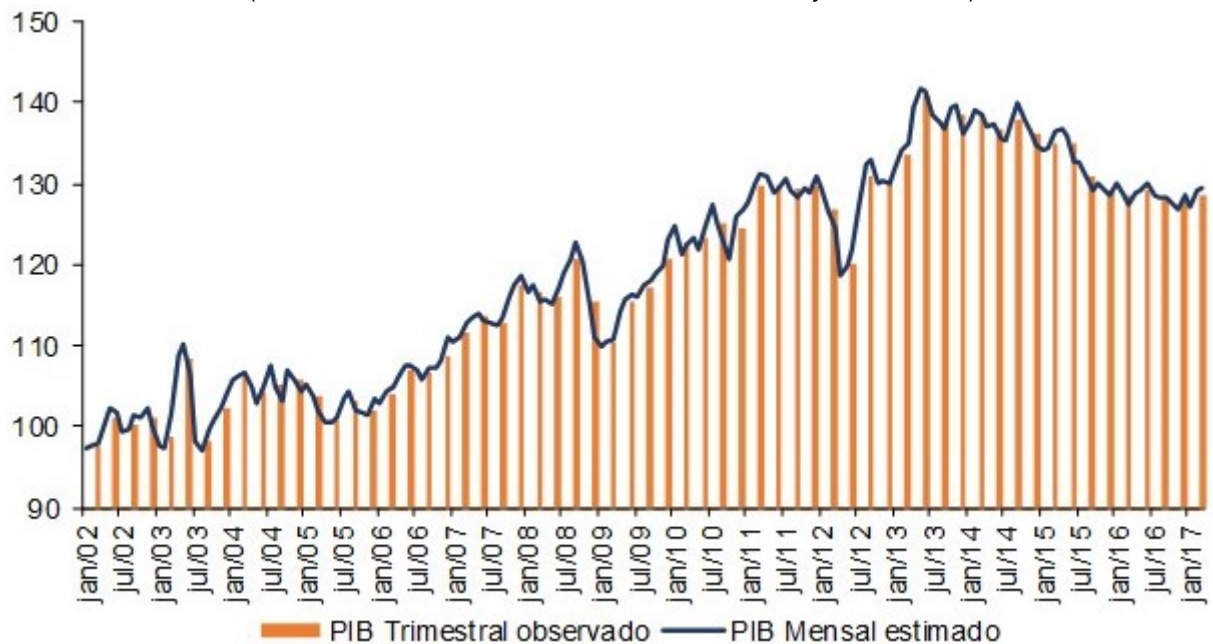
Na próxima seção, o PIB mensal interpolado será comparado, tanto em termos metodológicos quanto na sua evolução temporal, a uma *proxy* para a atividade econômica estadual calculada pelo Banco Central, o IBCR-RS.

4.4 Comparação do PIB mensal com o IBCR-RS

O PIB mensal estimado na seção anterior pode ser usado tanto por pesquisadores e acadêmicos que necessitam de uma série de alta frequência para o nível atividade da economia gaúcha, quanto em análises de ciclos econômicos para apontar o estado da economia quase que em tempo real. Neste último caso, a detecção dos

Gráfico 1 – PIB mensal estimado e PIB trimestral observado do RS – 1ºT/2002 ao 1ºT/2017

(Índice de base fixa: média 2002 = 100 – Com ajuste sazonal)



Fonte: FEE; autor.
 Elaboração: autor.

pontos de inflexão da economia pode ser feita com o uso de algoritmos, como o de Bry e Boschan (1971), que será apresentado na próxima seção.

Atualmente, existem alguns indicadores setoriais que podem ser usados como *proxy* para a atividade econômica estadual em frequência mensal, como a produção industrial do IBGE, o Índice de Desempenho Industrial (IDI-RS), calculado pela FIERGS, e as vendas no comércio varejista do IBGE. No entanto, para a economia como um todo, a única alternativa para esse propósito é um indicador calculado pelo Banco Central do Brasil, denominado Índice de Atividade Econômica Regional do Rio Grande do Sul (IBCR-RS).

O IBCR-RS é divulgado mensalmente para cinco regiões geográficas do Brasil e treze unidades da federação, com o início da série em janeiro de 2003. O indicador é construído com base em *proxies* representativas do volume da produção agropecuária, da indústria e do setor de serviços, ou seja, a partir de variáveis que compõem o lado da oferta da economia. As séries são agregadas com base nos pesos do respectivo valor adicionado da atividade, divulgados nas Contas Regionais e nas tabelas de recursos e usos do Sistema de Contas Nacionais, ambas do IBGE. Além disso, também são utilizadas outras informações de caráter estrutural obtidas na Pesquisa Industrial Anual (PIA/IBGE), na Pesquisa Anual do Comércio (PAC/IBGE), na Pesquisa Anual de Serviços (PNS/IBGE) e na Produção Agrícola Municipal (PAM/IBGE).

Quanto às principais informações conjunturais do IBCR-RS, a fonte de dados para a agricultura é o Levantamento Sistemático da Produção Agrícola (LSPA/IBGE),


onde as culturas são distribuídas mês a mês de acordo com o Censo Agropecuário de 2006 (IBGE). No setor industrial, a principal fonte é a Pesquisa Industrial Mensal Produção Física - Regional (PIM-PF Regional/IBGE), além de informações de emprego formal (RAIS/MTb e CAGED/MTb) para aproximar o desempenho da Construção Civil. Já nos Serviços, são diversas séries relativas ao comércio, serviços de transporte, serviços de informação, intermediação financeira, saúde, educação, entre outros (BCB, 2017).

Conforme apontado por Issler e Notini (2016), uma das vantagens do método proposto neste trabalho frente ao indicador calculado pelo Banco Central é computacional.⁵ Enquanto o IBCR-RS necessita de inúmeras séries temporais para ser calculado, o método empregado aqui requer apenas uma série como covariável para a interpolação. Uma segunda vantagem é a imposição, por construção do método, de que a soma de três meses do PIB mensal deve ser exatamente igual ao PIB trimestral oficial para todos os trimestres, fazendo com que a dinâmica de curto e longo prazo do PIB interpolado seja idêntica à do PIB observado. Por outro lado, o indicador do Banco Central não impõe qualquer disciplina entre seu comportamento e o nível ou a variação do PIB trimestral, de modo que os ciclos entre o IBCR-RS e o PIB não precisam ser sincronizados. Por fim, em função da representação do modelo em espaço de estados, o método pode ser facilmente utilizado para antecipar o resultado do PIB antes de sua divulgação, a partir do exercício de *nowcasting*, conforme discutido na seção 3.4.

A despeito das diferenças metodológicas descritas, as duas *proxies* para a atividade econômica do Rio Grande do Sul, quando analisadas em nível, apresentam uma evolução temporal muito similar, conforme mostra o Gráfico 2. Houve um certo descolamento entre as séries após a crise de 2008/2009, mas a dinâmica de evolução continuou parecida. De fato, a correlação entre as séries é bastante alta (0,98). O mesmo não pode ser dito quando se olha para as séries em 1ª diferença (Gráfico 3) e, principalmente, para as taxas de crescimento trimestre contra trimestre imediatamente anterior (Gráfico 4). Para esta última comparação, as séries foram agregadas para a frequência trimestral pela média. Como esperado, em função da disciplina imposta pelo método apresentado neste trabalho, a variação trimestral do PIB interpolado é exatamente igual à observada no PIB divulgado pela FEE. Já o IBCR-RS, por não guardar esta característica, apresenta alguns valores altamente discrepantes frente à variação do PIB no comparativo trimestre em relação ao trimestre anterior, como por exemplo, uma diferença de 12 pontos percentuais (p.p.) no segundo trimestre de 2002 (PIB: 9,7%; IBCR-RS: -2,3%), de 9,8 p.p. no segundo trimestre de 2012 (PIB: -5,2%; IBCR-RS: 4,6%) e, mais recentemente, uma diferença de 4,3 p.p. no primeiro trimestre de 2017 (PIB: 0,6%; IBCR-RS: 4,9%).


⁵ O trabalho de Issler e Notini (2016) fez a interpolação do PIB brasileiro e comparou com o IBC-BR, indicador análogo ao IBCR-RS, mas para a economia nacional.

Gráfico 2 – PIB mensal estimado para o RS e IBCR-RS – jan/2002 a mar/2017
(Em nível – Índice de base fixa: média 2003 = 100 – Com ajuste sazonal)




Fonte: autor; Banco Central.
Elaboração: autor.

Gráfico 3 – PIB mensal estimado para o RS e IBCR-RS – fev/2002 a mar/2017
(Em 1ª diferença – Índice de base fixa: média 2003 = 100 – Com ajuste sazonal)



Fonte: autor; Banco Central.
Elaboração: autor.

Gráfico 4 – PIB mensal estimado para o RS e IBCR-RS – 2ºT/2002 ao 1ºT/2017
(Taxa de crescimento frente ao trimestre imediatamente anterior – Com ajuste sazonal)



Fonte: autor; Banco Central.
Elaboração: autor.

4.5 Datação dos ciclos econômicos

Nesta seção será feita a cronologia dos ciclos de negócios da economia gaúcha (recessão vs. expansão) com a utilização do PIB mensal interpolado. Os pontos de inflexão serão determinados usando o algoritmo de Bry e Boschan (1971), que detecta os mínimos e máximos locais da série temporal através de seis etapas, conforme brevemente descrito na seção 3.7.⁶ Cabe lembrar que o método impõe duas restrições temporais: uma para duração das fases do ciclo (expansão ou recessão), que são de no mínimo cinco meses, e uma para a duração do ciclo completo (expansão + recessão), que deve ter no mínimo quinze meses.

A datação dos ciclos para o período de janeiro de 2002 a março de 2017, ou seja, considerando o período para o qual o PIB foi observado, encontra-se no Gráfico 5. No entanto, com a inclusão do PIB estimado para o segundo trimestre de 2017 através do exercício de *nowcasting*, que será detalhado na próxima seção, a datação para o final da série é alterada, com o encerramento de uma fase de recessão e início de uma fase de expansão, conforme ilustra o Gráfico 6. Na Tabela 6 estão detalhados os períodos de expansão e recessão, com suas características como duração, variação percentual acumulada e variação média mensal.

Segundo apresentado na Tabela 6, desde janeiro de 2002, o Rio Grande do Sul

⁶ Agradeço ao National Centre for Economic Research (NCER), da Austrália, por disponibilizar a macro para o Excel com o algoritmo programado, que encontra-se no seguinte endereço: <http://www.ncer.edu.au/resources/data-and-code.php>.

Gráfico 5 – Datação dos ciclos da economia do RS – jan/2002 a mar/2017
(Índice de base fixa: média 2002 = 100 – Com ajuste sazonal)



Elaboração: autor.

Nota: As áreas sombreadas marcam os períodos de recessão.

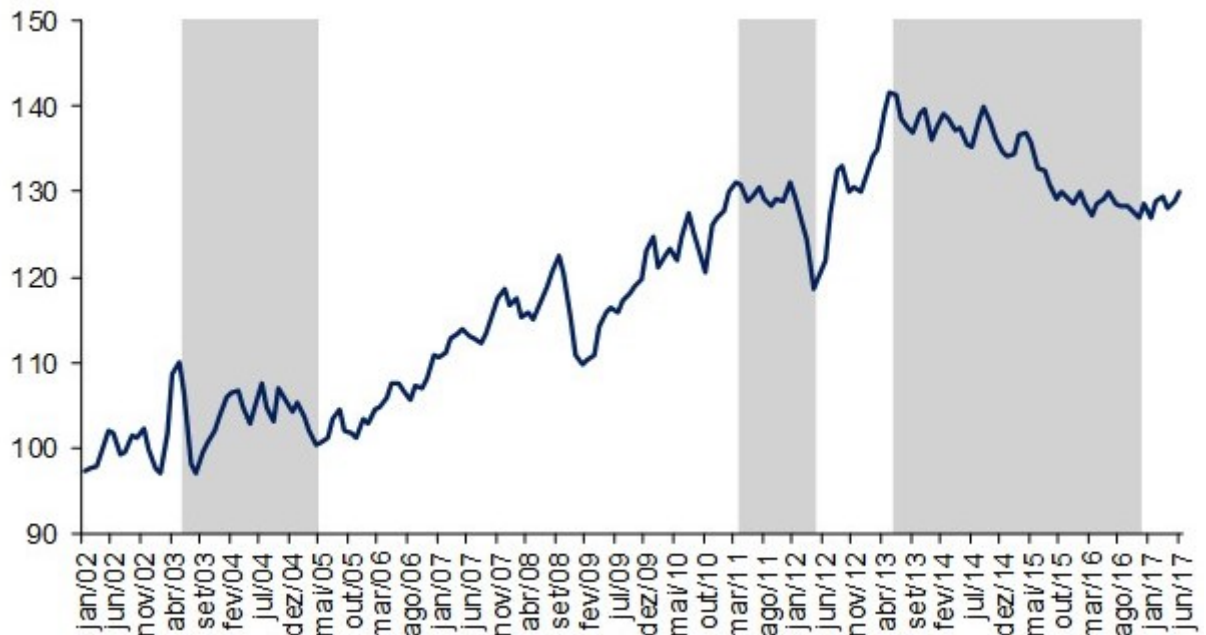
já passou por três fases de recessão. A primeira delas teve duração de 23 meses, com início em junho de 2003 e encerramento em abril de 2005, e teve como causa principal uma forte estiagem que prejudicou a produção agropecuária do estado. Segundo dados da Companhia Nacional de Abastecimento (CONAB), a produção de grãos nas safras de 2003/2004 e 2004/2005 tiveram quedas de 18,8% e 27,5%, no Rio Grande do Sul. Apesar de não ser a recessão mais curta, foi a que menos impactou a atividade no acumulado do período (-8,79%), com média mensal de queda de 0,40%.

A segunda recessão (abr/2011 a abr/2012), a menor entre as detectadas no período com duração de 13 meses, também teve como principal fator uma forte seca que derrubou a produção agrícola. De acordo com a CONAB, a produção de grãos caiu 27,5% na safra 2011/2012, mesmo com crescimento de 6,4% da área plantada. A queda do PIB acumulada no período recessivo alcançou os 9,47%, enquanto a média de 0,76% de retração mensal foi a maior entre as três recessões.

Já o terceiro e mais longo período recessivo (jun/2013 a nov/2016), com duração de 42 meses, foi também o mais intenso em termos de queda acumulada no PIB (-10,41%), causado pela crise política e pelos desequilíbrios macroeconômicos oriundos da Nova Matriz Econômica, e do seu processo de reversão em meados de 2016. Apesar da forte retração, a variação média mensal de -0,26% foi a menor entre as três recessões analisadas. Nesse período, toda a economia brasileira foi afetada, com o PIB nacional crescendo apenas 0,5% em 2014 e acumulando queda de 7,2% no biênio 2015/2016. Para o Brasil, de acordo com o Comitê de Datação de Ciclos Econômicos

Gráfico 6 – Datação dos ciclos da economia do RS com inclusão dos resultados do *nowcasting*– jan/2002 a jun/2017

(Índice de base fixa: média 2002 = 100 – Com ajuste sazonal)



Elaboração: autor.

Nota: As áreas sombreadas marcam os períodos de recessão.

Tabela 6 – Datação dos ciclos da economia do RS – jan/2002 a jun/2017

RECESSÕES				
Período		Duração em meses	Var. % acum. no período	Var. % mensal média
Mês seguinte ao pico	Vale			
jun/03	abr/05	23	-8,79%	-0,40%
abr/11	abr/12	13	-9,47%	-0,76%
jun/13	nov/16	42	-10,41%	-0,26%
EXPANSÕES				
Período		Duração em meses	Var. % acum. no período	Var. % mensal média
Mês seguinte ao vale	Pico			
jan/02	mai/03	17	13,31%	0,74%
mai/05	mar/11	71	30,55%	0,38%
mai/12	mai/13	13	19,26%	1,36%
dez/16	-	7	2,39%	0,34%

Elaboração: autor.

(CODACE/FGV), a recessão teve início no segundo trimestre de 2014 e ainda não encerrou.

Vale ressaltar que a inclusão do resultado do *nowcasting* faz o algoritmo de datação indicar o fim do período recessivo em novembro de 2016. Com as informações até março, mesmo que os dados já indicassem um possível vale na referida data, é necessário ter passado um período superior a cinco meses para a confirmação do ponto de inflexão. Além disso, os verdadeiros valores para o PIB do Rio Grande do Sul, a serem divulgados pela FEE em setembro de 2017, devem ser comparados às estimações feitas para o PIB entre abril e junho de 2017 (*nowcast*), confirmando o encerramento ou indicando a continuidade da recessão iniciada em junho de 2013.

Quanto aos períodos de expansão, cabe uma ressalva em relação ao período entre maio de 2005 e março de 2011, com duração de 71 meses e crescimento acumulado de 30,55%. Como é visível no Gráfico 6, houve uma queda significativa no PIB entre setembro de 2008 e janeiro de 2009 (-10,35%) durante a Crise Financeira Internacional. No entanto, como transcorreu um período de menos de cinco meses entre o mês seguinte ao possível pico (out/2008) e o possível vale (jan/2009), o algoritmo não aponta as duas datas como pontos de inflexão.

Caso o referido período de quatro meses fosse marcado como uma recessão, seria a segunda com maior retração acumulada, ficando apenas atrás da crise jun/2013-nov/16, mas com a maior queda mensal média (-2,70%). Além disso, o período de 71 meses de expansão seria dividido em dois: (i) entre maio de 2005 e setembro de 2008, com duração de 41 meses, crescimento acumulado de 21,91% e crescimento médio mensal de 0,48%; (ii) entre fevereiro de 2009 e março de 2011, com duração de 26 meses, crescimento acumulado de 19,33% e crescimento médio mensal de 0,67%.

4.6 *Nowcasting* do PIB

Nesta seção serão apresentados os resultados do exercício de *nowcasting* do PIB gaúcho utilizando o modelo de interpolação proposto. Este exercício objetiva antecipar o PIB de um trimestre a frente antes do conhecimento de seu verdadeiro valor. Além disso, o desempenho do modelo será comparado ao IBCR-RS.


O *nowcast* para três meses a frente foi computado conforme apresentado em detalhes na seção 3.4. Em linhas gerais, a projeção é feita com base no vetor de estados suavizado ($\xi_{T|T}$) e o uso dos coeficientes estimados da equação 3.25, tendo como fonte de informação para o comportamento do PIB nos períodos a frente a série coincidente selecionada, como apresentado nas seções 4.1 a 4.3: a produção industrial.⁷

Como pode ser observado nos Gráficos 7 e 8, os resultados do *nowcast* pelo

⁷ Os coeficientes estimados estão na Tabela A.2, no Anexo A.

modelo de interpolação se mostraram muito próximos à verdadeira variação observada no PIB trimestral. O maior erro ocorreu no terceiro trimestre de 2003, com diferença de 2,03 p.p. entre o valor estimado e PIB observado (*nowcast*: -7,29%; PIB: -9,32%). Por outro lado, o menor erro encontrado foi no segundo trimestre de 2015, onde a diferença foi de apenas 0,002 p.p. (*nowcast*: 0,085%; PIB: 0,087%). O IBCR-RS, por sua vez, apresenta diferenças significativas em alguns períodos, que chegaram aos 12,00 p.p. no segundo trimestre de 2003 (IBCR-RS: -2,34%; PIB: 9,66%) e 9,78 p.p. no segundo trimestre de 2012 (IBCR-RS: -5,16%; PIB: 4,62%). Já a menor diferença, de 0,04 p.p., foi verificada no quarto trimestre de 2016 (IBCR-RS: -0,54; PIB: -0,50), onde o *nowcast* com o modelo interpolado apresentou erro de 0,22 p.p. (*nowcast*: -0,28%).

Gráfico 7 – PIB mensal estimado, IBCR-RS e *Nowcast* – 2ºT/2002 ao 2ºT/2017
(Taxa de crescimento frente ao trimestre imediatamente anterior – Com ajuste sazonal)




Elaboração: autor; Banco Central.

Além da análise visual, outra forma de apurar se as variáveis apresentam um bom ajuste aos dados é através de medidas de acurácia. Foram calculadas duas medidas entre a taxa de crescimento frente ao trimestre anterior do PIB trimestral observado e as respectivas taxas de crescimento do IBCR-RS e do *nowcast* feito com o modelo de interpolação. A Tabela 7 apresenta os resultados do Erro Absoluto Médio (MAE, na sigla em inglês) e do Erro Quadrático Médio (MSE, na sigla em inglês) para diferentes períodos.

Nas duas medidas calculadas e para diferentes períodos, o erro do *nowcast* pelo modelo de interpolação é menor em relação ao auferido pelo IBCR-RS. Considerando o período como um todo (P1), o MAE do *nowcast* foi de 0,51, enquanto para o IBCR-RS foi de 1,93. Já o MSE, que penaliza desvios muito grandes em relação ao verdadeiro valor, apresentou um resultado significativamente mais elevado para o indicador do

Gráfico 8 – Erros de projeção um passo à frente – IBCR-RS e *Nowcast* – 1ºT/2003 ao 1ºT/2017



Elaboração: autor; Banco Central.

Banco Central (8,66 frente a 0,47 do *nowcast* com o modelo proposto). No período mais recente, com início na última recessão datada na seção anterior (P3 da Tabela 7), ambas variáveis melhoram suas previsões, apresentando diminuição tanto do MAE quanto do MSE, mas ainda se mostram altamente favoráveis ao modelo de PIB mensal.

Tabela 7 – Medidas de acurácia – PIB mensal estimado vs. IBCR-RS

Sigla	Período	MAE		MSE	
		IBCR-RS	Nowcast	IBCR-RS	Nowcast
P1	2ºT/03 – 1ºT/17	1,93	0,51	8,66	0,47
P2	2ºT/03 – 2ºT/13	2,15	0,58	10,55	0,58
P3	3ºT/13 – 1ºT/17	1,38	0,34	3,95	0,20

Elaboração: autor.

Nota: MAE (*Mean Absolute Error*); MSE (*Mean Squared Error*).

Portanto, as evidências demonstram que, de fato, o modelo de interpolação para o PIB gaúcho proposto neste trabalho é um método que se mostrou satisfatório em antecipar o resultado do PIB para o trimestre imediatamente posterior. Desse modo, como a série auxiliar utilizada no modelo de interpolação já possui observações que cobrem o período de abril a junho de 2017, o exercício de *nowcasting* foi estendido para o segundo trimestre de 2017 e os resultados já estão incluídos na ponta do Gráfico 7. O crescimento estimado pelo modelo é de 0,39% frente ao primeiro trimestre, enquanto o IBCR-RS aponta para uma queda de 1,86%.

5 CONSIDERAÇÕES FINAIS

Tendo em vista a importância de uma medida de PIB de alta frequência, que permita expressar a situação atual da atividade econômica do Rio Grande do Sul e sirva como base para a datação dos ciclos econômicos, o presente trabalho foi dividido em três objetivos.

O primeiro foi a estimação de uma série com frequência mensal para o PIB real do Rio Grande do Sul entre janeiro de 2002 e março de 2017, dado que o mesmo só é contabilizado em frequência trimestral. Para esse fim, foi estimado um modelo que utiliza séries mensais coincidentes com a atividade econômica como fonte de informação para a interpolação dos dados trimestrais do PIB, em linha com as abordagens de Bernanke, Gertler e Watson (1997), Mönch e Uhlig (2005) e Issler e Notini (2016). A *proxy* estimada para o PIB mensal é baseada em uma representação em espaço de estados que impõe a disciplina de que a soma ponderada dos três meses estimados deve ser igual ao valor do PIB trimestral observado.

O segundo objetivo foi comparar a série mensal estimada com um indicador de atividade mensal calculado pelo Banco Central do Brasil para o estado, o IBCR-RS. A comparação é feita tanto em termos metodológicos quanto sobre qual apresenta melhor desempenho em antecipar as variações do PIB trimestral antes de sua divulgação.

Por fim, com a série mensal do PIB estimada, o terceiro objetivo foi estabelecer a cronologia dos ciclos de expansão e recessão para a economia do Rio Grande do Sul. Os pontos de inflexão da atividade foram identificados com a aplicação do algoritmo de Bry e Boschan (1971).

Em primeiro lugar, foram identificadas doze séries mensais que estão disponíveis para o período desejado e que teoricamente guardam relação com o PIB. Em seguida, as variáveis candidatas a entrarem no modelo de interpolação passaram por testes de raiz unitária, de correlação e de cointegração, sendo selecionadas sete séries a serem utilizadas na etapa de estimação: produção industrial (*pro_ind*), faturamento real da indústria (*fat_ind*), utilização da capacidade instalada da indústria (*uci_ind*), compras industriais reais (*com_ind*), vendas no comércio varejista (*ven_var*), nível de emprego formal (*empf_tot*) e arrecadação de ICMS (*arr_icms*).

A estimação conjunta dos seis modelos de interpolação que o método proposto permite foi feita para quatro combinações entre as variáveis selecionadas nas etapas anteriores, sendo escolhido para fornecer a série mensal do PIB o que apresentou melhor ajuste em termos de R_{diff}^2 : M5, um modelo dinâmico em 1ª diferença com resíduos IID com somente a produção industrial (*pro_ind*) como série auxiliar.

Com a série mensal do PIB estimada, procedeu-se a comparação com o IBCR-RS, uma *proxy* para a atividade econômica estadual calculada pelo Banco Central. Além da vantagem computacional a favor do método de interpolação, pois apenas

uma série de dados precisa ser acompanhada enquanto que para o IBCR-RS são diversas séries, a imposição de disciplina de que as variações do PIB mensal devem ser exatamente iguais às do PIB trimestral faz com que a dinâmica de curto e longo prazo das variáveis sejam idênticas. Por outro lado, a despeito de o IBCR-RS apresentar evolução temporal semelhante ao PIB, em alguns trimestre a variação do indicador foi muito diferente da variação observada no PIB, chegando a alcançar 12 pontos percentuais de diferença.

A cronologia dos pontos de inflexão da atividade econômica, auferida com o método de Bry e Boschan (1971), apontou três períodos recessivos na economia gaúcha desde janeiro de 2002: jun/2003 a abr/2005 (23 meses e queda acumulada de 8,79%); abr/2011 a abr/2012 (13 meses e queda acumulada de 9,47%); e jun/2013 a nov/2016 (42 meses e queda acumulada de 10,41%). As duas primeiras ocorreram em função de fortes estiagens, com impactos na produção agrícola do estado e desdobramentos em todo o restante da economia. Já a terceira recessão ocorreu em um contexto de descontrole das finanças públicas tanto do governo federal como do governo estadual, aliada à crise política no âmbito federal. Cabe ressaltar que o encerramento da última recessão, datado em novembro de 2016, foi apontado somente com a inclusão dos resultados estimados para o segundo trimestre de 2017 pelo exercício de *nowcasting*. Os dados até março de 2017 indicavam a continuação do período recessivo.

Por fim, foi feito um exercício de *nowcasting* do PIB com o modelo de interpolação proposto e suas projeções foram comparadas à variação trimestral obtida pelo IBCR-RS. Os resultados mostraram um desempenho superior do método proposto neste trabalho em antecipar o resultado do PIB para um trimestre a frente. Para o período como um todo, o Erro Absoluto Médio (MAE) da variação projetada pelo modelo de interpolação foi de 0,51 e o Erro Quadrático Médio (MSE) de 0,47. Por outro lado, para o IBCR-RS as respectivas medidas de acurácia foram de 0,93 e 8,66.

Considerando a ampliação dessa pesquisa, uma possibilidade é realizar o mesmo exercício de interpolação para a série do PIB trimestral do Rio Grande do Sul sem ajuste sazonal. Os dados com ajuste sazonal sofrem alterações com mais frequência do que os não ajustados. Outra ideia seria trabalhar com os setores da economia, estimando a trajetória mensal para as diversas aberturas setoriais para as quais o PIB é divulgado. Finalmente, quanto aos ciclos econômicos, existem outras alternativas para a datação dos pontos de inflexão da atividade, como o método que utiliza mudança de regime markoviana proposto por Hamilton (1989).

REFERÊNCIAS

- BCB. Índice de Atividade Econômica Regional (IBCR) – revisão metodológica. *Boletim Regional*, Banco Central do Brasil, Brasília/DF, v. 11, n. 2, p. 82–85, 2017. Disponível em: <<http://www.bcb.gov.br/pec/boletimregional/port/2017/04/br201704P.pdf>>.
- BERNANKE, B. S.; GERTLER, M.; WATSON, M. Systematic monetary policy and the effects of oil price shocks. *Brookings Papers on Economic Activity No. 1*, v. 1997, n. 1, p. 91–157, 1997. ISSN 0007-2303.
- BOOT, J. C.; FEIBES, W.; LISMAN, J. H. C. Further methods of derivation of quarterly figures from annual data. *Applied Statistics*, JSTOR, p. 65–75, 1967.
- BRY, G.; BOSCHAN, C. *Cyclical Analysis of Time Series: Selected Procedures and Computer Programs*. New York, USA: NBER, 1971.
- BURNS, A. F.; MITCHELL, W. C. Measuring business cycles. *National Bureau of Economic Research (NBER)*, 1946.
- CHAUVET, M. An econometric characterization of business cycle dynamics with factor structure and regime switching. *International Economic Review*, JSTOR, v. 39, n. 4, p. 969–996, 1998.
- CHAUVET, M. Leading indicators of inflation for brazil. Working Papers Series, No. 7, Brasília: BCB. 2000.
- CHOW, G. C.; LIN, A.-I. Best linear unbiased interpolation, distribution, and extrapolation of time series by related series. *The Review of Economics and Statistics*, v. 53, n. 4, p. 372–375, 1971. ISSN 0034-6535.
- Di Fronzo, T. Temporal disaggregation of economic time series: towards a dynamic extension. *European Commission (Eurostat) - Working Papers and Studies*, v. 1, p. 41, 2003.
- DIEBOLD, F.; RUDEBUSCH, G. Measuring business cycles: A modern perspective. *The Review of Economics and Statistics*, MIT Press, v. 78, n. 1, p. 67–77, 1996.
- DUARTE, A. J. M.; ISSLER, J. V.; SPACOV, A. Indicadores coincidentes de atividade econômica e uma cronologia de recessões para o brasil. *Pesquisa e Planejamento Econômico*, v. 34, n. 1, 2004.
- FERNÁNDEZ, R. B. A methodological note on the estimation of time series. *The Review of Economics and Statistics*, v. 63, n. 3, p. 471–476, 1981. ISSN 0034-6535.
- FORNI, M.; HALLIN, M.; LIPPI, M.; REICHLIN, L. The generalized dynamic-factor model: identification and estimation. *Review of Economics and statistics*, MIT Press, v. 82, n. 4, p. 540–554, 2000.
- FORNI, M.; HALLIN, M.; LIPPI, M.; REICHLIN, L. Coincident and leading indicators for the euro area. *The Economic Journal*, Wiley Online Library, v. 111, n. 471, p. 62–85, 2001.
- GALLARDO, M.; PEDERSEN, M. *Un sistema de indicadores líderes compuestos para la región de América Latina*. Santiago, Chile: CEPAL, 2007.

HAMILTON, J. D. A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica: Journal of the Econometric Society*, JSTOR, p. 357–384, 1989.

HAMILTON, J. D. Book. *Time series analysis*. Princeton, NJ: Princeton University Press, 1994.

HARVEY, A. C. Book. *Forecasting, structural time series models and the Kalman filter*. [S.l.]: Cambridge University Press, 1989. ISBN 0521405734.

HOLLAUER, G.; ISSLER, J. V.; NOTINI, H. H. Novo indicador coincidente para a atividade industrial brasileira. *Economia Aplicada*, SciELO Brasil, v. 13, n. 1, p. 5–28, 2009.

HOLMES, E.; WARD, E.; WILLS, K. *MARSS: Multivariate Autoregressive State-Space Modeling*. [S.l.], 2014. R package version 3.9. Disponível em: <<http://cran.r-project.org/web/packages/MARSS/>>.

ISSLER, J. V.; NOTINI, H. H. Estimating brazilian monthly gdp: a state-space approach. *Revista Brasileira de Economia*, v. 70, n. 1, p. 41–59, 2016. ISSN 0034-7140. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0034-71402016000100041&nrm=iso>.

ISSLER, J. V.; VAHID, F. The missing link: Using the nber recession indicator to construct coincident and leading indices of economic activity. *Journal of Econometrics*, v. 132, n. 1, p. 281–303, 2006.

JACOBS, J. *Dividing by 4: A feasible quarterly forecasting method?* [S.l.], 1994.

MITCHELL, T. D.; JONES, P. D. An improved method of constructing a database of monthly climate observations and associated high-resolution grids. *International Journal of Climatology*, v. 25, n. 6, p. 693–712, 2005. ISSN 1097-0088.

MORAIS, I. A. C. d. Ciclo e indicadores antecedentes na indústria do rio grande do sul. *Nova Economia*, sciELO, v. 23, n. 1, p. 133–154, 2013. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-63512013000100005&nrm=iso>.

MORAIS, I. A. C. d.; PORTUGAL, M. S. Um novo índice coincidente para a atividade industrial do estado do rio grande do sul. *Estudos Econômicos (São Paulo)*, v. 37, n. 1, p. 35–70, 2007. ISSN 0101-4161. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0101-41612007000100002&nrm=iso>.

MÖNCH, E.; UHLIG, H. Towards a monthly business cycle chronology for the euro area. *Journal of Business Cycle Measurement and Analysis*, v. 2, n. 1, p. 43–69, 2005. ISSN 1729-3618.

NARDO, M.; SAISANA, M.; SALTELLI, A.; TARANTOLA, S.; HOFFMAN, A.; GIOVANNINI, E. *Handbook on constructing composite indicators*. [S.l.]: OECD publishing, 2005.

PICCHETTI, P.; TOLEDO, C. Estimating and interpreting a common stochastic component for the brazilian industrial production index. *Revista Brasileira de Economia*, SciELO Brasil, v. 56, n. 1, p. 107–120, 2002.

PROIETTI, T. Temporal disaggregation by state space methods: Dynamic regression methods revisited. *The Econometrics Journal*, [Royal Economic Society, Wiley], v. 9, n. 3, p. 357–372, 2006. ISSN 13684221, 1368423X. Disponível em: <<http://www.jstor.org/stable/23114924>>.

R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2017. Disponível em: <<https://www.R-project.org/>>.

SALAZAR, E. L.; SMITH, R. J.; WEALE, M. Interpolation using a dynamic regression model: Specification and monte carlo properties. NIESR Discussion Paper n. 126. 1997.

SALAZAR, E. L.; SMITH, R. J.; WEALE, M.; WRIGHT, S. A monthly indicator of gdp. *National Institute Economic Review*, v. 161, n. 1, p. 84–89, 1998. Disponível em: <<http://dx.doi.org/10.1177/002795019716100106>>.

SPACOV, A. D. *Índices antecedentes e coincidentes da atividade econômica brasileira: uma aplicação da análise de correlação canônica*. Dissertação (Dissertação de Mestrado) — Fundação Getúlio Vargas, Escola de Pós-Graduação em Economia (FGV/EPGE), Rio de Janeiro, RJ, 2001.

STOCK, J.; WATSON, M. W. A probability model of the coincident economic indicators. In: _____. *The Leading Economic Indicators: New Approaches and Forecasting Records*. Cambridge, UK: Cambridge University Press, 1991. p. 63–90.

STOCK, J.; WATSON, M. W. Business cycles fluctuations in us macroeconomic time series. In: _____. *Handbook of Macroeconomics*. [S.l.]: Elsevier Science B.V., 1999. cap. 1.

STOCK, J. H.; WATSON, M. W. A probability model of the coincident economic indicators. NBER Working Paper Series, No. 2772. 1988.

STOCK, J. H.; WATSON, M. W. New indexes of coincident and leading economic indicators. In: _____. *NBER Macroeconomics Annual 1989, Volume 4*. [S.l.]: MIT Press, 1989. p. 351–409.

STOCK, J. H.; WATSON, M. W. A procedure for predicting recessions with leading indicators: econometric issues and recent experience. In: _____. *New Research on Business cycles, Indicators and Forecasting*. [S.l.]: University of Chicago Press, 1993. p. 95–156.

TORRES, G. P. *Um índice coincidente para a atividade econômica do comércio varejista no Rio Grande do Sul*. Dissertação (Dissertação de Mestrado) — Universidade Federal do Rio Grande do Sul, Programa de Pós-Graduação em Economia (UFRGS/PPGE), Porto Alegre, RS, 2014.


U.S. Census Bureau. X13-arima-seats reference manual acessible html output version. 2015. Disponível em: <<https://www.census.gov/ts/x13as/docX13AS.pdf>>.

WEI, W. W.; STRAM, D. O. Disaggregation of time series models. *Journal of the Royal Statistical Society. Series B (Methodological)*, JSTOR, p. 453–467, 1990.

ZARNOWITZ, V. *Business Cycles: Theory, History, Indicators, and Forecasting*. [S.l.]: University of Chicago Press, 1992.

APÊNDICE A – TABELAS E GRÁFICOS ADICIONAIS

Gráfico A.1 – PIB trimestral do Rio Grande do Sul – 1ºT/2002 ao 1ºT/2017
(Índice de base fixa: média 2002 = 100 – Com ajuste sazonal)

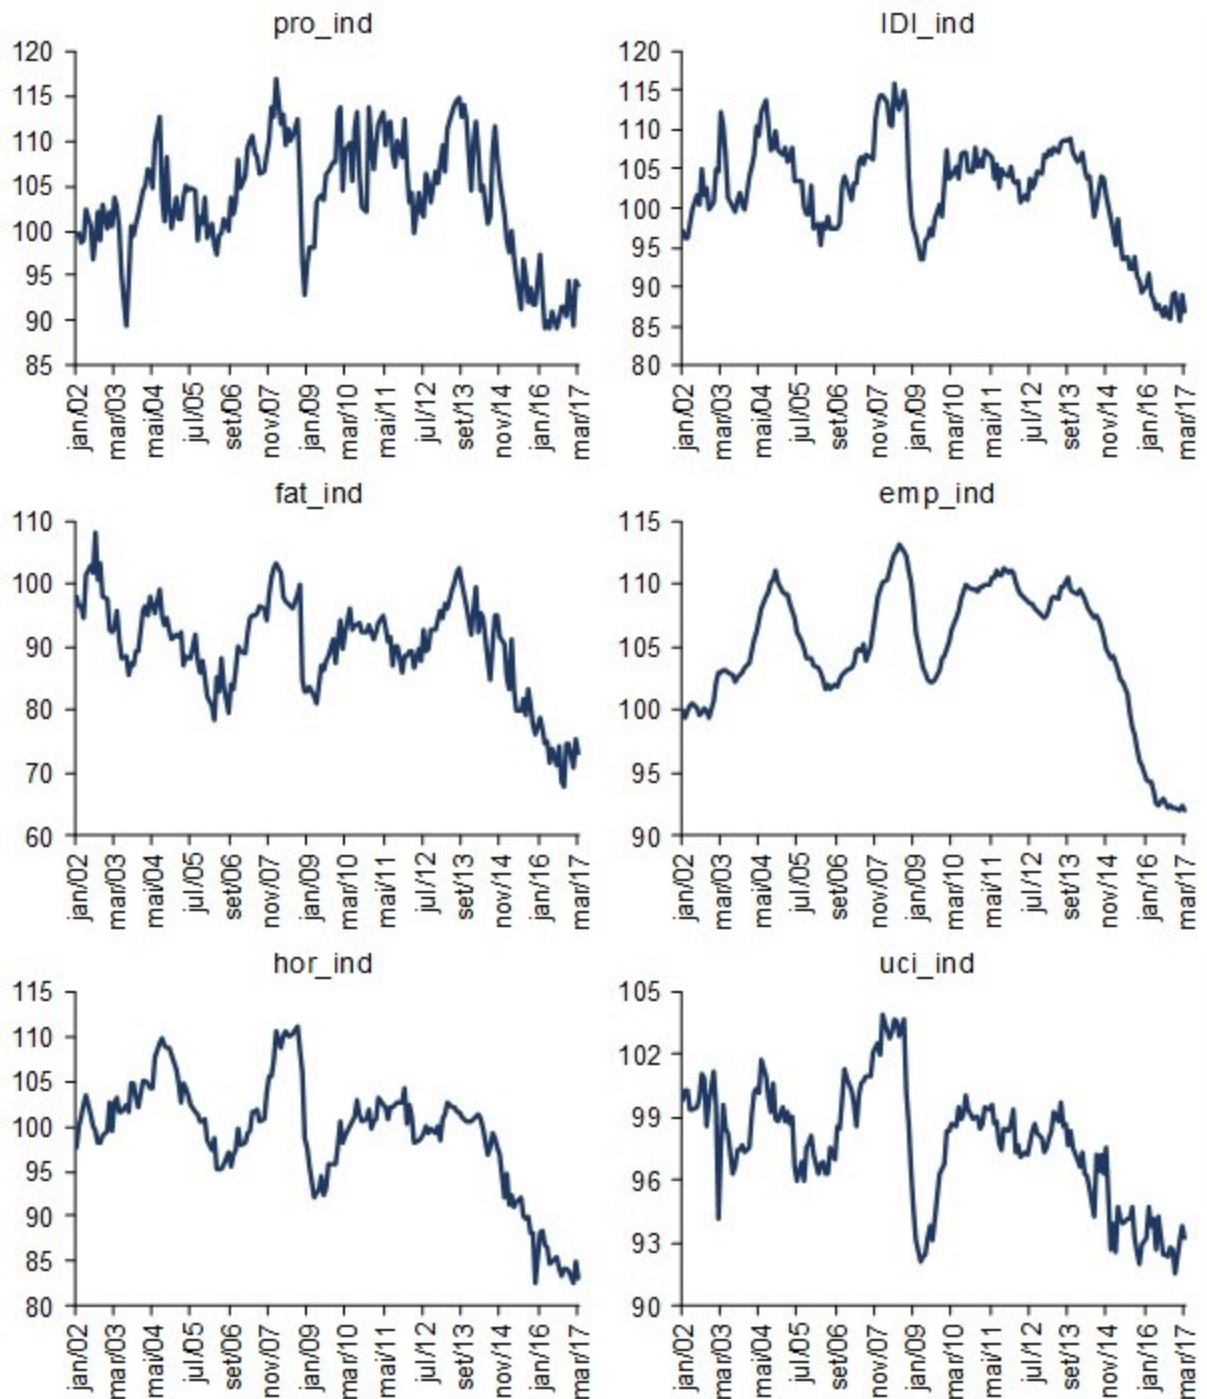


Fonte: FEE.

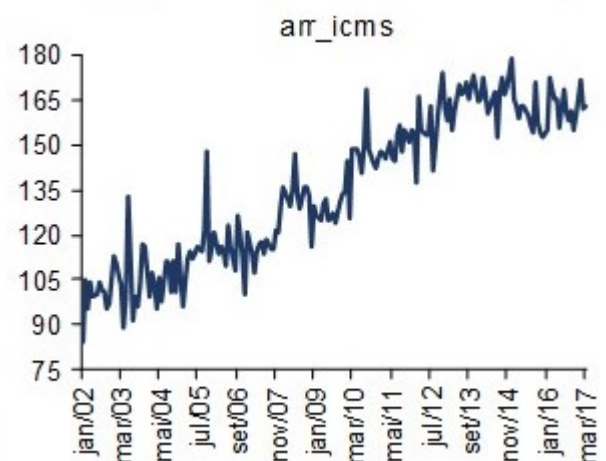
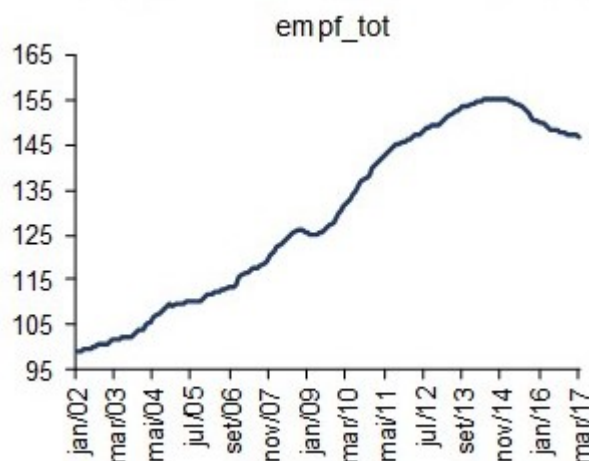
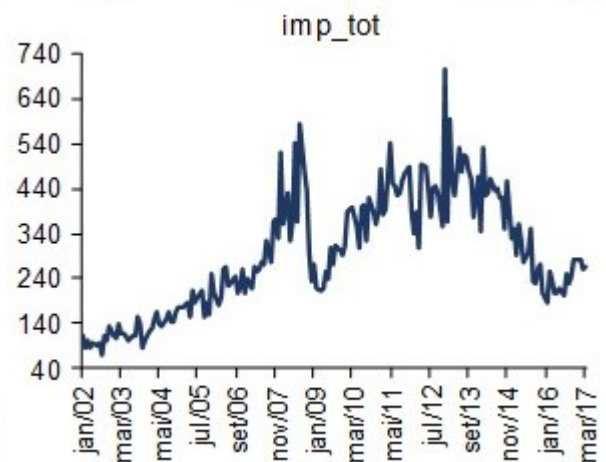
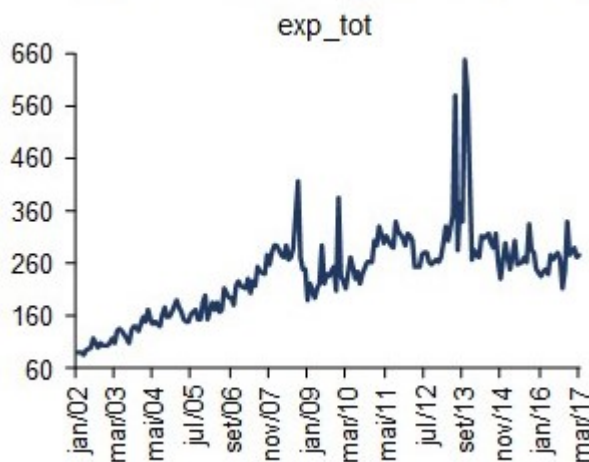
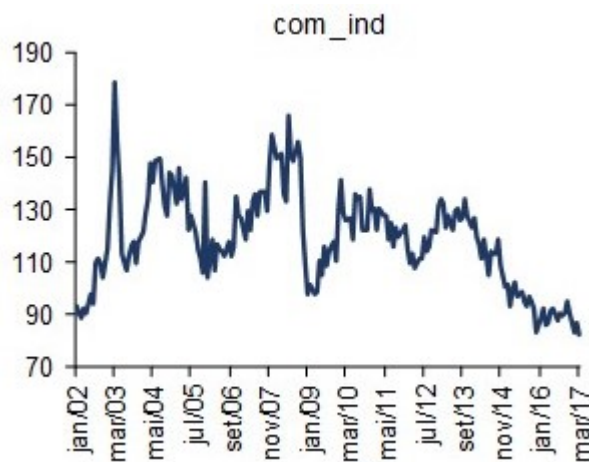
Elaboração: autor.

Gráfico A.2 – Séries coincidentes pré-selecionadas – jan/2002 a mar/2017
 (Índices de base fixa: média 2002 = 100 – Com ajuste sazonal)

(Continua)



(Conclusão)



Fontes: IBGE; FIERGS; MDIC; MTb; MF.
Elaboração: autor.

Tabela A.1 – Testes de cointegração de Johansen entre o PIB e as séries coincidentes

(Continua)

Variável	Lag do VAR	Autovalor	Tipo do teste	Teste	Estatística de teste ($r=0$)
pro_ind	2	0,02	None	Traço	7,87
				Max. Autovalor	6,69
		0,06	Constante	Traço	13,06
				Max. Autovalor	9,34
		0,06	Tendência	Traço	15,01
				Max. Autovalor	11,27
IDI_ind	2	0,01	None	Traço	7,87
				Max. Autovalor	7,42
		0,08	Constante	Traço	13,61
				Max. Autovalor	8,87
		0,06	Tendência	Traço	18,44
				Max. Autovalor	14,65
fat_ind	2	0,03	None	Traço	8,01
				Max. Autovalor	6,39
		0,05	Constante	Traço	15,8
				Max. Autovalor	12,79
		0,06	Tendência	Traço	21,95
				Max. Autovalor	18,31*
emp_ind	2	0,01	None	Traço	7,77
				Max. Autovalor	7,14
		0,07	Constante	Traço	12,13
				Max. Autovalor	8,14
		0,08	Tendência	Traço	16,95
				Max. Autovalor	12,23
hor_ind	2	0,01	None	Traço	6,43
				Max. Autovalor	6
		0,10	Constante	Traço	12,74
				Max. Autovalor	6,79
		0,06	Tendência	Traço	15,46
				Max. Autovalor	11,55
uci_ind	2	0,03	None	Traço	14,27
				Max. Autovalor	12,76
		0,07	Constante	Traço	18,59*
				Max. Autovalor	14,16*
		0,04	Tendência	Traço	18,32
				Max. Autovalor	15,63

(Conclusão)

Variável	Lag do VAR	Autovalor	Tipo do teste	Teste	Estatística de teste (r=0)
com_ind	2	0,01	None	Traço Max. Autovalor	14,62 14,01*
		0,06	Constante	Traço Max. Autovalor	18,08* 14,28*
		0,04	Tendência	Traço Max. Autovalor	25,02* 22,36**
ven_var	2	0,01	None	Traço Max. Autovalor	14,49 13,63*
		0,08	Constante	Traço Max. Autovalor	18,39* 13,72
		0,02	Tendência	Traço Max. Autovalor	15,16 13,67
exp_tot	2	0,03	None	Traço Max. Autovalor	10,83 9,15
		0,06	Constante	Traço Max. Autovalor	12,92 9,25
		0,05	Tendência	Traço Max. Autovalor	12,58 9,76
imp_tot	2	0,05	None	Traço Max. Autovalor	8,24 5,08
		0,07	Constante	Traço Max. Autovalor	10,22 6,24
		0,08	Tendência	Traço Max. Autovalor	13,12 8,43
empf_tot	2	0,05	None	Traço Max. Autovalor	19,76** 16,96**
		0,07	Constante	Traço Max. Autovalor	21,23** 17,02**
		0,07	Tendência	Traço Max. Autovalor	21,6 17,29*
arr_icms	2	0,02	None	Traço Max. Autovalor	14,79 13,34*
		0,08	Constante	Traço Max. Autovalor	19,18* 14,15*
		0,04	Tendência	Traço Max. Autovalor	20,04 17,63*

Elaboração: autor.

Notas: (i) A seleção do *lag* do VAR foi feita com base no menor entre quatro critérios de informação: Akaike (AIC), Hannan-Quinn (HQ), Schwarz (SC) e *Final Prediction Error* (FPE). Além disso, o *lag* máximo foi definido em 8 trimestres e o teste foi conduzido com constante e tendência. Foi utilizada a função *VARselect()* do pacote *vars* do R. (ii) A estatística de teste refere-se à hipótese nula de que não há relação de cointegração, ou seja, o número de vetores de cointegração (posto *r*) é igual a zero. (iii) Os asteriscos indicam a rejeição da hipótese nula de não cointegração a 1% (***) , 5% (**) e 10% (*) de significância.

Tabela A.2 – Resultados dos seis modelos de interpolação para o Conjunto C3

Parâmetro	M1	M2	M3	M4	M5	M6
ϕ				0,9655***	0,2868**	0,9813***
Erro padrão				0,0154	0,1163	0,0148
Z-stat				62,8411	2,4661	66,1987
p-valor				0,0000	0,0146	0,0000
IC.inf 95%				0,9354	0,0589	0,9523
IC.sup 95%				0,9956	0,5147	1,0104
Intercepto	75,2472***	45,1237***	45,4370***	-2,2447	22,1913*	-3,6480
Erro padrão	27,7799	12,4734	12,5049	3,5085	13,2323	3,4346
Z-stat	2,7087	3,6176	3,6335	-0,6398	1,6771	-1,0621
p-valor	0,0074	0,0004	0,0004	0,5231	0,0953	0,2896
IC.inf 95%	20,7997	20,6763	20,9278	-9,1211	-3,7435	-10,3797
IC.sup 95%	129,6948	69,5711	69,9462	4,6318	48,1260	3,0837
pro_ind	0,4146	0,5228***	0,5196***	0,062**	0,4707***	0,0573*
Erro padrão	0,2640	0,1226	0,1230	0,0311	0,1037	0,0305
Z-stat	1,5704	4,2647	4,2245	1,9942	4,5392	1,8762
p-valor	0,1181	0,0000	0,0000	0,0476	0,0000	0,0622
IC.inf 95%	-0,1029	0,2826	0,2785	0,0011	0,2674	-0,0026
IC.sup 95%	0,9322	0,7631	0,7606	0,1230	0,6739	0,1172
ρ		1,0028***				0,1097
Erro padrão		0,0063				0,3602
Z-stat		160,3729				0,3046
p-valor		0,0000				0,7610
IC.inf 95%		0,9905				-0,5962
IC.sup 95%		1,0151				0,8156
σ	490,4359	3,5503	3,5976	6,8638	2,3294	6,5953
Log likelihood	-242,0069	-156,0508	-156,1367	-164,3808	-157,1162	-164,6393

Elaboração: autor.