

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

FERNANDO IOANNIDES LOPES DA CRUZ

TRÊS ENSAIOS SOBRE OS CICLOS DE NEGÓCIOS NO
BRASIL

Porto Alegre

2018

FERNANDO IOANNIDES LOPES DA CRUZ

TRÊS ENSAIOS SOBRE OS CICLOS DE NEGÓCIOS NO
BRASIL

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

Orientador: Prof. Dr. Hudson da Silva Torrent

Coorientador: Prof. Dr. Igor Alexandre Clemente de Moraes

Porto Alegre

2018

CIP - Catalogação na Publicação

Cruz, Fernando Ioannides Lopes da
Três ensaios sobre os ciclos de negócios no Brasil
/ Fernando Ioannides Lopes da Cruz. -- 2018.
129 f.
Orientador: Hudson da Silva Torrent.

Coorientador: Igor Alexandre Clemente de Moraes.

Tese (Doutorado) -- Universidade Federal do Rio Grande do Sul, Faculdade de Ciências Econômicas, Programa de Pós-Graduação em Economia, Porto Alegre, BR-RS, 2018.

1. Ciclos de Negócios. 2. Indicadores Antecedentes.
3. Recessão. 4. Séries Temporais. 5. Previsão. I.
Torrent, Hudson da Silva, orient. II. Moraes, Igor
Alexandre Clemente de, coorient. III. Título.

FERNANDO IOANNIDES LOPES DA CRUZ

TRÊS ENSAIOS SOBRE OS CICLOS DE NEGÓCIOS NO
BRASIL

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

Aprovada em: Porto Alegre, 18 de dezembro de 2018.

BANCA EXAMINADORA:

Prof. Dr. Hudson da Silva Torrent – Orientador
UFRGS

Prof. Dr. João Frois Caldeira
UFRGS

Prof. Dr. Flávio Tosi Feijó
UFRGS

Prof. Dr. Gustavo Inácio de Moraes
PUC-RS

Para a minha família.

AGRADECIMENTOS

Ao professor e meu orientador Hudson Torrent, não apenas pelos valiosos conhecimentos transmitidos em suas aulas e durante a elaboração desta tese, mas principalmente pela receptividade ao projeto e inestimável apoio diante de todos os percalços.

Ao professor Igor Moraes, coorientador desta tese, entusiasta e incentivador de trabalhos relacionados à mensuração e previsão dos ciclos de negócios no Brasil.

Aos membros da banca, professor Gustavo Moraes, professor Flávio Feijó e professor João Caldeira, pelos comentários, críticas e sugestões enriquecedoras.

À minha família pelo amor, sacrifícios e suporte incondicional ao longo de toda minha trajetória profissional e acadêmica.

Aos colegas de doutorado, em especial, Eduardo Tillmann, meu *brother in arms* desde que ingressei no mestrado da UFRGS em 2011 e Danilo Matsuoka, com quem conheci a Singular Spectrum Analysis e quem tive o privilégio de ter como co-autor em dos ensaios.

Aos colegas da Fundação de Economia e Estatística (FEE), com quem compartilhei boa parte das experiências dos últimos quatro anos. Sem dúvida esta tese se beneficiou da imersão em um ambiente tão rico. A todas essas pessoas, muito obrigado, em especial a Jéfferson Colombo, João Pedro Maffessoni, Luis Henrique Paese, Renan Xavier e Vanclei Zanin pelos incentivos, sempre bem humorados, à conclusão deste trabalho. Ao Jéfferson e ao Paese cabe um agradecimento adicional, o primeiro pela leitura e sugestões ao terceiro ensaio e o segundo pela generosa atenção e auxílio com meus códigos em R. Agradeço também a toda a equipe de Contas Regionais, e a todos os envolvidos nos projetos “Indicadores Coincidentes e Antecedentes da Economia Gaúcha” e “Monitor da Economia Gaúcha (MEG)”, com quem pude amadurecer diversas das idéias aqui presentes.

Aos colegas do DOF/SPGG pela receptividade e compreensão durante a fase final de elaboração desta tese.

Aos professores do PPGE da UFRGS, em especial, Marcelo Portugal, Flávio Ziegelmann e Sabino Porto Junior pelas lições dentro e fora de sala de aula.

À secretaria do PPGE, em especial Iara, Marcelo e Maria Delourdes (Lurdes) por todo o suporte administrativo.

À CAPES pelo financiamento durante os primeiros meses do curso.

Aos amigos de Porto Alegre e do Rio, que tornaram esta jornada menos desgastante. Do Princesa Isabel. Da UFF. Da Housing. Da UFRGS. Da FEE. Obrigado a todos.

À Érica, pelo companheirismo, apoio, paciência e compreensão.

RESUMO

A presente tese, composta por três ensaios empíricos, estuda os ciclos de negócios no Brasil lançando mão de diferentes métodos de análise de séries temporais. Os ciclos são abordados tanto em sua interpretação clássica quanto em sua caracterização de hiato do produto, conhecida na literatura como ciclos de crescimento. Os ensaios focam em três aspectos: 1) mensuração, 2) caracterização e 3) previsão. O primeiro ensaio estuda os ciclos de negócios na produção industrial brasileira através de modelos de mudança markoviana de regime. O estudo busca integrar as análises nos níveis nacional, setorial e regional. Os principais resultados apontam: i) uma sincronia entre as fases cíclicas da produção industrial e dos ciclos de negócios, sobretudo com dados trimestrais, ii) evidências de ciclos setor-específicos, iii) maior sincronização entre os ciclos na indústria de transformação e indústria geral e entre os ciclos de estados do sul e sudeste com o ciclo nacional, iv) heterogeneidade no padrão espacial entre as duas últimas recessões pelas quais o país passou. O segundo ensaio, por sua vez, aborda os ciclos de crescimento no Brasil. O trabalho explora os resultados de extração do componente cíclico do PIB trimestral com ênfase no uso da Análise do Espectro Singular (SSA), seguindo o procedimento de agrupamento proposto por Carvalho e Rua (2017). Os efeitos de variações na janela são estudados empiricamente e os resultados são comparados com os de outros filtros sugeridos na literatura. Os resultados indicam que a SSA, além de apresentar ciclos consistentes com outros métodos tradicionais, apresenta performance superior a alguns dos principais filtros em tempo real. Porém, os resultados são sensíveis à escolha da janela. Por fim, o terceiro ensaio estuda o poder preditivo dos indicadores antecedentes da OCDE para o Brasil no contexto de recessões e desacelerações utilizando abordagens probabilísticas, com modelos logit e Bayesian Model Averaging. O horizonte de previsão varia entre 0 e 12 meses. Os resultados indicam que, nos horizontes relevantes, a performance da combinação bayesiana dos modelos supera a do indicador composto da OCDE, tanto nas desacelerações quanto nas recessões. Por fim, os indicadores antecedentes selecionados pela OCDE mostram-se melhores previsores de recessões do que de desacelerações. Com estes estudos pretende-se contribuir com a literatura de ciclos de negócios, em especial, em países em desenvolvimento, onde ainda há importantes *gaps* a serem preenchidos. Assim, os ensaios procuram expandir as evidências disponíveis sobre os fenômenos cíclicos no Brasil tanto com relação ao *timing*, duração e conformidade entre setores e regiões, métodos de filtragem do componente cíclico, como também de ferramentas disponíveis para inferência sobre seus desenvolvimentos futuros, em particular, os indicadores antecedentes da OCDE.

Palavras chave: Ciclos de Negócios. Indicadores Antecedentes. Recessão. Séries Temporais. Previsão.

ABSTRACT

This thesis, composed of three essays, studies Business Cycles in Brazil using different methods of time series analysis. We study both classical and growth cycles, the later being characterized as the output gap view of business cycles. The essays focus on three aspects: i) measurement, ii) characterization and iii) forecasting. In the first essay we study business cycles in the Brazilian industrial production using Markov Switching models. We seek to integrate the analysis in the national, sectoral and regional levels. The main results show we found: i) evidence of synchrony between cyclical phases of industrial production and the aggregate national business cycle and the results are stronger with quarterly data, ii) evidence of sector-specific cycles, iii) greater synchronization between cycles in manufacturing and general industries and between South and Southeast states and national industry, iv) heterogeneity in the spatial pattern between the last two recessions. The second studies growth cycles in Brazil. We explore the results of the cyclical component of quarterly GDP using Singular Spectrum Analysis (SSA). The Grouping step follows the method proposed in Carvalho and Rua (2017). We study empirically the effects of changes in the window length and compare the results with other filters suggested in the literature. Our results indicate that SSA not only presents cycles that are consistent with other methods but also presents superior real time performance in many cases. However the results are sensitive to the choice of window length. Finally, the third essay studies the predictive power of OECD's leading indicators for Brazil. We use a probabilistic approach to evaluate forecasting of slowdowns and recessions, both in and out of sample. The forecasting horizon ranges from 0 to 12 months. We test each indicator individually with logit models and collectively through Bayesian Model Averaging (BMA). The results indicate that, for the relevant horizons, the BMA performance is superior to that of the OECD's composite leading indicator, both for recessions and slowdowns. Lastly, we find that the leading indicators selected by the OECD are better for forecasting recessions than slowdowns. These studies seek to contribute with the Business Cycles literature, especially in developing economies where important gaps still need to be filled. Thus, the essays seek to expand the evidences on cyclical phenomena in Brazil, such as timing, duration, conformity between sectors and regions, among others, as well as evaluate the tools available for inference on the future developments of the Brazilian business cycles, such as the OECD's leading indicators.

Keywords: Business Cycles. Leading Indicators. Recession. Time Series. Forecasting.

Sumário

1	Introdução	11
2	Ciclos de negócios na produção industrial do Brasil: análise nacional, setorial e regional usando modelos de mudança markoviana de regime	17
2.1	Introdução	18
2.2	Modelos de mudança markoviana de regime e o ciclo de negócios	20
2.3	Resultados	23
2.3.1	Análise nacional: Dados e estimação dos modelos paramétricos	23
2.3.2	Análise setorial: indústrias diferentes, ciclos comuns?	30
2.3.3	Análise regional: a geografia dos ciclos na produção industrial	32
2.4	Conclusão	38
	Referências	44
	Apêndice A - Testes de Raiz Unitária	45
	Apêndice B - Modelos de Markov selecionados	49
	Apêndice C - Atividades PIM-PF	50
3	Ciclos de crescimento no Brasil: uma abordagem com Análise do Espectro Singular	51
3.1	Introdução	52
3.2	Breve revisão sobre os ciclos de crescimento	54
3.3	Estrutura básica da Análise do Espectro Singular	56
3.3.1	Parâmetros da SSA e identificação dos ciclos	58
3.4	Alguns Métodos Alternativos	60
3.4.1	Tendência determinística polinomial	60
3.4.2	Tendência Estocástica	60
3.4.3	Filtro Hodrick-Prescott	61
3.4.4	Filtro Christiano-Fitzgerald	62
3.4.5	Método dos Componentes Não-Observáveis	63
3.4.6	Método da Regressão Linear de Hamilton (2017)	64
3.5	Os dados	64
3.6	Resultados empíricos	65

3.6.1	Inspeção visual e estatísticas descritivas	65
3.6.2	Análise dos <i>turning points</i>	70
3.6.3	Performance em (quase) tempo real	74
3.7	Conclusão	78
	Referências	85
4	Recessões e desacelerações no Brasil: o que os indicadores antecedentes da OCDE indicam?	85
4.1	Introdução	86
4.2	Revisão da literatura de previsão de <i>turning points</i> no Brasil	90
4.3	Metodologia	92
4.3.1	Modelo Logit simples	92
4.3.2	Bayesian Model Averaging em modelos lineares generalizados	93
4.3.3	Estatísticas de performance	95
4.4	Investigação empírica	96
4.4.1	Os dados	96
4.4.2	Resultados dos modelos	101
4.5	Conclusão	109
	Referências	116
	Apêndice A - Performances preditivas	117
5	Considerações Finais	125
	Referências	127

1 Introdução

Momentos de crescimento alto, brando ou mesmo de queda da atividade econômica e posterior recuperação são comuns à maior parte das economias do mundo. Economistas há tempos estudam estas flutuações, conhecidas na literatura como Ciclos de Negócios, buscando compreender as causas do fenômeno, mensurá-lo, desenvolver ferramentas para prevê-lo e prescrever políticas que combatam seus efeitos. Fora da academia, há também um interesse global no monitoramento das fases dos ciclos, fundado no trabalho seminal de Burns e Mitchell (1946) sobre a mensuração dos ciclos de negócios e a identificação de seus pontos de virada. Este interesse ganhou novo impulso pela dimensão da crise econômico-financeira que assolou o mundo a partir de 2008 com a quebra do banco de investimentos Lehman Brothers.

O estudo dos ciclos de negócios constitui um dos principais temas da macroeconomia. Trata-se de um fenômeno recorrente com o qual os agentes econômicos interagem tanto de forma passiva quanto ativa. Por exemplo, de acordo com a teoria da renda permanente (FRIEDMAN, 1957), famílias buscam estabilizar seu consumo ao longo do tempo, ajustando a poupança às fases do ciclo econômico: em tempos de bonança ao invés de elevarem seu consumo, poupam a renda excedente, enquanto em fases de retração do ciclo, despoupam e tomam empréstimos de forma a suavizar o consumo no tempo. Da mesma forma, a decisão dos empresários de investir é função, dentre outras coisas, de suas expectativas quanto às condições da economia no futuro. Por outro lado, o governo, busca controlar estas oscilações, implementando políticas macroeconômicas com vistas a estabilizar o comportamento do produto e emprego. Isto porque as flutuações econômicas podem ter como conseqüência perdas de bem-estar significativas, sobretudo em países em desenvolvimento. (PALLAGE; ROBE, 2003) Uma forma de medir o efeito das oscilações sobre o bem-estar da população é perguntar quanto de consumo um indivíduo estaria disposto a abrir mão para eliminar sua volatilidade em torno da tendência de longo prazo, conforme proposto em Lucas (1987) e Lucas (2003). Lucas conclui que os ganhos da estabilização em termos de bem-estar são baixos, sugerindo que as prioridades de política econômica fossem voltadas para o crescimento de longo prazo, ao invés do gerenciamento da demanda de curto prazo. No entanto, Pallage e Robe (2003) encontram evidências de que os custos das oscilações em termos de bem-estar em países mais pobres são mais altos que nos Estados Unidos e o benefício da estabilização pode inclusive superar o de maior crescimento de longo prazo.

O estudo do fenômeno requer, sobretudo no campo empírico, a definição e mensuração do mesmo. Nos Estados Unidos, o *National Bureau of Economic Research* (NBER) publicou a primeira cronologia dos ciclos de negócios em 1929. A instituição divulga a datação dos picos e vales da atividade econômica americana de 1854 (data do primeiro vale) até 2009 (data do último vale). No Brasil, estas cronologias foram inferidas por alguns pesquisadores em trabalhos acadêmicos até a criação do Comitê de Datação dos Ciclos de Negócios (CODACE/IBRE-FGV) em 2008. Diversos outros exemplos de instituições ao redor do mundo executam tarefas semelhantes, com metodologias próprias, tais como a OCDE, o ECRI, dentre outros.

No segundo trimestre de 2014 a economia brasileira entrou em sua mais recente fase recessiva, uma das mais severas da história do país, com implicações em diversas regiões e setores da economia nacional. Diante da gravidade da recessão, torna-se imperativo o contínuo desenvolvimento e aperfeiçoamento de instrumentos que permitam identificar, analisar e prever tais eventos.

A discussão acima motivou a composição da presente tese no formato de três ensaios aplicados aos ciclos de negócios no Brasil. A pesquisa empírica, em especial de ciclos, possui quatro objetivos (JACOBS, 2012): i) testar hipóteses teóricas, ii) avaliar os efeitos de políticas econômicas, iii) descrever e mensurar as flutuações econômicas e iv) realizar previsões. Os ensaios aqui presentes se concentram em explorar estes dois últimos tópicos.

O primeiro ensaio estuda os ciclos de negócios na produção industrial brasileira utilizando modelos de mudança markoviana de regime em diferentes níveis de agregação. No Brasil, alguns trabalhos como Cunha e Moreira (2006) e Portugal e Morais (2008) conduziram estudos a fim de explorar características empíricas dos ciclos regionais como volatilidade, correlação entre ciclos estaduais e nacional e identificação de *turning points*. Em particular, este último estuda os ciclos de negócios na produção industrial de alguns dos principais estados do país utilizando modelos de mudança de regime markoviano univariados e multivariados.

No entanto, o trabalho de Portugal e Morais (2008) estudou um período notoriamente distinto da atual situação da economia brasileira. Sobretudo a partir de 2008, pelo menos dois novos choques podem ter ocasionado mudanças nos parâmetros dos modelos: a instauração da crise econômica mundial a partir da quebra do Lehman Brothers em setembro de 2008 e a chamada Nova Matriz Econômica a partir de 2012. Destarte, uma nova caracterização dos ciclos pode servir de complementação ao estudo, permitindo novas evidências sobre a época analisada pelos autores, além de caracterizar períodos posteriores, que incluem a recessão iniciada no segundo trimestre de 2014.

Com o uso de modelos de Markov pode-se obter uma cronologia dos ciclos, estimada a partir das probabilidades de transição entre os regimes de Markov para a indústria nacional, setorial e regional. Para a indústria nacional, diferentes modelos são testados e os resultados obtidos com a estimação dos ciclos são comparados com cronologias alter-

nativas. São utilizadas regras não-paramétricas, como o algoritmo Bry-Boschan para a indústria ou provenientes de uma datação heurística para a economia nacional, derivada do consenso entre especialistas, como a do CODACE. A partir deste exercício, elege-se um modelo como *benchmark* dos ciclos da indústria nacional agregada.

Com objetivo de investigar mais profundamente as diversidades intra-setoriais e inter-regionais nos ciclos industriais, o trabalho examina com a mesma classe de modelos as séries de produção da indústria extrativa e de transformação nacional, bem como a produção da indústria geral de diferentes unidades federativas. Estes exercícios buscam investigar a hipótese de co-movimentos nos ciclos das indústrias, bem como fornecer alguns *insights* sobre as consequências de choques específicos, ajudando a revelar fontes de flutuações na atividade industrial e na economia agregada. Conforme notado na literatura (OWYANG et al., 2005; OWYANG et al., 2008), o *mix* de indústrias existentes em cada região pode levá-las a reagirem de maneiras distintas a choques específicos.

O segundo ensaio explora o tema da mensuração dos ciclos, em especial, a diversidade de estimativas de hiato do produto que são obtidas com a aplicação de diferentes filtros ao PIB trimestral brasileiro. Neste processo dois pontos são importantes: Em primeiro lugar, fatos estilizados dos ciclos produzidos por diferentes métodos são distintos. Em segundo lugar, o componente cíclico - associado comumente a medidas de hiato do produto - apresenta problemas de ajuste nos extremos das séries com tradicionais métodos de filtragem, como o filtro Hodrick-Prescott.

No que tange ao primeiro aspecto, Canova (1998) apontou que diferentes métodos de filtragem e remoção da tendência possuem hipóteses distintas sobre o comportamento dos componentes de tendência e ciclo e portanto produzem diferentes conjuntos de relações entre as variáveis macroeconômicas analisadas, tais como volatilidade, correlações e transmissão de choques. Em séries brasileiras o problema foi abarcado por Teles et al. (2005), que estudaram a sensibilidade dos fatos estilizados a diversos procedimentos de filtragem e remoção de tendência, comparando-os com aqueles obtidos através de simulações de modelos de Real Business Cycles. Os métodos utilizados foram Tendência Linear, Primeira Diferença, Ruído Branco, Filtro Hodrick-Prescott e Filtro Christiano-Fitzgerald.

Com relação ao segundo ponto, um dos métodos mais tradicionais na literatura para obter este componente é o filtro Hodrick-Prescott (HP) No entanto, como discutido em Mise et al.(2003) e outros, o filtro apresenta problemas de ajuste da tendência no fim da amostra, tornando-o menos confiável justamente nos períodos críticos para tomada de decisão de política econômica. Orphanides e Norden (2002) encontram evidências de que diante de revisões nos dados - cuja maior fonte são os recômputos dos componentes com a chegada de novos dados - as medidas do componente cíclico não são confiáveis. Em exercício semelhante, Carvalho et al. (2012) aplicam três métodos - Hodrick-Prescott (HP), Christiano-Fitzgerald (CF) e Carvalho-Rodrigues-Rua (CRR)- e encontram que o filtro HP apresenta qualidade inferior em tempo real, com menor correlação entre a série

em tempo real e a final, maior razão ruído-sinal (noise-to-signal) e menor percentual do tempo em que o sinal (sign) do ciclo gerado em tempo real é igual ao do ciclo com a estimativa final, juntamente com o filtro CF. O método CRR é na verdade uma Análise de Espectro Singular, conforme será descrito à frente.

Desta forma, particular ênfase é dada no ensaio à chamada Análise do Espectro Singular (SSA), um método não-paramétrico altamente difundido na literatura de ciências naturais, com recentes aplicações em estudos dos ciclos de negócios. A decomposição de séries de tempo através da SSA envolve uma série de etapas. O ponto central é que para a identificação apropriada dos componentes de interesse, i.e. tendência, ciclo e ruído, é necessária a especificação adequada de dois parâmetros: 1) o tamanho da janela, L , na fase de decomposição e 2) a identificação correta dos grupos na etapa de reconstrução das séries.

Utilizando a informação *a priori* sobre a frequência dos ciclos de negócios, Carvalho e Rodrigues (2017) propuseram recentemente um pseudo-algoritmo para a filtragem de componentes de interesse na fase de reconstrução. Contudo, a escolha da janela ainda permanece um procedimento *a priori*. Como forma de estudar empiricamente a sensibilidade dos ciclos obtidos a partir de diferentes escolhas de janela, utilizamos a estratégia de Carvalho e Rodrigues (2017) com janelas variando entre 7 e 45 trimestres. Os resultados são comparados aos obtidos por diversos outros filtros, como tendência determinística polinomial, tendência estocástica, filtro Hodrick-Prescott, filtro Christiano-Fitzgerald, filtro de Kalman e o método da regressão linear de Hamilton (2017). A análise é conduzida com ênfase em três aspectos: a) características gerais dos ciclos, b) análise dos *turning points* e c) performance em tempo real.

Por fim, quanto ao terceiro ensaio, indicadores coincidentes e antecedentes mostram-se ferramentas úteis para sumarizar o estado da economia - uma variável não observável - em determinado ponto do tempo e prever suas condições futuras, especificamente, seus pontos de virada. A variável observada geralmente utilizada para inferir sobre a variável não-observada estado da economia é o PIB. No entanto, existem três problemas com a utilização deste indicador para inferência sobre o estado da economia. O primeiro é que ele está disponível apenas em frequência trimestral ou anual. A segunda desvantagem é que o PIB sofre diversas revisões, principalmente nos dados mais recentes, divulgados entre um trimestre e outro. Por fim, o terceiro problema está relacionado à tempestividade do indicador. Por exemplo, a divulgação do PIB de um determinado trimestre só é realizada cerca de dois meses após o fim daquele trimestre, um intervalo relativamente grande.

Indicadores e índices que contornem as desvantagens supracitadas - isto é, disponíveis em frequência mais alta, sujeitos a menos revisões e com intervalos menores entre o período de referência e o período de divulgação - refletindo o comportamento de aspectos múltiplos do ciclo econômico, tornam-se instrumentos importantes para o monitoramento da atividade e a tomada de decisão de governos, famílias e empresas. O movimento cíclico

de alguns destes indicadores se dá contemporaneamente ao do estado da economia e por essa razão, são chamados de indicadores coincidentes. Por outro lado, os ciclos observados em outros indicadores tendem a preceder os do primeiro grupo, sendo conhecidos como indicadores antecedentes de atividade econômica. Há ainda um terceiro grupo, cujas viradas cíclicas ocorrem com certa defasagem em relação aos dois primeiros grupos, os indicadores defasados.

Um dos sistemas de indicadores antecedentes mais conhecidos no mundo é o da OCDE. Inicialmente criado com o propósito de antecipar os pontos de virada na economia de um conjunto de países membros, a partir de 2006 passou a incorporar também informações de seis países não-membros, dentre os quais, o Brasil. Os indicadores selecionados pela OCDE são agregados em uma medida sintética chamada de Composite Leading Indicator (CLI) com o intuito de potencializar o poder preditivo destes indicadores sobre o ciclo econômico. Diferentemente do CODACE, a OCDE utiliza o conceito de ciclo de crescimento para elaborar sua cronologia dos ciclos, o que faz com que as datas de picos e vales estabelecida pela OCDE sejam distintas das do CODACE. Isto faz com que alguns períodos de baixo crescimento, porém a taxas ainda positivas sejam caracterizados, por exemplo, como desacelerações na cronologia da OCDE e expansões na do CODACE.

Sendo séries de tempo macroeconômicas, os indicadores individuais selecionados estão sujeitos a quebras estruturais que têm o potencial de modificar seu poder preditivo, havendo necessidade de constante avaliação dos mesmos. Outra questão relacionada à composição do CLI se refere ao peso atribuído a cada um de seus componentes. O sistema da OCDE distribui igualmente os pesos entre os indicadores selecionados baseado em três premissas: transparência, fácil manutenção e replicação e redução de fontes de revisão nos dados. Na prática, essa escolha dos pesos reflete a importância equânime dada a cada indicador na antecipação dos ciclos.

Diante das questões expostas, o terceiro ensaio propõe avaliar a performance dos indicadores antecedentes da OCDE na previsão de desacelerações e recessões clássicas na economia brasileira. Em particular, busca-se responder a duas perguntas: 1) os indicadores são capazes de prever tanto desacelerações quanto recessões clássicas? e 2) o CLI é a melhor forma de extrair informações cíclicas destes indicadores? Para respondê-las, uma série de exercícios econométricos de previsão com variáveis latentes são conduzidos dentro e fora da amostra utilizando duas estratégias de modelagem. A primeira é com modelos logit univariados, utilizando as séries selecionadas pela OCDE. A segunda é através de uma combinação de diferentes modelos logit, com o uso da *Bayesian Model Averaging*, uma vez que a literatura aponta que ganhos de poder preditivo podem ser obtidos incorporando na análise os resultados de modelos sub-ótimos, do ponto de vista estatístico. Os horizontes de interesse variam de zero a doze meses.

Com estes estudos, espera-se contribuir com a literatura através da ampliação de

evidências empíricas sobre os ciclos de negócios no Brasil, fornecendo uma melhor compreensão do fenômeno em economias em desenvolvimento. Os trabalhos propõem ainda agendas de pesquisas futuras em complementação aos resultados aqui obtidos.

2 Ciclos de negócios na produção industrial do Brasil: análise nacional, setorial e regional usando modelos de mudança markoviana de regime

Resumo. O presente trabalho estuda os ciclos de negócios na produção industrial brasileira utilizando modelos de mudança markoviana de regime em diferentes níveis de agregação. Na análise agregada nacional comparamos os resultados de diferentes modelos às datações de recessão do CODACE/FGV-IBRE, bem como aquelas obtidas através do algoritmo Bry Boschan trimestral. O modelo preferido é utilizado como *benchmark* de ciclos na indústria nacional para avaliar os resultados setoriais e regionais. Nossos principais resultados são: i) sincronia entre as fases cíclicas da produção industrial e o ciclo de negócios brasileiro, em linhas gerais, sobretudo com dados trimestrais, ii) existência de ciclos específicos em diferentes setores da indústria, iii) maior sincronização entre os ciclos na indústria de transformação e na indústria geral e entre os ciclos de estados do sudeste e do sul com o ciclo de negócios nacional; iv) heterogeneidade no padrão espacial entre as duas últimas recessões.

Palavras-chaves: Ciclos de Negócios. Produção Industrial. Brasil. Análise setorial. Análise Regional

Classificação JEL. E32, R1

2.1 Introdução

Uma das principais características ressaltadas na definição clássica de Burns e Mitchell (1946) dos ciclos de negócios são os co-movimentos entre diferentes variáveis econômicas. Enquanto boa parte da literatura empírica nesta tradição se concentra em encontrar os *turning points* em medidas agregadas únicas de atividade econômica, menor atenção é dada ao estudo das datações e sincronização de fases cíclicas em indicadores desagregados, por setor ou região. Ao se escolher uma medida de atividade agregada, PIB e PNB são os candidatos mais frequentemente estudados. De fato, tais medidas contemplam, em parte, o conceito de atividade econômica agregada de Burns e Mitchell, sobretudo quando disponíveis em frequências mais altas, como trimestral ou mensal.¹ No entanto, alguns estudos utilizam o índice de produção industrial para representar o mesmo conceito e estudar o fenômeno cíclico nestas frequências.(CHANG; HWANG, 2015; WALL, 2006)

O índice de produção industrial (IPI) é um dos principais indicadores de atividade econômica de curto prazo, medindo mudanças no volume de produção agregado de uma indústria ou conjunto de indústrias em determinada região geográfica com relação a um período de tempo específico. Assim, o monitoramento deste indicador se justifica não apenas no âmbito da análise setorial, onde a indústria e seus setores são o foco, mas também possui importância fundamental do ponto de vista macroeconômico, em especial no que concerne a análise dos ciclos de negócios.² Há, pelo menos, duas razões centrais para isso.

Primeiramente, o peso da produção industrial na composição do valor adicionado da maior parte dos países, sobretudo na segunda metade do século XX, e sua relação cíclica com o produto, justificavam historicamente o uso do IPI como *proxy* mensal para o PIB. De fato, este foi um dos motivos que levaram a OCDE a estabelecer o índice de produção industrial como a série de referência em seu *Sistema de Indicadores Antecedentes Compostos* até a década de 2010, quando foi substituído por uma estimativa mensal do PIB a partir de dados trimestrais (FULOP; GYOMAI, 2012; GYOMAI; GUIDETTI, 2008). Em segundo lugar, mesmo perdendo espaço para outros indicadores como série de referência para medição do estado corrente da economia - e.g., *proxies* mensais de PIB ou

¹Conforme lembram Harding e Pagan (2002), Burns e Mitchell (1946) destacaram que "*Aggregate activity can be given a definite meaning and made conceptually measurable by identifying it with gross national product at current prices.*"(BURNS E MITCHELL, 1946,p.72), embora este indicador não estivesse disponível à época nestas frequências para o período analisado. Outros autores, como Stock e Watson (1988) contudo, apresentam críticas à mensuração do "estado da economia" através de medidas como o PNB, uma vez que tal variável é construída com vistas a medir um conceito - bem definido - distinto, qual seja, o valor de todos os produtos e serviços produzidos em um período de tempo. Para uma revisão dos possíveis problemas em se utilizar uma série única para representar o ciclo de negócios, ver Boehm (1998).

²Mesmo quando o foco da pesquisa é o setor industrial, uma medida única como a produção industrial pode não ser suficiente para mensurar o estado da atividade setorial. Hollauer e Issler (2006), por exemplo, agregam diferentes indicadores - dentre os quais o IPI - com vistas a construir uma "série de referência" para a indústria.

outros indicadores compostos de atividade econômica - o IPI é com frequência utilizado como um dos indicadores que compõem os índices compostos coincidentes elaborados por diversas instituições, como IBRE/FGV, TCB, NBER, ESRI, dentre outros, para monitoramento do ciclo econômico. Em outras palavras, os picos e vales na atividade de produção da indústria estão, em geral, correlacionados com as mudanças entre estados de expansão e recessão na atividade econômica mais ampla.

Diante do exposto, acessar informações sobre o estágio dos ciclos econômicos através deste indicador é um exercício importante, sobretudo quando há indisponibilidade de séries longas de atividade econômica. Este é um problema frequente em estudos sobre o Brasil, o qual se agrava quando as unidades de análise são seus setores e regiões. No que concerne às últimas, nota-se um interesse ainda incipiente na literatura empírica sobre ciclos regionais no Brasil, com algumas exceções (PICCHETTI, 2010; PORTUGAL; MORAIS, 2008; CORREIA, 2012; EVANGELISTA, 2009; CARVALHO et al., 2005; CUNHA; MOREIRA, 2006). Tais estudos documentam os padrões cíclicos comuns que existem entre unidades federativas, bem como flutuações específicas ocorridas em cada uma das regiões estudadas. Pouca atenção, no entanto, é dada ao fato de que estas idiosincrasias podem estar relacionadas ao *mix* de indústrias existentes em cada região, como evidenciado na literatura internacional (Ver, por exemplo, Owyang et al. (2005) e Owyang et al. (2008), onde a atenção deste último é voltada para as cidades.).³ Mais ainda, estes comovimentos de mudanças de fase nos ciclos das diferentes indústrias - ou a ausência dele - podem fornecer alguns *insights* sobre as conseqüências de choques específicos em algum setor ou região, ajudando a revelar as fontes de flutuações na atividade industrial geral ou mesmo na atividade econômica agregada, além de fornecer um panorama mais amplo da situação da indústria nacional. Na literatura nacional, há também alguns trabalhos que reconhecem a importância da análise dos ciclos de negócios em diferentes setores (MORAIS; CHAUVET, 2011; SCHUCK, 2012). No entanto, seu foco é voltado para a construção de indicadores antecedentes e não para a identificação de sincronias entre diferentes níveis de agregação dos indicadores.

Em face do exposto, o presente trabalho propõem preencher este *gap* analisando os ciclos de negócios na produção industrial brasileira, em diferentes níveis de agregação, utilizando uma classe de modelos não-lineares, qual seja, a de modelos de mudança markoviana de regime. A nível nacional, exploramos as diferenças encontradas nas probabilidades de recessão na indústria quando modelamos o IPI em frequência mensal e trimestral, bem como quando a série modelada é a primeira diferença ou a diferença anual. Os resultados são comparados com a cronologia de recessões da economia brasileira divulgada pelo CODACE/FGV-IBRE. Para os dados trimestrais, o algoritmo Bry-Boschan Trimestral aplicado à série do IPI em nível também é utilizado como *benchmark* alternativo. A partir dos resultados obtidos na análise nacional é estabelecido um "ciclo de referência" da

³Uma exceção é Correia (2012).

produção industrial para as análises setorial e regional. Esta análise desagregada busca identificar regimes de expansão e recessão ou alto e baixo crescimento na indústria extrativa e de transformação e na indústria geral dos estados, bem como explorar sua sincronia com o ciclo nacional.

O trabalho está dividido em quatro seções, incluindo esta introdução. Na segunda seção faz-se uma breve descrição da metodologia utilizada, ressaltando algumas de suas aplicações no contexto de estudos de ciclos de negócios. Na terceira seção são discutidos os dados e resultados dos modelos estimados. As três seções seguintes apresentam as análises nacional, setorial e regional, respectivamente. Por fim, a sexta seção apresenta as conclusões.

2.2 Modelos de mudança markoviana de regime e o ciclo de negócios

Um dos objetivos da literatura macroeconômica, realçado após o *Grande Crash* de 2008, consiste em aprimorar o conhecimento - teórico e empírico - sobre as flutuações de curto prazo na atividade econômica agregada de economias de mercado, fenômeno conhecido como *ciclo de negócios*. Em um sentido amplo, isto implica que diferentes indicadores econômicos como vendas, produção, renda, emprego, etc, apresentam dinâmicas distintas dependendo de a economia encontrar-se em estado de expansão ou de recessão. No que tange a análise de séries de tempo, tais mudanças de dinâmica podem ser interpretadas como quebras estruturais nos parâmetros das equações que governam o processo gerador de dados. O momento da quebra, contudo, nem sempre é conhecido, sendo necessário algum procedimento para fazer inferência sobre as datas de transição entre um regime e outro.

Neste contexto, desde o trabalho seminal de Hamilton (1989), os modelos de mudança markoviana de regime têm sido amplamente empregados para identificação, análise e previsão de dados com dependência temporal (CHAUVET, 2002; KROLZIG, 1997), particularmente em análises dos ciclos econômicos. Em primeiro lugar, o modelo de Hamilton (1989) foi capaz de distinguir períodos com média de crescimento positiva e negativa, interpretados como as diferentes fases dos ciclos de negócios na economia americana - expansão e recessão, respectivamente - em consonância com a definição do ciclo de negócios de Burns e Mitchell (1946).⁴ Mais ainda, os momentos de quebra ou mudança nos parâmetros do modelo foram determinados endogenamente através de Cadeias de Markov para as probabilidades de transição. Além disso, as probabilidades filtrada e suavizada estimadas para os períodos de recessão ultrapassam 50% nos períodos em que o NBER identifica períodos de recessão⁵; as datas em que isto ocorre são muito próximas àquelas

⁴Na definição de Burns e Mitchell (1946), os autores consideram fases intermediárias de contração e renovação entre uma recessão e uma expansão.

⁵Uma discussão sobre o método do NBER pode ser encontrada em Hall et al. (2003) e Moore e Zarnowitz (1986)

de início e fim das recessões americanas datadas pelo *Bureau*. Ademais, a estimação das datas de transição entre regimes permite verificar características de assimetria e duração dos ciclos. Estes resultados foram obtidos modelando-se exclusivamente a taxa de crescimento do PNB americano em função de seus valores passados. Por fim, a utilização de um modelo dinâmico permite realizar exercícios de previsões em séries de tempo com modelos não-lineares, tornando-se uma ferramenta útil para identificar mudanças de regime não apenas dentro mas também fora da amostra. Esta característica torna a utilização de modelos dinâmicos para fins de identificação dos ciclos altamente vantajosa em relação aos procedimentos do NBER, em que a identificação dos pontos de virada só é possível após o término da fase cíclica.⁶

Embora em sua formulação original apenas os parâmetros da média estivessem sujeitos a quebras, o modelo pode ser estendido para permitir mudanças de regime em outros parâmetros, como intercepto, variância e coeficientes autoregressivos, bem como um maior número de regimes.⁷

Em resumo, os modelos de mudança markoviana de regime apresentam-se como ferramentas úteis na investigação econométrica de ciclos de negócios. Destarte, utilizaremos esta classe de modelos para estudar as flutuações cíclicas na taxa de crescimento da produção física da indústria brasileira. A análise a seguir considera dois regimes, interpretados como as fases cíclicas na produção industrial, que se alternam, conforme o ciclo de negócios evolui. Cada regime possui sua própria média e variância. De acordo com os valores estimados para o parâmetro de intercepto, classificaremos os regimes como aquecimento e desaquecimento quando ambos os parâmetros forem positivos e expansão e recessão quando um deles for positivo e o outro negativo.

O modelo pode ser descrito de maneira simples da seguinte forma.⁸ Seja y_t igual a cem vezes a primeira diferença do log do IPI. Assumimos que a taxa de crescimento do IPI pode ser vista como um processo autoregressivo onde os parâmetros de intercepto e variância são distintos em períodos de alto e baixo crescimento e alta e baixa volatilidade:

$$\phi(L)y_t = \nu_{s_t} + e_t \quad e_t \sim N(0, \sigma_{s_t}^2), \quad (2.1)$$

ou seja,

$$\phi(L)y_t = \begin{cases} \nu_1 + e_t & e_t \sim N(0, \sigma_1^2) \\ \nu_2 + e_t & e_t \sim N(0, \sigma_2^2) \end{cases} \quad (2.2)$$

⁶Deve haver clareza, no entanto, de que modelos preditivos podem apresentar diferentes performances dentro e fora da amostra, o que os torna por um lado, ferramentas úteis, mas por outro, menos precisos do que métodos mais holísticos como os do NBER.

⁷Para uma discussão ampla sobre diferentes especificações dos modelos de mudança markoviana de regime, ver Krolzig (1997).

⁸Para uma descrição mais completa e didática dos modelos, ver Hamilton (1994) e Kim e Nelson (1999).

As seguintes equações completam a caracterização do modelo:

$$\nu_{s_t} = \nu_1 S_{1t} + \nu_2 S_{2t}, \quad (2.3)$$

$$\sigma_{s_t}^2 = \sigma_1^2 S_{1t} + \sigma_2^2 S_{2t}, \quad (2.4)$$

$$\Pr[S_t = j / S_{t-1} = i] = p_{ij} \quad i, j = 1, 2 \quad (2.5)$$

$$\sum_{i=1}^2 p_{ij} = 1. \quad (2.6)$$

A equação 4.1 representa um modelo autoregressivo de ordem p em que os parâmetros de intercepto e de variância variam ao longo do tempo de acordo com o comportamento de uma variável não observada, S_t . As equações 2.3 e 2.4 especificam, respectivamente, os valores do intercepto e da variância, de acordo com o regime vigente a cada instante t . Assim, $S_{1t} = 1$ se $S_t = 1$ e 0 caso contrário; analogamente, $S_{2t} = 1$ se $S_t = 2$ e 0 caso contrário. Para estimarmos os parâmetros do modelo, é preciso assumir algumas hipóteses acerca do comportamento da variável não-observada S_t . A hipótese central, representada pela equação 2.5, é de que a variável latente, S_t , segue uma Cadeia de Markov de primeira ordem, o que significa que seu estado corrente pode ser predito com certa probabilidade baseando-se unicamente no conhecimento do estado imediatamente anterior. As probabilidades de transição entre um estado i e um estado j são denotadas por p_{ij} . Como só há dois estados, dado que em $t - 1$ o sistema se encontrava no regime i , a probabilidade de o sistema manter-se no mesmo regime ou transitar para um regime diferente soma um, como mostrado na equação 2.6.

Colecionando as probabilidades de transição em uma matriz, obtemos a matriz de probabilidades de transição:

$$\mathbf{P} = \begin{bmatrix} p_{11} & p_{21} \\ p_{12} & p_{22} \end{bmatrix} \quad (2.7)$$

O modelo descrito pelas equações (1)-(7), na nomenclatura de Krolzig (1997), é conhecido como *Markov Switching Intercept Heterocedastic Model* (MSIH). Especificações mais simples podem ser obtidas anulando-se o intercepto (MSH) ou tornando o modelo homocedástico (MSI). Outras especificações para a modelagem da média também podem ser obtidas, como o modelo *Markov Switching Mean* (MSM) usado em Hamilton (1989). Krolzig (1997) destaca que há diferenças no processo de ajuste dinâmico em diferentes especificações. Em particular, modelos com mudança no intercepto (MSI) permitem

uma transição suave entre diferentes regimes, enquanto modelos com mudança na média (MSM) implicam mudanças mais bruscas no processo da média ante uma mudança de regime. No entanto, quando se anula o processo autoregressivo (AR(0)) no processo gerador de dados, as especificações MSI e MSM coincidem. Este modelo é conhecido como Modelo de Cadeia de Markov Oculta (MCO):

$$y_t = \nu_{s_t} + e_t \quad e_t \sim N(0, \sigma_{s_t}) \quad (2.8)$$

A estimação dos parâmetros do modelo, incluindo os parâmetros de distúrbio relacionados às probabilidades de transição podem ser estimados por máxima verossimilhança utilizando métodos recursivos (HAMILTON, 1989) ou através do algoritmo EM (HAMILTON, 1990). É importante destacar que, nesta especificação, ainda que não haja componentes autoregressivos, a variável dependente apresenta autocorrelação através da dependência serial entre os regimes, mantidas as condições de regularidade da Cadeia de Markov. Chauvet (2002) utiliza este modelo para lidar com eventuais quebras estruturais no PIB brasileiro, provenientes de choques de política econômica, e.g., os planos de estabilização das décadas de 1980 e 1990. No entanto, outros fatores associados a quebras estruturais em séries econômicas brasileiras, particularmente na produção industrial, são os choques externos provenientes de contágios de crises econômico-financeiras na década de 1990, a abertura comercial iniciada em 1990, a passagem de um sistema de bandas cambiais para um regime de câmbio flutuante em 1999, com a desvalorização do Real e mais recentemente, o choque externo proveniente da crise do *subprime* que tomou proporções mundiais a partir da quebra do banco Lehman Brothers em setembro de 2008. O modelo MCO com mudança de regime na variância também foi usado por Portugal e Morais (2008) para estudar os ciclos na indústria brasileira.

2.3 Resultados

A seguir, os resultados empíricos são analisados.

2.3.1 Análise nacional: Dados e estimação dos modelos paramétricos

Os dados do IPI nacional foram coletados em frequência mensal do IPEA (1975-2014) e do IBGE (2002-2017). Para obtenção de uma série histórica longa com dados mais recentes, optou-se por retropolar a série mais recente do IBGE pelas taxas de variação da série disponibilizada pelo IPEA, ambas sem ajuste sazonal. Para construção das séries trimestrais usou-se a média dos números índices mensais em cada trimestre, sem ajuste sazonal. Em seguida, utilizou-se ajuste sazonal com o método X13-ARIMA-SEATS para

remoção da mesma. Além da alta sazonalidade, é possível perceber nas séries um componente de tendência positiva, o que caracteriza a mesma como não-estacionária. Neste caso, é importante identificar se a tendência presente na série é determinística ou estocástica.

A forma tradicional encontrada na literatura para testar a existência de raiz unitária são os testes de Dickey e Fuller (1979), construídos sob a hipótese nula de existência de raiz unitária. Nelson e Plosser (1982) utilizaram esse ferramental para desafiar a visão tradicional dos ciclos, de que choques possuem apenas um efeito temporário sobre as séries. Contudo, em geral estes testes possuem baixo poder, rejeitando H_0 falso com baixa probabilidade. A dificuldade se torna maior quando da distinção entre um processo de raiz unitária e um AR(1) estável com coeficiente autoregressivo próximo à unidade.⁹ Mais do que isso, tais testes tornam-se viesados sob a presença de quebras estruturais, na direção da não rejeição da hipótese nula de existência de raiz unitária. Estas quebras na série podem ser entendidas como mudanças que ocorrem em apenas um ponto do tempo e permanecem durante o restante da série ou que atuam apenas em determinado ponto do tempo. Contudo, na presença de raiz unitária, ambos os fenômenos produzem efeitos duradouros sobre a série e a diferenciação entre processos I(1) e I(0) torna-se mais difícil, como mostrado em Perron (1989). O autor desenvolve como alternativa um teste de raiz unitária considerando conhecido o momento da quebra. Tal procedimento sofreu críticas de autores como Zivot e Andrews (2002), os quais alegavam que os pontos de quebra escolhidos por Perron (1989) eram endógenos, uma vez que foram estabelecidos após a inspeção visual dos dados e atribuídos a eventos conhecidos, como a crise de 1929 e o choque do petróleo de 1973.¹⁰ Em face disso, os autores propõem um teste de raiz unitária com quebra estrutural em que a escolha do ponto de quebra é endógena. O ponto escolhido é aquele cujo resultado é o menos favorável à hipótese de raiz unitária.

Outra questão relevante são as transformações na série realizadas com vistas a tratar a característica de sazonalidade dos dados. Isto pode ser feito durante o processo de estimação, incluindo *dummies* sazonais na regressão ou antes da modelagem, através de procedimentos de ajuste sazonal.¹¹ Contudo, há casos em que o componente sazonal causa mudanças persistentes na série, como reflexo da existência de uma raiz unitária sazonal. Da mesma forma como ocorre com os testes de raiz unitária, diversas formulações foram propostas para identificação da ordem de integração sazonal de séries de tempo (OSBORN et al., 1988; HYLLEBERG et al., 1990; CANOVA; HANSEN, 1995).¹² Para

⁹Diversos autores propuseram formas alternativas de testar a presença de raiz unitária. Alguns exemplos são Phillips e Perron (1988) e Elliot et al. (1996). Para testes sob a hipótese nula de não existência de raiz unitária, ver o teste KPSS de Kwiatkowski et al. (1992).

¹⁰Zivot e Andrews (2002) argumentam que outros grandes eventos exógenos, como o corte de impostos de 1964, a guerra do Vietnã e a desregulamentação financeira da década de 1980 seriam também candidatas a potenciais pontos de quebra.

¹¹Mesmo a utilização de filtros, como X11, X12 ou X13-ARIMA-SEATS podem distorcer a dinâmica de um modelo estimado, como discutido por Wallis (1974).

¹²Analogamente ao teste KPSS, o teste de Canova e Hansen (1995) testa a hipótese nula de não existência de raiz unitária sazonal, enquanto a nula dos demais é de um processo sazonal integrado.

dados mensais, um procedimento comumente aplicado é o de Beaulieu e Miron (1993), que estendem para essa frequência o teste proposto por Hylleberg et al. (1990) formulado originalmente para séries trimestrais. Com isto, é possível testar a presença de raiz unitária para outras frequências além da frequência zero.¹³

Tendo em vista estes aspectos, os testes ADF, ZA e HEGY foram aplicados para as séries mensais e trimestrais do IPI. Os resultados encontram-se no apêndice A. Em linhas gerais, os testes apontaram existência de raiz unitária em nível, mesmo quando considerada a existência de quebra estrutural. Ademais, algumas das formas funcionais utilizadas no teste HEGY apontaram não-rejeição de raiz unitária em certas frequências nas séries sem ajuste sazonal. Em face dos resultados obtidos, escolhemos modelar tanto as séries com diferença sazonal, quanto as séries em primeira diferença, nas frequências mensal e trimestral. Desta forma, serão consideradas quatro séries y_t , quais sejam: ΔY_t^{mensal} , $\Delta_{12} Y_t^{mensal}$, ΔY_t^{trim} , $\Delta_4 Y_t^{trim}$, em que Y_t corresponde a $100\log(IPI_t)$.¹⁴

Foram testados modelos autoregressivos de ordem p com mudança de regime no intercepto, na variância e no intercepto e na variância, doravante $MSI-AR(p)$, $MSH-AR(p)$ e $MSIH-AR(p)$, respectivamente. Para ambas as frequências, foram testadas defasagens entre 0 e 12 meses. Seguindo Krolzig (1997), para escolha do modelo final foram utilizados o critério de informação de Schwartz (BIC), bem como testes de razão de verossimilhança para avaliar restrições sobre os parâmetros dos modelos. Na maioria dos casos, modelos com mudança de regime no intercepto e na variância (MSIH) foram preferidos a modelos com mudança em apenas um destes parâmetros, considerando-se um nível de significância de 5% nos testes de razão de verossimilhança, em todos os *lags*. Por outro lado, fixado o modelo MSIH em cada uma das séries modeladas, raramente os critérios adotados apontavam a escolha de um mesmo número de *lags*. Nestes casos, adotou-se o critério de parcimônia para escolha da ordem autoregressiva dos modelos.

Com relação ao número de regimes, optou-se por utilizar modelos apenas com dois estados, interpretando-os como regimes de expansão e recessão, de acordo com o sinal estimado para a constante em cada um dos mesmos. A tabela no Apêndice B resume os resultados encontrados com os modelos escolhidos. Todos os modelos, independentemente da frequência e da diferença utilizada foram capazes de identificar períodos de crescimento positivo (expansão) e negativo (recessão) na produção da indústria geral brasileira. Para as variáveis mensais, a taxa de crescimento em expansão foi igual para as duas transformações consideradas, enquanto em recessão, a taxa de crescimento negativa foi substancialmente menor para a primeira diferença do que para o modelo com diferença

¹³Para uma discussão sobre a performance destes e outros testes de raiz unitária sazonal, ver Rodrigues e Osborn (1999).

¹⁴Beaulieu e Miron (1993) argumentam que "[...] the appropriateness of applying the filter $(1 - B^d)$ to a series with a seasonal component, as advocated by Box and Jenkins (1970), depends on the series being integrated at frequency zero **and all** of the seasonal frequencies." Contudo, uma vez que o poder destes testes "nunca é perfeito", como reconhecido pelos autores, escolheu-se realizar a modelagem também com a série em diferença sazonal.

anual. Por outro lado, o modelo em primeira diferença apresenta menor variância, para ambos os regimes. Já os modelos com dados trimestrais apontam grandes diferenças entre as taxas de crescimento dos dois regimes. Por outro lado, a diferença na variância entre regimes de expansão e recessão é maior no modelo com primeira diferença. É interessante notar também que a probabilidade de manter-se em regime de expansão é similar para todas as frequências estudadas.

A análise dos modelos com dados mensais e trimestrais sugere que a frequência mais baixa é mais apropriada para a identificação de regimes contíguos associados a flutuações cíclicas. Conforme observado na figura 1, as probabilidades suavizadas de transição apresentam grande variabilidade com dados mensais, entre um mês e outro.

2.3.1.1 Sensibilidade das datações às séries modeladas

Uma das principais vantagens dos modelos de mudança markoviana de regime é a possibilidade de classificação de períodos de expansão e recessão na economia de maneira endógena. Conforme discutido anteriormente, o IPI apresenta alta conformidade cíclica com a atividade econômica geral. Destarte, investigaremos a correlação existente entre as probabilidades de recessão na produção industrial e a cronologia proposta pelo Comitê de Datação dos Ciclos Econômicos (CODACE/FGV-IBRE). A Figura 1 ilustra os resultados.

Em linhas gerais, nos quatro modelos estudados, nota-se que as probabilidades de recessão no IPI aumentam substancialmente próximo a períodos em que o CODACE identifica as recessões nacionais. Contudo, a utilização de um cut-off de 50% para classificação de períodos de recessão torna-se menos útil quando considerados dados mensais, uma vez que ocorrem mudanças bruscas nas probabilidades suavizadas de recessão entre um mês e outro, conforme notado na seção anterior. Tais resultados ocorrem independentemente da transformação feita na série em nível, i.e. se a primeira diferença ou a diferença anual é modelada.

Por outro lado, as probabilidades suavizadas, para os modelos com dados trimestrais sustentam maiores períodos contíguos de altas probabilidades de recessão, tornando mais apropriada a classificação de períodos de expansão e recessão usando o cut-off de 50%. Há contudo diferenças interessantes entre os modelos com transformações diferentes nesta frequência.

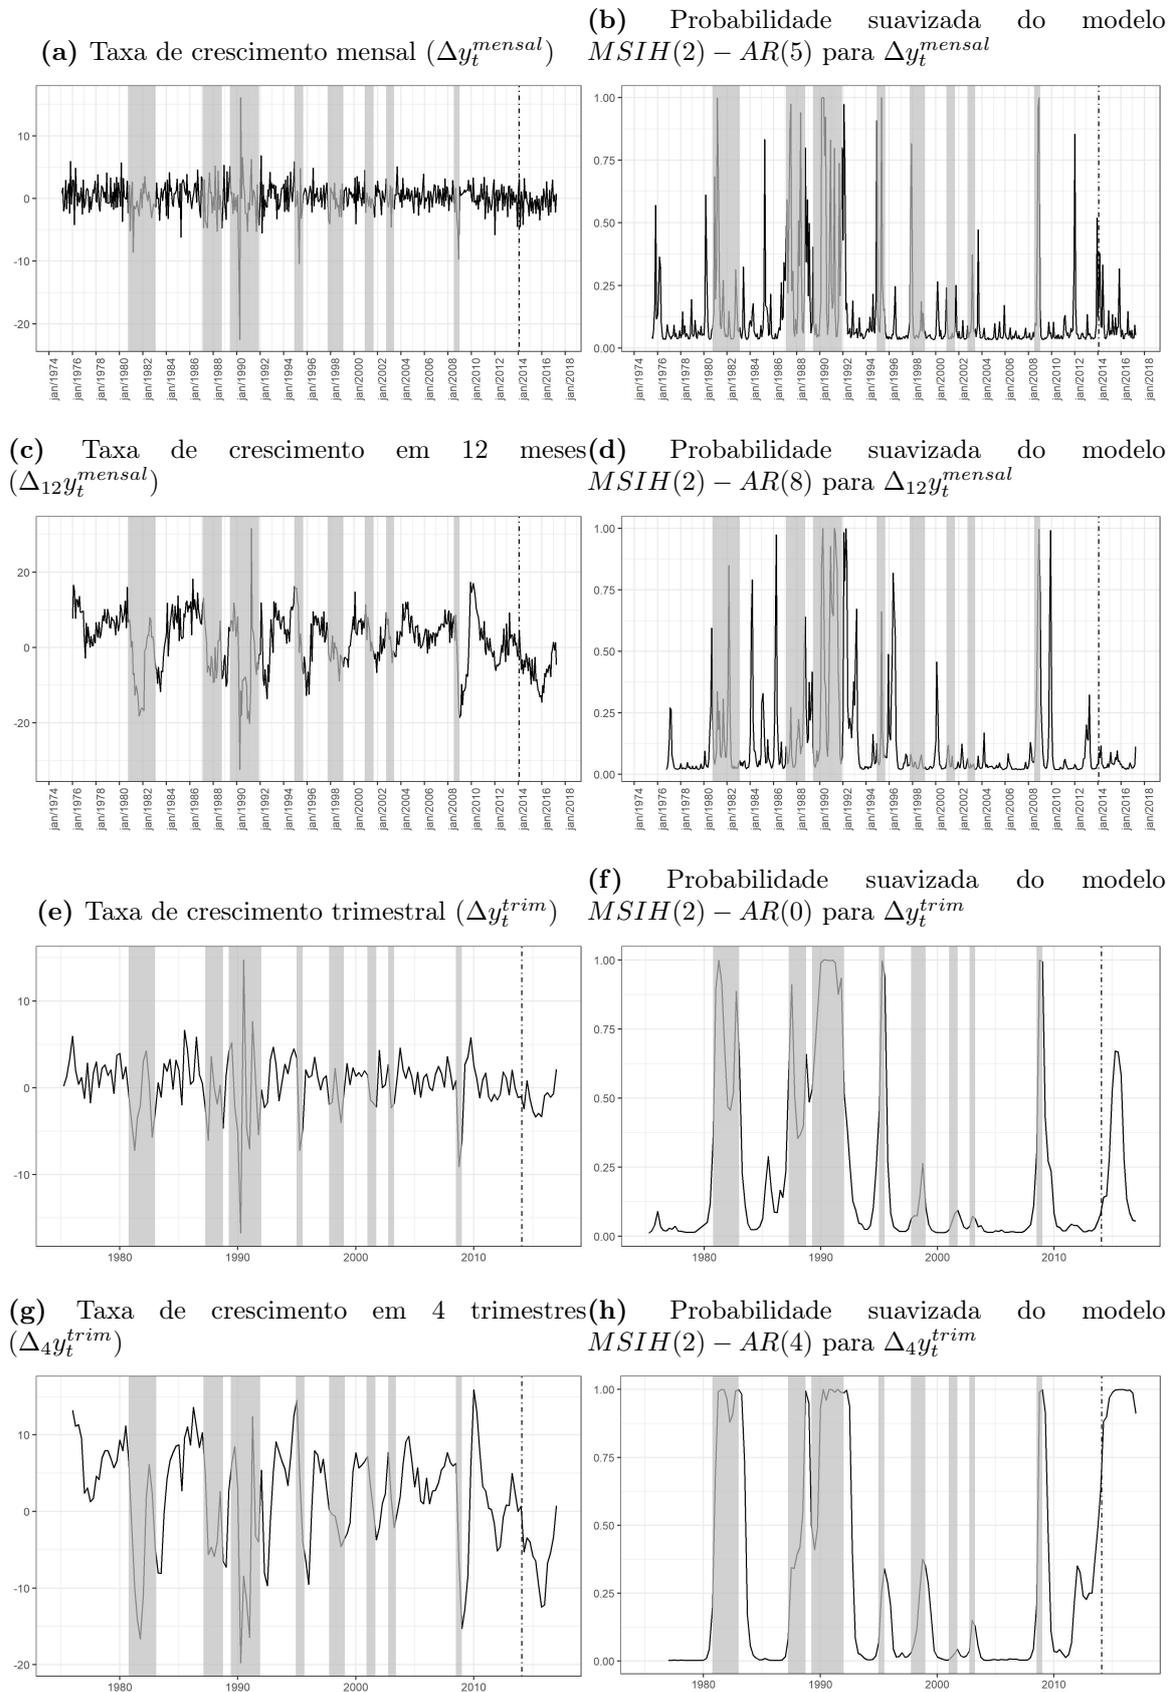
Em primeiro lugar, no modelo com primeira diferença as probabilidades caem abaixo de 50% junto ao fim da recessão nacional de 1989 – 1992, enquanto no modelo com diferença anual as probabilidades sem mantêm acima deste nível por mais alguns trimestres. Em segundo lugar, durante a recessão nacional de 1995, apenas no modelo com primeira diferença as probabilidades atingem a marca de 50%; nas três recessões seguintes - 1997 – 1999, 2001 e 2002 – 2003 - ambos os modelos falharam na identificação do período

recessivo.¹⁵

Outro fato digno de nota na diferença entre os modelos é o aumento da probabilidade de recessão - em níveis semelhantes aos as recessões da década de 1990 - no modelo com diferença anual em 2011. Analisando-se os gráficos das taxas de crescimento (à esquerda) é possível notar que em ambas as séries ocorre um intervalo de taxas de crescimento negativas neste período, intercalado por um novo patamar de crescimento positivo antes da identificação do pico pelo CODACE no primeiro trimestre de 2014. Ademais, ambos os modelos captam o início da recessão iniciada em 2014; no entanto, as probabilidades tardam a subir acima de 50% no modelo em primeira diferença, enquanto a transição de patamar de probabilidades no modelo com diferença anual é praticamente simultânea à identificação do pico. Finalmente, ao fim da amostra, as probabilidades de recessão no modelo em primeira diferença retornam a patamares abaixo de 50% sugerindo o fim da recessão, enquanto o modelo com diferença anual aponta probabilidades de recessão acima deste patamar, fornecendo um sinal ambíguo sobre o fim da última recessão.

¹⁵É interessante ressaltar que problema semelhante foi discutido por Wall (2006) para o caso do Japão. No entanto, quando o autor considerou a existência de quebra estrutural na série, o novo modelo captou os períodos de recessão perdidos, identificando inclusive um período não considerado pelo ESRI como recessão.

Figura 2.1: Taxas de crescimento do IPI - Indústria Geral do Brasil, probabilidades suavizadas de recessão na indústria e o ciclo de negócios brasileiro



2.3.1.2 *Timing* e Duração: Ciclos da indústria ou ciclos de negócios?

Nos modelos com séries trimestrais é possível identificar os *turning points* na produção da indústria, formando uma cronologia de recessões e expansões através de um cut-off de 50%. Na subseção anterior tal cronologia foi contrastada com aquela do CODACE. Contudo, cabe investigar se os resultados encontrados com os modelos paramétricos se sustentam diante de metodologias alternativas de datação de ciclos. Nesta subseção, comparamos os resultados dos modelos com uma regra de datação não-paramétrica: o algoritmo Bry-Boschan modificado para dados trimestrais (BBQ), de Harding e Pagan (2002).

A tabela 1 mostra as datas de picos e vales encontradas por meio do algoritmo BBQ aplicado às séries em nível, com e sem ajuste sazonal, bem como os pontos de virada da economia brasileira e aqueles apontados pelos modelos paramétricos. Ressalta-se que neste trabalho, o pico é identificado como o último trimestre de um período de expansão. A partir do trimestre seguinte inicia-se a recessão, que segue até um vale, identificado como último trimestre de recessão.

Os resultados apontam uma grande similaridade entre datas de picos e vales, entre os diferentes métodos de datação e entre estes e as datas elegidas pelo CODACE. No entanto, tomando-se como *benchmark* os pontos de virada da economia brasileira, é possível observar mini-fases de recessão, sobretudo no método BBQ, havendo porém fases curtas também identificadas no modelo MSIH(2)-AR(0) com dados em primeira diferença nas recessões da década de 1980. Merece destaque também o fato de o método BBQ para os dados com ajuste sazonal ser o único a captar a recessão de 2001. Ademais, com o método BBQ houve a identificação de um período de recessão na produção industrial em 2011/2012, ignorado tanto pelo modelo paramétrico da primeira diferença quanto pelo CODACE, mas, conforme ressaltado na seção anterior, apontado, ainda que com baixa probabilidade, pelo modelo com diferença anual. Este fato pode ser um indicativo de que houve um período de recessão específico da indústria, sem consonância com movimentos mais amplos da economia. Por fim, todos os métodos, com exceção do modelo MSIH(2)-AR(0) com dados em primeira diferença, foram incapazes de identificar um vale para a recessão nacional iniciada em 2014.

A análise dos dados da indústria nacional permitem chegar a duas conclusões. Primeiramente, a utilização de dados mensais para identificação de uma cronologia de recessão da indústria com modelos de mudança markoviana de regime é dificultada pela grande variabilidade nas probabilidades de recessão estimadas. Neste sentido, a análise com dados trimestrais mostra-se mais apropriada. Em segundo lugar, os modelos escolhidos falham em captar recessões mais brandas, como as do fim da década de 1990 e início da década de 2000.

Seguindo com o objetivo de realizar a análise baseada nos modelos de mudança mar-

Tabela 2.1: Identificação de picos e vales - Dados trimestrais

CODACE/FGV-IBRE		BBQ - y_t sem ajuste sazonal		BBQ - y_t com ajuste sazonal		MSIH(2)-AR(0) para Δy_t^{trim}		MSIH(2)-AR(12) para $\Delta_4 y_t^{trim}$	
Pico	Vale	Pico	Vale	Pico	Vale	Pico	Vale	Pico	Vale
1980 Q4	-	1980 Q3	-	1980 Q3	1981 Q4	1980 Q4	1981 Q4	1980 Q4	-
-	1983 Q1	-	1983 Q1	1982 Q3	1983 Q3	1982 Q2	1983 Q1	-	1983 Q3
1987 Q2	1988 Q4	1986 Q3	1989 Q1	1987 Q1	1988 Q4	1987 Q1	1987 Q4	1988 Q2	-
-	-	-	-	1989 Q3	1990 Q2	1988 Q3	1988 Q4	-	1989 Q1
1989 Q2	1992 Q1	1989 Q3	1991 Q1	1991 Q3	1992 Q3	1989 Q1	-	1989 Q4	-
-	-	-	-	-	-	-	1992 Q1	-	1992 Q3
1995 Q1	1995 Q3	1994 Q3	1996 Q1	1995 Q1	1995 Q3	1995 Q1	1995 Q3	-	-
1997 Q4	1999 Q1	1997 Q3	1999 Q1	1997 Q3	1999 Q1	-	-	-	-
2001 Q1	2001 Q4	-	-	2001 Q1	2001 Q4	-	-	-	-
2002 Q4	2003 Q2	2002 Q3	2003 Q1	2002 Q4	2003 Q2	-	-	-	-
2008 Q3	2009 Q1	2008 Q3	2009 Q1	2008 Q3	2009 Q1	2008 Q3	2009 Q1	2008 Q3	2009 Q2
-	-	2011 Q3	2012 Q1	2011 Q1	2012 Q2	-	-	-	-
2014 Q1	-	2013 Q3	2015 Q1	2013 Q2	-	2014 Q4	2015 Q4	2013 Q4	-
-	-	2015 Q3	2016 Q1	-	-	-	-	-	-
-	-	2016 Q3	-	-	-	-	-	-	-

koviana, uma vez que modelagem da série em primeira diferença gerou menos "sinais perdidos" e menos "sinais falsos" com relação à cronologia do CODACE e ao algoritmo Bry-Boschan, utilizaremos a mesma como *benchmark* para as recessões na indústria nas próximas seções.

2.3.2 Análise setorial: indústrias diferentes, ciclos comuns?

Para testar hipóteses de não-linearidade ou mesmo identificar o processo gerador de dados, a inclusão de ordens autoregressivas mais altas que zero podem ser importantes. Contudo, como argumentado por Owyang et al. (2005) para identificação de períodos de regimes de crescimento positivo ou negativo associados a fases cíclicas de um indicador, um modelo simples de cadeia de Markov oculta pode ser suficiente. Ausência de um componente autoregressivo podem ser notadas em modelagens do PIB brasileiro (CHAUVET, 2002; PEREIRA; VIEIRA, 2013) e da produção da indústria (PROTUGAL; MORAIS, 2008). Utilizando um modelo MSIH(2)-AR(0), para a primeira diferença dos dados trimestrais com ajuste sazonal¹⁶ - a análise setorial é conduzida considerando-se o âmbito da indústria extrativa e de transformação nacionais, respectivamente seções B e C da CNAE 2.0, conforme divulgado pelo IBGE, no período de 1^oTrim./2002 a 1^oTrim./2017.¹⁷ Optou-se por utilizar este nível de desagregação setorial por dois motivos. Primeiro, o IBGE divulga as atividades da indústria extrativa de forma agregada apenas. Segundo, apesar de uma maior abertura de dados da indústria de transformação ser disponibilizada, uma análise mais detalhada de outras divisões da CNAE 2.0 tornaria a análise demasiado extensa. Apesar destas limitações, a abertura entre estes dois setores permite identificar algumas comunalidades e diferenças entre seus ciclos, sugerindo que

¹⁶Da mesma forma que na análise nacional, os dados sem ajuste sazonal foram coletados do IBGE, agregados e dessazonalizados, utilizando o programa X13-ARIMA-SEATS.

¹⁷Paralelamente, apenas para o nível nacional, os produtos selecionados são organizados também segundo a Classificação por Grandes Categorias Econômicas - CGCE, do IBGE, grupos e classes selecionados (três e quatro dígitos da CNAE 2.0) e indicadores especiais (que são agregações de produtos selecionados). Para maior detalhamento dos Indicadores Conjunturais da Indústria, ver IBGE (2015).

atenção deve ser dada às idiosincrasias de cada tipo de indústria.

A tabela 2 apresenta taxas de crescimento trimestrais médias nas indústrias extrativa e de transformação para o período I/2002 a I/2017, para os períodos de expansão e recessão identificados pelos modelos MSIH(2)-AR(0), bem como a diferença entre as taxas de crescimento. O crescimento médio no período na indústria de transformação representa um décimo daquele observado na extrativa. Da mesma forma, em períodos de expansão, o crescimento médio é maior na indústria extrativa. Contudo, as duas taxas são semelhantes nos períodos de recessão estimados. A diferença de crescimento entre os regimes na extrativa é de 2,54 p.p., enquanto na transformação é de 1,56.

Tabela 2.2: Taxas de crescimento trimestrais por setor da indústria - II/1991-I/2017

	(1) Crescimento médio no período	(2) Crescimento médio em expansão	(3) Crescimento médio em recessão	(2)-(3)
Extrativa	0.71 (0.44)	1.33 (0.3)	-1.21 (2.41)	2.54
Transformação	0.07 (0.32)	0.46 (0.33)	-1.1 (1.16)	1.56

NOTA: erro-padrão entre parênteses.

É interessante notar também que, para os trimestres analisados, os modelos identificaram dois períodos de recessão na indústria de transformação - ambos coincidindo em maior ou menor grau a períodos de recessão na indústria geral nacional - e quatro na indústria extrativa, sendo um deles representado por apenas um trimestre (II/2005) e outro descontínuo entre III/2012 e II/2013.

DA tabela 3 apresenta os períodos recessivos nos diferentes setores da indústria, marcados com um X. As áreas em cinza representam os períodos recessivos da indústria geral, conforme estimado na seção anterior. Conforme é possível notar, o início e fim das recessões setoriais não é necessariamente coincidente com aqueles do agregado da indústria. A crise de 2008, por exemplo, apesar de findada no primeiro trimestre de 2009 com os dados agregados, prolongou-se individualmente entre os setores. De forma semelhante, a indústria de transformação inicia sua recessão no segundo trimestre de 2014 - junto à data de início da recessão pelo CODACE - embora a recessão na indústria geral comece apenas no primeiro trimestre de 2015, de acordo com o modelo estimado na seção anterior.

Tabela 2.3: Recessões setoriais

Setor	II.2002	III.2002	IV.2002	I.2003	II.2003	III.2003	IV.2003	I.2004	II.2004	III.2004	IV.2004	I.2005	II.2005	III.2005	IV.2005	I.2006	II.2006	III.2006	IV.2006	I.2007	II.2007	III.2007	IV.2007	I.2008	II.2008	III.2008	IV.2008	I.2009	II.2009	III.2009	IV.2009
Extrativa													X														X	X	X	X	
Transformação																											X	X	X	X	X

Setor	I.2010	II.2010	III.2010	IV.2010	I.2011	II.2011	III.2011	IV.2011	I.2012	II.2012	III.2012	IV.2012	I.2013	II.2013	III.2013	IV.2013	I.2014	II.2014	III.2014	IV.2014	I.2015	II.2015	III.2015	IV.2015	I.2016	II.2016	III.2016	IV.2016	I.2017	II.2017	III.2017	IV.2017
Extrativa	X									X		X	X									X	X	X								
Transformação	X																X	X	X		X	X	X	X								

2.3.3 Análise regional: a geografia dos ciclos na produção industrial

Através da análise nacional foi possível identificar períodos de expansão e recessão na atividade de produção da indústria geral. Contudo, assim como a desagregação entre indústrias revelou padrões cíclicos específicos de determinados setores - e.g. a indústria extrativa - a desagregação regional permite explorar melhor uma possível diversidade de padrões cíclicos entre Unidades Federativas. Utilizaremos também nesta seção o modelo MSIH(2)-AR(0) com mudança de regime na média e na variância para explorar estas hipóteses.

A tabela 4 apresenta, de forma semelhante à tabela 2, as taxas de crescimento para as diversas UF's e os períodos de aquecimento e desaquecimento detectados, assim como sua diferença.¹⁸ Ressalta-se que as séries foram ajustadas sazonalmente e que o tamanho da amostra varia para cada estado. Alguns aspectos chamam a atenção. Em primeiro lugar, Pernambuco é o único estado a apresentar crescimento médio negativo no período. Além disso, mesmo em período de aquecimento, o modelo captou uma taxa de crescimento negativa. Ademais, merece destaque o estado do Pará, com a maior taxa de crescimento, tanto em expansão quanto no período todo. Este resultado é condizente com a análise setorial, que apontou uma alta taxa de crescimento da indústria extrativa, uma vez que o Pará é um dos seis estados, dentre os 14 para os quais constam dados da PIM-PF, onde a indústria extrativa é relevante.¹⁹

Já nos períodos de desaquecimento estimados, todos os estados, com exceção de Pará, Paraná e Goiás apresentam taxas de crescimento negativas. Uma possível explicação para este fenômeno, sobretudo nestes dois últimos estados, é sua associação à produção de soja no país, que teve uma expansão forte nas últimas décadas. Embora ligada ao agronegócio, a cadeia da soja movimenta diversos setores da indústria, em especial, o setor de máquinas e equipamentos agrícolas.²⁰ Por fim, a maior diferença de crescimento entre períodos de aquecimento e desaquecimento advém do Espírito Santo, enquanto a menor é do Pará.

A figura 2 mostra as probabilidades suavizadas de desaquecimento contrapostas às

¹⁸Optamos por nos referir aos diferentes regimes identificados pelos modelos como "aquecimento" e "desaquecimento" ao invés de "expansão" e "recessão" devido ao fato de que os valores estimados para o período de baixo crescimento não serem necessariamente negativos para todos os estados. Quando são negativos, chamaremos de "recessão estadual na produção industrial".

¹⁹Os estados para os quais há dados da PIM-PF são Amazonas, Pará, Ceará, Pernambuco, Bahia, Minas Gerais, Espírito Santo, Rio de Janeiro, São Paulo, Paraná, Santa Catarina, Rio Grande do Sul, Mato Grosso (não analisado neste trabalho devido à amostra pequena, iniciada em 2012) e Goiás. Todos apresentam dados de indústria de transformação. Contudo, apenas Amazonas, Pará, Bahia, Minas Gerais, Espírito Santo, Rio de Janeiro e Goiás possuem amostra de indústria extrativa. Ver Apêndice C.

²⁰Apesar de interessante, esta hipótese não será aqui testada.

Tabela 2.4: Taxas de crescimento trimestrais por UF

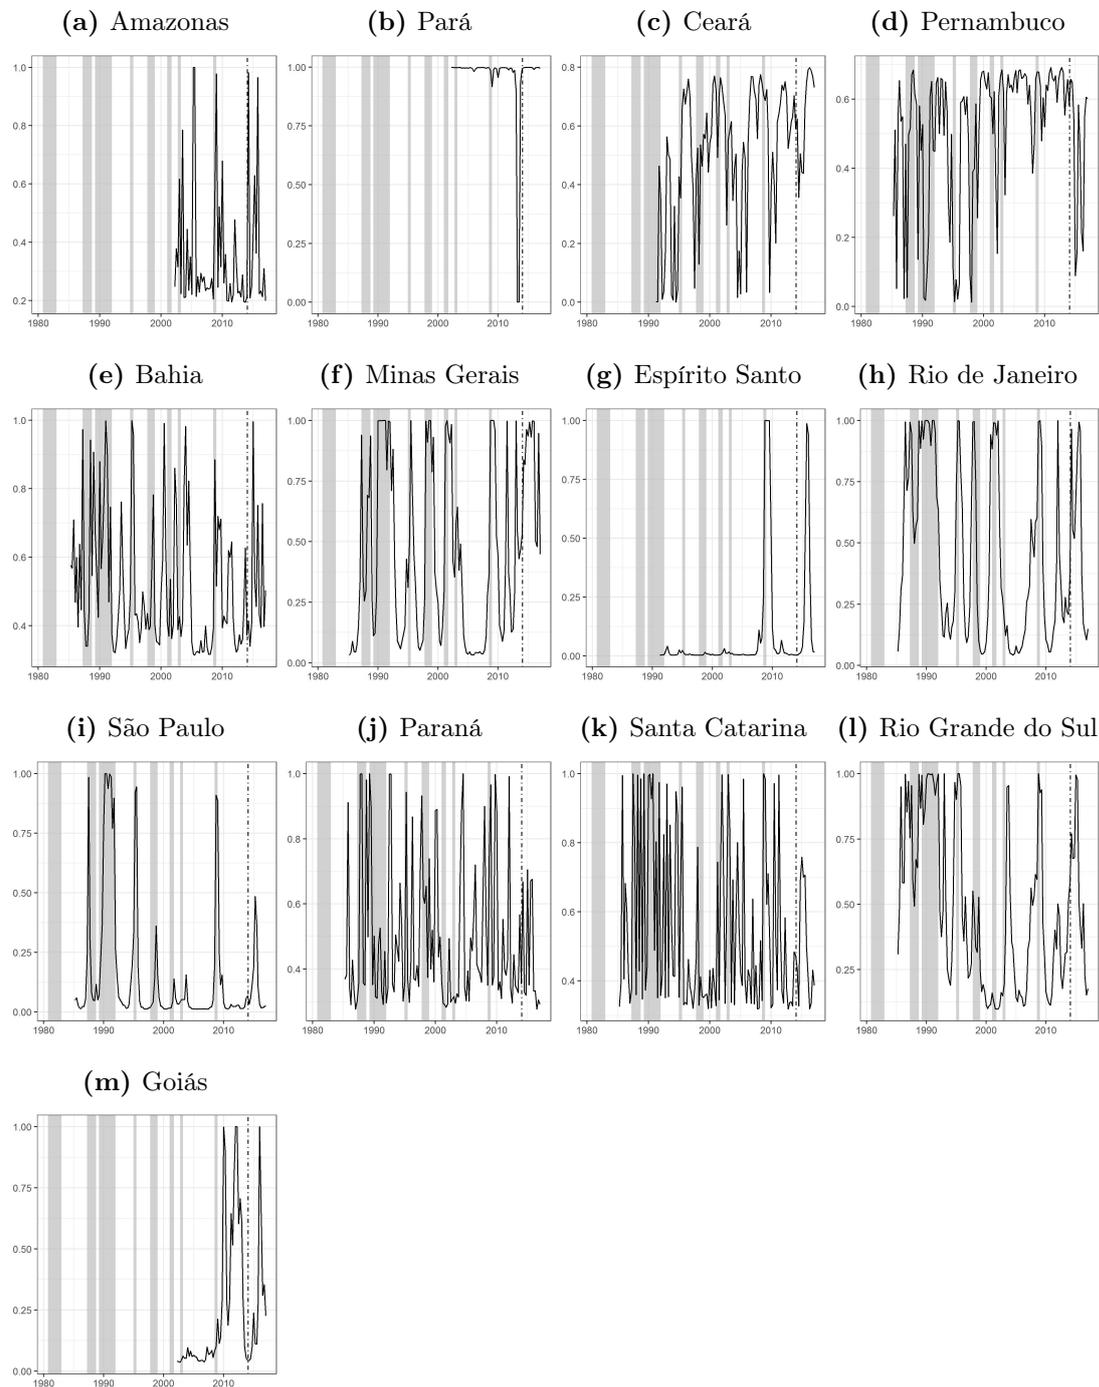
	(1) Crescimento médio no período	(2) Crescimento médio em aquecimento	(3) Crescimento médio em desaquecimento	(2)-(3)
AM	0.17 (0.76)	0.75 (0.64)	-0.85 (3.1)	1.6
PA	1.2 (0.47)	1.28 (9.56)	1.2 (0.26)	0.08
CE	0.27 (0.47)	0.92 (1.21)	-0.35 (0.74)	1.27
PE	-0.2 (0.59)	-0.07 (1.81)	-0.33 (1.21)	0.26
BA	0.14 (0.43)	0.76 (0.76)	-0.46 (0.73)	1.22
MG	0.33 (0.32)	1.44 (0.24)	-0.97 (0.79)	2.41
ES	0.72 (0.49)	1.1 (0.34)	-3.17 (4.29)	4.27
RJ	0.4 (0.31)	0.94 (0.26)	-0.23 (0.67)	1.17
SP	0.14 (0.38)	0.67 (0.32)	-2.64 (2.09)	3.31
PR	0.53 (0.42)	0.58 (1.08)	0.47 (0.69)	0.11
SC	0.19 (0.33)	0.82 (0.75)	-0.34 (1.12)	1.16
RS	0.15 (0.39)	0.57 (0.45)	-0.28 (0.81)	0.85
GO	0.9 (0.49)	1.05 (0.38)	0.48 (1.74)	0.57

datações de recessão do CODACE.²¹ Conforme esperado, as probabilidades na maior parte dos estados tendem a se elevar próximo a períodos identificados pelo CODACE como recessão. Este padrão é mais facilmente visto nos estados de Minas Gerais, Rio de Janeiro, São Paulo e Rio Grande do Sul. Nos demais estados, há maior oscilação nas probabilidades de desaquecimento. Por outro lado, um caso que também chama a atenção, novamente, é o do Pará, onde a maior parte do tempo permanece em desaquecimento, com exceção de um rápido período em 2013.²²

²¹Para os estados do Amazonas, Pará e Goiás, não havia amostra disponível para o período anterior a 2002.

²²Isto se deve à presença de um outlier na série no período, captado como período expansivo.

Figura 2.2: Probabilidades suavizadas de desaquecimento nas indústrias regionais e o ciclo de negócios brasileiro



NOTA: As áreas hachuradas correspondem aos períodos de recessão, compreendidos entre os picos e vales da economia brasileira identificados pelo CODACE. A linha pontilhada indica o último pico registrado pelo CODACE no 1ºtrim. de 2014, não havendo, até a submissão deste texto, uma data oficial para o vale deste ciclo.

Por fim, é importante explorar diferenças e similitudes nos padrões geográficos dos ciclos da produção industrial. Uma vez que o período para o qual há dados para todos os

estados considerados na análise é de 2002 em diante e neste período só foram capturados dois períodos recessivos na produção industrial, conforme discutido na seção 3 - quais sejam, as recessões de 2008/2009 e 2015 - realizaremos a análise em períodos selecionados ao redor dos *turning points* estimados naquela seção.

Iniciando pela recessão na produção industrial com pico em III/2008 e vale em I/2009 (figura 3), parece haver um padrão de "contaminação" na trajetória da recessão entre os estados. Nos primeiro trimestre de 2008, apenas Rio Grande do Sul, Paraná, Pará e Ceará apresentavam desaquecimento. Conforme se aproximava o pico na indústria nacional, mais estados ingressavam em uma fase de baixo/negativo crescimento. Contudo, nos dois trimestres após o pico (IV/2008 e I/2009), todos os estados, com exceção de Goiás encontravam-se neste regime.

Figura 2.3: Recessão na indústria nacional agregada: IV/2008 a I/2009

(a) I/2008



(b) II/2008



(d) IV/2008



(e) I/2009



NOTA: *As áreas em cinza escuro representam desaquecimento, enquanto áreas em cinza claro representam aquecimento. UF's com áreas em branco não possuem dados na amostra.*

Este padrão, contudo, não parece presente na última recessão da amostra, com pico em IV/2014 e vale em IV/2015. Conforme observado na figura 4, há entrada e saída de UF's em estados de aquecimento e desaquecimento. Mesmo durante os trimestres centrais da recessão este comportamento se mantém. No entanto, findada a recessão setorial, nota-

se que a maior parte dos estados ingressa em uma fase de aquecimento, em consonância com o *benchmark* da produção industrial nacional. Em I/2017, apenas estados do norte e nordeste se mantinham em regime de desaquecimento.

Figura 2.4: Recessão na indústria nacional agregada: I/2015 a IV/2015

(a) I/2014



(b) II/2014



(d) Pico: IV/2014



(e) I/2015



(f) II/2015



(g) III/2015



(i) I/2016



(j) I/2017



NOTA: As áreas em cinza escuro representam desaquecimento, enquanto áreas em cinza claro representam aquecimento. UF's com áreas em branco não possuem dados na amostra.

2.4 Conclusão

O índice de produção industrial (IPI) é comumente utilizado na literatura para acessar o estado da economia, isto é, fases de expansão e recessão na atividade econômica. Embora este indicador apresente deficiências como medida representativa da atividade econômica agregada - e.g. PIB, PNB ou mesmo indicadores compostos coincidentes cumprem melhor esta função -, trata-se de um indicador importante para análise dos ciclos de negócios, seja pelo alto peso da produção da indústria no PIB, sobretudo no século XX, seja por sua correlação cíclica com outras medidas da atividade agregada. Com base nisto, analisamos as flutuações cíclicas em diferentes níveis de agregação, com objetivo de integrar a análise dos ciclos na indústria em suas dimensões setorial e regional à análise dos ciclos nacionais. Para tanto, foram utilizados modelos de mudança markoviana de regime.

Primeiramente, modelamos o IPI agregado nacional, explorando diferenças na identificação dos regimes de expansão e recessão, conforme a frequência dos dados - mensal e trimestral - e a transformação - primeira diferença ou diferença anual - neles realizada. Os resultados mostram, em todos os casos, uma forte correlação nos períodos de regimes de recessão na produção industrial encontrados pelos modelos e cronologia das recessões no Brasil estabelecidas pelo CODACE. No entanto, é notório que os modelos com dados trimestrais se mostram mais interessantes para o estudo da cronologia dos ciclos, uma vez que as probabilidades suavizadas de recessão estimadas são menos voláteis do que nos casos com dados mensais. Além disso, há grande similaridade nas datações obtidas entre os modelos paramétricos e regras de datação não-paramétricas, como o algoritmo Bry-Boschan. Os modelos paramétricos, contudo, falharam em captar as recessões do fim da década de 1990 e início da década de 2000 com o uso da regra de cut-off de 50% para as probabilidades estimadas. Uma vez que o modelo da série em primeira diferença apresentou menos sinais perdidos de recessão dentre os modelos paramétricos, a cronologia estabelecida pelo mesmo foi utilizada como *benchmark* de ciclos na indústria brasileira.

A análise desagregada, conduzida com modelos de Cadeia de Markov Oculta com mudanças de regime na variância identificaram fases recessivas nas indústrias de transformação e extrativa, onde a primeira apresenta maior sincronia com os ciclos na indústria nacional, identificando-se períodos recessivos específicos na indústria extrativa. Usando a mesma classe de modelos, não foi possível identificar em todos os estados analisados fases recessivas, uma vez que algumas UF's, como Pará, Paraná e Goiás, apresentam taxas de crescimento positivas nos dois regimes, identificadas como fases de aquecimento e desaquecimento em sua produção industrial. Em alguns casos, estes resultados podem ter sido provocados pela má especificação dos modelos e presença de outliers nos dados. No entanto os modelos sinalizaram alta sincronia entre recessões nacionais e as probabilidades de recessões em estados do sul e sudeste. Estudos futuros deverão explorar modelos com dinâmicas mais complexas na análise desagregada, por exemplo, incluindo

componentes autoregressivos ou mesmo considerando um número maior de regimes para confirmação dos resultados aqui encontrados, uma vez que para alguns estados os modelos MS(2)-AR(0) não se mostraram satisfatórios. Por fim, com estes modelos observou-se um padrão de trajetória da recessão entre os estados no período de 2008/2009, após a data de pico no IPI, o qual se mantém até o vale do ciclo. Contudo, este fenômeno não se repetiu na recessão da indústria de 2015. Durante o período, diferentes estados oscilavam entre períodos de expansão e recessão. Contudo, os dados mais recentes sugerem o arrefecimento da recessão na maior parte deles.

Como última ressalva, é importante destacar que o estudo não tem objetivo de exaurir as possibilidades de análise do "estado da economia" com uso de indicadores de produção física da indústria. O que se buscou foi integrar as análises em diferentes níveis de agregação com objetivo de identificar e estudar os padrões cíclicos para estes níveis de abertura dos dados. Ressalta-se contudo, que avanços ainda são necessários. Em primeiro lugar, conforme discutido, há de se considerar novas especificações para os modelos com dados desagregados. Além disso, trabalhos futuros deverão explorar ciclos nas diferentes indústrias de transformação, com vistas a levantar hipóteses sobre as origens das flutuações na indústria agregada, ou mesmo nas economias regionais. Este exercício poderá ajudar a identificar, inclusive, possíveis fatores que expliquem as taxas de crescimento em cada estado, em cada um dos regimes, e as diferenças e similaridades em seu comportamento cíclico, como sugerido em Owyang et al. (2005).

Referências

BEAULIEU, J. J.; MIRON, J. A., **Seasonal unit roots in aggregate US data**, *Journal of Econometrics* 55(1-2), 305–328, 1993. Disponível em <<https://www.sciencedirect.com/science/article/pii/030440769390018Z>>. Acesso em 12/12/2018.

BOEHM, E. A., **A review of some methodological issues in identifying and analysing business cycles**, Melbourne Institute of Applied Economic and Social Research, 1998. Disponível em <https://melbourneinstitute.unimelb.edu.au/downloads/working_papers/series/wp1998n26.pdf> .Acessoem12/12/2018.

BURNS, A. F.; MITCHELL, W. C. **Measuring business cycles**, NBER Books, 1946. Disponível em <<https://www.nber.org/books/burn46-1>>. Acesso em 12/12/2018.

CANOVA, F.; HANSEN, B. E., **Are seasonal patterns constant over time? A test for seasonal stability**, *Journal of Business Economic Statistics* 13(3), 237–252, 1995. Disponível em

<<https://amstat.tandfonline.com/doi/abs/10.1080/07350015.1995.10524598>>. Acesso em 12/12/2018.

CARVALHO, J. H. D. d.; CARVALHO, A. X. d.; ELLERY JÚNIOR, R. d. G., **Ciclo comum na indústria regional**, IPEA, 2005. Disponível em <<http://repositorio.ipea.gov.br/bitstream/11058/1651/1/TD1139.pdf> > .Acessoem10/10/2018.

CHANG, Y.; HWANG, S., **Asymmetric phase shifts in US industrial production cycles**, Review of Economics and Statistics 97(1), 116–133, 2015. Disponível em <https://www.mitpressjournals.org/doi/abs/10.1162/REST_a00436 > .Acessoem12/12/2018.

CHAUVET, M. **The Brazilian business and growth cycles**, Revista Brasileira de Economia 56(1), 75–106, 2002. Disponível em <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0034-71402002000100003 > .Acessoem12/12/2018.

CORREIA, L. B. **Sincronia dos ciclos econômicos regionais: um estudo de caso aplicado aos estados brasileiros**, PhD thesis, 2012. Disponível em <<http://bibliotecadigital.fgv.br/dspace/handle/10438/9861>>. Acesso em 12/12/2018.

CUNHA, A. ; MOREIRA, L. P., **Ciclos econômicos regionais no Brasil de 1985 a 2002: uma introdução**, Revista de Economia Contemporânea 10(1), 115–138, 2006. Disponível em <http://www.scielo.br/scielo.php?pid=S1415-98482006000100005&script=sci_abstract&lng=es > .Acessoem12/12/2018.

DICKEY, D. A.; FULLER, W. A., **Distribution of the estimators for autoregressive time series with a unit root**, Journal of the American statistical association 74(366a), 427–431, 1979. Disponível em <<https://www.tandfonline.com/doi/abs/10.1080/01621459.1979.10482531>>. Acesso em 12/12/2018.

ELLIOT, B.; ROTHENBERG, T. ; STOCK, J., **Efficient Tests for an Autoregressive Unit Root**, Econometrica 64(4), 13–36, 1996. Disponível em <https://www.jstor.org/stable/2171846?seq=1&page_scan_tabc_contents > .Acessoem12/12/2018.

EVANGELISTA, I. R., **Sincronização de ciclos econômicos para as regiões brasileiras**, 2009. Disponível em <<http://www.repositorio.ufc.br/handle/riufc/14774>>. Acesso em 07/09/2018.

FULOP, G. ; GYOMAI, G., **Transition of the OECD CLI system to a GDP-based business cycle target**, 2012. Disponível em <<http://www.oecd.org/std/leading-indicators/49985449.pdf>>. Acesso em 10/04/2015.

GYOMAI, G. ; GUIDETTI, E., **OECD system of composite leading indicators**, Organisation for Economic Co-Operation and Development (OECD), 2008. Disponível em <<http://www.oecd.org/sdd/leading-indicators/41629509.pdf>>. Acesso em 12/12/2018.

HALL, R.; FELDSTEIN, M.; FRANKEL, J.; GORDON, R.; ROMER, C.; ROMER, D. ; ZARNOWITZ, V., **The NBER's business-cycle dating procedure**, Business Cycle Dating Committee. 2003. Disponível em <<http://www.nber.org/cycles/july2003/recessions.pdf>>. Acesso em 12/12/2018.

HAMILTON, J. D., **A new approach to the economic analysis of nonstationary time series and the business cycle**, *Econometrica: Journal of the Econometric Society* pp. 357–384. 1989. Disponível em <https://www.jstor.org/stable/1912559?seq=1page_scan_tab_contents >. Acesso em 12/12/2018.

HAMILTON, J. D. , **Analysis of time series subject to changes in regime**, *Journal of Econometrics* 45(1), 39–70, 1990. Disponível em <<https://www.sciencedirect.com/science/article/pii/0304407690900939>>. Acesso em 12/12/2018.

HAMILTON, J. D., **Time series analysis**, Vol. 2, Princeton university press, Princeton, 1994.

HARDING, D. ; PAGAN, A., **Dissecting the cycle: a methodological investigation**, *Journal of monetary economics* 49(2), 365–381, 2002. Acesso em <<https://www.sciencedirect.com/science/article/abs/pii/S0304393201001088>>. Acesso em 12/12/2018.

HOLLAUER, G. ; ISSLER, J. V. **Construção de indicadores coincidentes para a atividade industrial brasileira e comparação de metodologias**, 2006. Disponível em <<http://repositorio.ipea.gov.br/handle/11058/2130>>. Acesso em 12/12/2018.

HYLLEBERG, S.; ENGLE, R. F.; GRANGER, C. W. ; YOO, B. S.. **Seasonal integration and cointegration**, *Journal of Econometrics*, 1990. Disponível em <>. Acesso em 12/12/2018. Disponível em <<https://www.sciencedirect.com/science/article/pii/030440769090080D>>. Acesso em

12/12/2018.

IBGE, **Indicadores conjunturais da indústria: Produção**, 2015. Disponível em <<https://biblioteca.ibge.gov.br/visualizacao/livros/liv94589.pdf>>. Acesso em 01/10/2012.

KIM, C.-J., NELSON, C. R. **State-space models with regime switching: Classical and Gibbs-sampling approaches with applications**, MIT Press Books, 1999.

KROLZIG, H.-M. **Markov-switching vector autoregressions: Modelling, statistical inference, and application to business cycle analysis**, Vol. 454, Springer Science Business Media, 1997.

KWIATKOWSKI, D., PHILLIPS, P. C., SCHMIDT, P. SHIN, Y.. **Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?'**, Journal of econometrics, 1992. Disponível em <<https://www.sciencedirect.com/science/article/pii/030440769290104Y>>. Acesso em 12/12/2018.

MOORE, G. H. ; ZARNOWITZ, V. **The American business cycle: Continuity and change**, University of Chicago Press, 1986. Disponível em <<https://www.nber.org/books/gord86-1>>. Acesso em 12/12/2018.

MORAIS, I. A. C. ; CHAUVET, M. **Leading indicators for the capital goods industry**, Brazilian Review of Econometrics 31(1), 2011. Disponível em <<http://bibliotecadigital.fgv.br/ojs/index.php/bre/article/view/3630>>. Acesso em 12/12/2018.

NELSON, C. R. ; PLOSSER, C. R. **Trends and random walks in macroeconomic time series: some evidence and implications'**, Journal of monetary economics, 1982. Disponível em <<https://www.sciencedirect.com/science/article/abs/pii/0304393282900125>>. Acesso em 12/12/2018.

OSBORN, D. R., CHUI, A. P., SMITH, J. P. BIRCHENHALL, C. R. **Seasonality and the order of integration for consumption**, Oxford Bulletin of Economics and Statistics, 1988. Disponível em <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1468-0084.1988.mp50004002.x>>. Acesso em 12/12/2018.

OWYANG, M. T.; PIGER, J. M.; WALL, H. J. ; WHEELER, C. H. **The economic performance of cities: A Markov-switching approach**, Journal of Urban Economics, 2008. Disponível em

<<https://www.sciencedirect.com/science/article/pii/S0094119008000557>>. Acesso em 12/12/2018.

OWYANG, M. T.; PIGER, J. ; WALL, H. J. **Business cycle phases in US states**, The Review of Economics and Statistics, 2005. Disponível em

<<https://www.mitpressjournals.org/doi/abs/10.1162/003465305775098198>>. Acesso em 12/12/2018.

PEREIRA, P. L. V. ; VIEIRA, H. P. **A study of the Brazilian business cycles (1900-2012)**, Brazilian Review of Econometrics, 2013. Disponível em

<<http://bibliotecadigital.fgv.br/ojs/index.php/bre/article/view/17176>>. Acesso em 12/12/2018.

PERRON, P. **The great crash, the oil price shock, and the unit root**

hypothesis, Econometrica: Journal of the Econometric Society, 1989. Disponível em

<<https://www.jstor.org/stable/1913712>>. Acesso em 12/12/2018.

PHILLIPS, P. C. ; PERRON, P. **Testing for a unit root in time series regression**, Biometrika, 1988. Disponível em

<<https://academic.oup.com/biomet/article-abstract/75/2/335/292919>>. Acesso em 12/12/2018.

PICCHETTI, P. **Cycles across Brazilian states: a functional data analysis**,

CIRET Con . 2010. Disponível em <<https://eesp.fgv.br/en/node/4420>>. Acesso em

12/12/2018.

PORTUGAL, M. S. ; MORAIS, I. A. C. **Business cycle in the industrial**

production of Brazilian states, Análise Econômica. Porto Alegre. vol. 26, n. 50

(set. 2008), p. 27-56, 2008. Disponível em

<<https://www.lume.ufrgs.br/handle/10183/25329>>. Acesso em 12/12/2018.

RODRIGUES, P. M. OSBORN, D. R. **Performance of seasonal unit root tests for monthly data**, Journal of Applied Statistics, 1999. Disponível em

<<https://www.tandfonline.com/doi/abs/10.1080/02664769921981>>. Acesso em 12/12/2018.

SCHUCK, G. J. **Indicadores antecedentes compostos da agroindústria**,

2012. Disponível em <<http://www.repositorio.jesuita.org.br/handle/UNISINOS/4231>>.

Acesso em 10/10/2018.

WALL, H. J. **Regional business cycle phases in Japan**, Federal Reserve Bank of St. Louis Review, 89(1), pp. 61-76, 2007. Disponível em https://papers.ssrn.com/sol3/papers.cfm?abstract_id=931204 > .Acessoem12/12/2018.

WALLIS, K. F. **Seasonal adjustment and relations between variables**. Journal of the American Statistical Association, v. 69, n. 345, p. 18-31, 1974. Disponível em <https://www.tandfonline.com/doi/abs/10.1080/01621459.1974.10480123>>. Acesso em 12/12/2018.

Apêndice A - Testes de Raiz Unitária

Tabela A.1: Teste ADF - IPI - Indústria Geral - Brasil

Teste ADF																	
3[2]*Tipo	3[2]*Variável	Modelo sem constante e sem tendência			Modelo com constante			Modelo com constante e tendência									
		Frequência dos dados	Defasagem	Estatística de Teste	Valores críticos			Defasagem	Estatística de Teste	Valores críticos							
					1%	5%	10%			1%	5%	10%					
Com ajuste sazonal	Nível	Mensal	1	-2,02	-2,58	-1,95	-1,62	1	-1,99	-3,43	-2,86	-2,57	1	-2,95	-3,96	-3,41	-3,12
Com ajuste sazonal	Primeira diferença	Mensal	1	-17,17	-2,58	-1,95	-1,62	1	-17,20	-3,43	-2,86	-2,57	1	-17,21	-3,96	-3,41	-3,12
Com ajuste sazonal	Diferença Anual	Mensal	12	-4,16	-2,58	-1,95	-1,62	12	-4,28	-3,44	-2,87	-2,57	12	-4,40	-3,98	-3,42	-3,13
Com ajuste sazonal	Nível	Trimestral	1	1,13	-2,58	-1,95	-1,62	1	-1,75	-3,46	-2,88	-2,57	1	-2,84	-3,96	-3,41	-3,12
Com ajuste sazonal	Primeira diferença	Trimestral	1	-9,70	-2,58	-1,95	-1,62	1	-9,81	-3,46	-2,88	-2,57	1	-17,18	-3,96	-3,41	-3,12
Com ajuste sazonal	Diferença Anual	Trimestral	4	-3,46	-2,58	-1,95	-1,62	4	-3,55	-3,46	-2,88	-2,57	1	-5,31	-3,98	-3,42	-3,13

NOTA: Número máximo de lags, para dados mensais=12, para dados trimestrais=4. Defasagens escolhidas por critério BIC. Dados com ajuste sazonal.

Tabela A.2: Teste ZA - IPI - Indústria Geral - Brasil

Teste ZA																	
3[2]*Tipo	3[2]*Variável	Modelo com constante			Modelo com tendência			Modelo com constante e tendência									
		Frequência dos dados	Defasagem	Estatística de Teste	Valores críticos			Defasagem	Estatística de Teste	Valores críticos							
					1%	5%	10%			1%	5%	10%					
Com ajuste sazonal	Nível	Mensal	1	-3,93	-5,34	-4,8	-4,58	1	-3,86	-4,93	-4,42	-4,11	1	-4,08	-5,57	-5,08	-4,82
Com ajuste sazonal	Primeira diferença	Mensal	11	-7,95	-5,34	-4,8	-4,58	11	-7,74	-4,93	-4,42	-4,11	11	-7,98	-5,57	-5,08	-4,82
Com ajuste sazonal	Diferença Anual	Mensal	12	-5,03	-5,34	-4,8	-4,58	12	-4,78	-4,93	-4,42	-4,11	12	-5,06	-5,57	-5,08	-4,82
Com ajuste sazonal	Nível	Trimestral	1	-3,98	-5,34	-4,8	-4,58	1	-3,96	-4,93	-4,42	-4,11	1	-4,16	-5,57	-5,08	-4,82
Com ajuste sazonal	Primeira diferença	Trimestral	4	-7,28	-5,34	-4,8	-4,58	4	-7,09	-4,93	-4,42	-4,11	4	-7,29	-5,57	-5,08	-4,82
Com ajuste sazonal	Diferença Anual	Trimestral	4	-4,32	-5,34	-4,8	-4,58	4	-4,07	-4,93	-4,42	-4,11	4	-4,34	-5,57	-5,08	-4,82

NOTA: Número máximo de lags, para dados mensais=12, para dados trimestrais=4. Defasagens escolhidas por critério BIC. Dados com ajuste sazonal.

Tabela A.3: Teste HEGY - Dados Mensais - IPI - Indústria Geral - Brasil

Modelo	Nível			Primeira Diferença		Diferença Anual	
	Estatística	Estatística de Teste	P-Valor	Estatística de Teste	P-Valor	Estatística de Teste	P-Valor
Const, Tend, Dummy	t_1	-2,87	0,14	-7,40	0,00	-3,94	0,01
Const, Tend, Dummy	t_2	-7,05	0,00	-6,17	0,00	-8,77	0,00
Const, Tend, Dummy	F_3:4	29,52	0,00	23,25	0,00	35,01	0,00
Const, Tend, Dummy	F_5:6	52,68	0,00	38,29	0,00	31,86	0,00
Const, Tend, Dummy	F_7:8	41,20	0,00	30,81	0,00	38,35	0,00
Const, Tend, Dummy	F_9:10	28,70	0,00	26,99	0,00	38,09	0,00
Const, Tend, Dummy	F_11:12	49,62	0,00	34,76	0,00	47,77	0,00
Const, Tend, Dummy	F_2:12	128,00	0,00	35,72	0,00	48,96	0,00
Const, Tend, Dummy	F_1:12	118,41	0,00	43,04	0,00	47,56	0,00
Const, Dummy	t_1	-1,17	0,67	-7,41	0,00	-3,94	0,00
Const, Dummy	t_2	-7,01	0,00	-6,17	0,00	-8,78	0,00
Const, Dummy	F_3:4	28,44	0,00	23,34	0,00	35,10	0,00
Const, Dummy	F_5:6	51,66	0,00	38,38	0,00	31,94	0,00
Const, Dummy	F_7:8	40,56	0,00	30,88	0,00	38,45	0,00
Const, Dummy	F_9:10	28,34	0,00	27,08	0,00	38,19	0,00
Const, Dummy	F_11:12	48,98	0,00	34,82	0,00	47,90	0,00
Const, Dummy	F_2:12	126,25	0,00	35,82	0,00	49,09	0,00
Const, Dummy	F_1:12	116,90	0,00	43,12	0,00	47,68	0,00
Const	t_1	-0,90	0,78	-4,77	0,00	-4,00	0,00
Const	t_2	-1,63	0,09	-1,63	0,09	-8,89	0,00
Const	F_3:4	1,28	0,29	1,26	0,30	36,06	0,00
Const	F_5:6	1,15	0,33	1,14	0,33	32,69	0,00
Const	F_7:8	2,41	0,09	2,41	0,09	39,46	0,00
Const	F_9:10	34,93	0,00	35,05	0,00	39,14	0,00
Const	F_11:12	2,14	0,12	2,14	0,12	49,17	0,00
Const	F_2:12	8,31	0,00	8,33	0,00	50,41	0,00
Const	F_1:12	7,70	0,00	10,35	0,00	48,97	0,00
Tend	t_1	-2,93	0,14	-4,76	0,00	-3,99	0,01
Tend	t_2	-1,61	0,10	-1,63	0,09	-8,88	0,00
Tend	F_3:4	1,35	0,27	1,26	0,29	35,96	0,00
Tend	F_5:6	1,15	0,33	1,14	0,33	32,61	0,00
Tend	F_7:8	2,36	0,10	2,41	0,09	39,36	0,00
Tend	F_9:10	35,50	0,00	34,95	0,00	39,04	0,00
Tend	F_11:12	2,09	0,13	2,14	0,12	49,05	0,00
Tend	F_2:12	8,41	0,00	8,30	0,00	50,29	0,00
Tend	F_1:12	8,46	0,00	10,33	0,00	48,84	0,00

NOTA: Número máximo de lags, para dados mensais=12, para dados trimestrais=4. Defasagens escolhidas por critério BIC. P-valores baseados em regressões de resposta de superfície. Dados sem ajuste sazonal

Tabela A.4: Teste HEGY - Dados Trimestrais - IPI - Indústria Geral - Brasil

Modelo	Estatística	Nível		Primeira Diferença		Diferença Anual	
		Estatística de Teste	P-Valor	Estatística de Teste	P-Valor	Estatística de Teste	P-Valor
Const, Tend, Dummy	t_1	-3,20	0,05	-7,01	0,00	-3,91	0,01
Const, Tend, Dummy	t_2	-9,16	0,00	-7,30	0,00	-11,58	0,00
Const, Tend, Dummy	F_3:4	38,86	0,00	26,55	0,00	93,68	0,00
Const, Tend, Dummy	F_2:4	104,20	0,00	34,70	0,00	98,33	0,00
Const, Tend, Dummy	F_1:4	81,65	0,00	39,16	0,00	110,16	0,00
Const, Dummy	t_1	-1,34	0,56	-7,03	0,00	-3,93	0,00
Const, Dummy	t_2	-8,96	0,00	-7,32	0,00	-11,62	0,00
Const, Dummy	F_3:4	36,78	0,00	26,73	0,00	94,39	0,00
Const, Dummy	F_2:4	99,35	0,00	34,92	0,00	99,12	0,00
Const, Dummy	F_1:4	76,14	0,00	39,42	0,00	110,96	0,00
Const	t_1	-0,99	0,74	-4,02	0,00	-3,97	0,00
Const	t_2	-2,66	0,01	-2,67	0,01	-11,75	0,00
Const	F_3:4	1,11	0,35	1,11	0,35	96,47	0,00
Const	F_2:4	3,07	0,02	3,09	0,00	101,30	0,00
Const	F_1:4	2,57	0,08	6,44	0,00	113,39	0,00
Tend	t_1	-3,37	0,05	-4,00	0,01	-3,95	0,01
Tend	t_2	-2,57	0,01	-2,66	0,01	-11,70	0,00
Tend	F_3:4	1,09	0,35	1,10	0,35	95,76	0,00
Tend	F_2:4	2,90	0,02	3,07	0,00	100,51	0,00
Tend	F_1:4	5,32	0,00	6,39	0,00	112,59	0,00

NOTA: Número máximo de lags, para dados mensais=12, para dados trimestrais=4. Defasagens escolhidas por critério BIC. P-valores baseados em regressões de resposta de superfície. Dados sem ajuste sazonal

Apêndice B - Modelos de Markov selecionados

Tabela B.1: Estimativas para os modelos selecionados do IPI - Indústria Geral - Brasil

	ΔY_t^{mensal}	$\Delta_{12} Y_t^{mensal}$	$\Delta Y_t^{trimestral}$	$\Delta_{12} Y_t^{trimestral}$
	MSIH-AR(5)	MSIH-AR(8)	MSIH-AR(0)	MSIH-AR(4)
$\nu 1$	-0,89 (0,79)	-0,26 (1,83)	-1,63 (1,22)	-3,24 (0,91)
$\nu 2$	0,36 (0,1)	0,36 (0,23)	0,99 (0,26)	3,17 (2,94)
AR(1)	-0,22 (0,05)	0,57 (0,06)	-	0,58 (0,37)
AR(2)	0,01 (0,05)	0,22 (0,05)	-	-0,18 (0,1)
AR(3)	0,03 (0,05)	0,14 (0,06)	-	0,17 (0,09)
AR(4)	-0,08 (0,04)	-0,1 (0,05)	-	-0,38 (0,06)
AR(5)	-0,08 (0,04)	0 (0,05)	-	-
AR(6)	-	0,02 (0,05)	-	-
AR(7)	-	-0,09 (0,05)	-	-
AR(8)	-	0,03 (0,04)	-	-
AR(9)	-	-	-	-
AR(10)	-	-	-	-
AR(11)	-	-	-	-
AR(12)	-	-	-	-
$\sigma 1$	25,26	99,34	28,94	29,01
$\sigma 2$	3,05	11,66	4,28	10,32
p11	0,39	0,56	0,77	0,87
p22	0,89	0,94	0,93	0,95
LogLik	-1119,65	-1397,37	-415,65	-463
AIC	2257,31	2818,73	839,29	942
BIC	2295,38	2869,5	856,21	975,85

NOTA: Erros-padrão entre parênteses.

Apêndice C - Atividades PIM-PF

Tabela C.1: Atividades selecionadas para a PIM-PF, por UF

	Extrativa	Transformação
AM	X	X
PA	X	X
CE		X
PE		X
BA	X	X
MG	X	X
ES	X	X
RJ	X	X
SP		X
PR		X
SC		X
RS		X
MT		X
GO	X	X

3 Ciclos de crescimento no Brasil: uma abordagem com Análise do Espectro Singular

Resumo. O presente trabalho busca estudar os ciclos de negócios no Brasil em sua interpretação de hiato do produto, conhecida na literatura como ciclos de crescimento ou ciclos de desvios. Para isto, a Análise do Espectro Singular (SSA) é utilizada, seguindo o procedimento de agrupamento proposto por Carvalho e Rua (2017). Os efeitos de variações na janela são estudados empiricamente e os resultados são comparados com os obtidos por outros filtros utilizados na literatura. A análise é conduzida com ênfase em três aspectos: a) características gerais dos ciclos, b) análise dos *turning points* e c) performance em tempo real. Os resultados indicam que a SSA, além de apresentar ciclos consistentes com outros métodos tradicionais, apresenta performance superior em tempo real. Os resultados são, contudo, sensíveis à escolha da janela.

Palavras-chave: Ciclos de negócios. Ciclos de Crescimento. Hiato do produto. Brasil. Tendência. Análise do Espectro Singular.

JEL Classifications. E32; R1

3.1 Introdução

Pesquisas sobre as flutuações econômicas no Brasil receberam uma importante contribuição a partir da criação do Comitê de Datação dos Ciclos Econômicos (CODACE-IBRE/FGV). Inspirado no *Business Cycle Dating Comitee* do NBER e em outras instituições, o CODACE divulga uma cronologia do ciclo de negócios brasileiro, apontando as datas de início e fim dos períodos recessivos e de expansão econômica no país desde o primeiro trimestre de 1980.

Existem duas características principais no procedimento de datação dos ciclos pelo CODACE. A primeira é o fato de as decisões sobre o *timing* dos pontos de virada dos ciclos serem tomadas com base não apenas no comportamento do PIB trimestral, mas de uma gama de outras estatísticas econômicas, de diferentes frequências. Este *modus operandi* do CODACE está de acordo com a visão de que os ciclos de negócios representam co-movimentos entre diferentes atividades e setores da economia (BURNS; MITCHELL, 1946; LUCAS, 1977). A segunda, e mais singular característica, é que o CODACE utiliza o conceito clássico dos ciclos de negócios como referência para caracterização das fases cíclicas. Em outras palavras, são os movimentos no nível de atividade – produção, emprego, vendas, etc. – que importam para a caracterização dos períodos cíclicos e determinação dos pontos de virada.

Embora as atenções para o ciclo clássico sejam importantes devido aos custos, em termos de bem-estar econômico e social gerados durante as recessões e depressões econômicas, períodos de aceleração e desaceleração, ainda que com taxas de crescimento positivas do produto, também se alternam, nem sempre mediados por quedas no nível de atividade. Estes “ciclos de crescimento” ou “ciclos de desvios” (MINTZ, 1969) também são alvo de monitoramento ao redor do mundo, por instituições como OCDE, através de seu Sistema de Indicadores Antecedentes. Ambas divulgam, inclusive, as datações dos pontos de virada das acelerações e desacelerações da atividade econômica em uma gama de países desenvolvidos.

Estes ciclos de crescimento, contudo, por não serem observados diretamente, necessitam ser estimados. A variedade de métodos disponíveis para a execução de tal tarefa, contudo, pode gerar resultados bastante diversos. Desde a ampla revisão dos métodos de separação de tendência e ciclo realizada por Canova (1998), novas técnicas foram propostas, dentre as quais, a Análise de Espectro Singular (do inglês, *Singular Spectrum Analysis*, doravante, SSA).¹ A SSA é uma metodologia não-paramétrica que não exige a elaboração de um modelo estatístico *a priori* para análise e previsão de séries de tempo. A técnica, já altamente difundida em áreas como climatologia, meteorologia e geofísica, recentemente tem ganhado espaço em aplicações na Economia, em particular em pesquisas sobre ciclos econômicos. (GONZALEZ et al, 2015; GROTH et al., 2015; SELLA; MARCHIONATTI,

¹Para uma revisão de alguns destes métodos, ver Alexandrov et al. (2012).

2012; CARVALHO et al., 2012; CARVALHO; RUA, 2017; DUMAS et al., 2011) Uma das vantagens também atribuídas ao método é seu caráter de adaptação aos dados. Conforme Hassani e Thomakos (2010), como não é necessário estimar nenhum coeficiente, a SSA lida melhor com quebras estruturais. Esta é uma característica importante para o estudo de séries econômicas brasileiras, permeadas por quebras estruturais, sobretudo nas décadas de 1980 e 1990, originadas em diversos choques externos e internos, tais como crises cambiais, financeiras, de dívida, ou mesmo os planos de estabilização monetária anteriores ao Plano Real.

Apesar de as características acima ilustrarem a flexibilidade da SSA para análise de séries de tempo, as estimativas obtidas dependem fundamentalmente da escolha de dois parâmetros: a escolha do tamanho da janela e o agrupamento das autotriplas. Em um trabalho recente, Carvalho e Rua (2017) propõem um método para a escolha dos agrupamentos voltado para estudos de ciclos de negócios. A escolha da janela neste contexto, contudo, ainda permanece um procedimento *ad hoc*. Investigar as consequências de diferentes escolhas de janelas é, portanto, fundamental para avaliar a performance da SSA enquanto método de estimação dos ciclos econômicos.

Tendo em vista o exposto, o presente trabalho apresenta duas principais contribuições à literatura de ciclos de negócios no Brasil, em especial no que tange à sua interpretação em termos de hiato do produto, i.e., os ciclos de crescimento. Em primeiro lugar, a técnica básica de SSA univariado (*Single-Channel SSA*) é empregada, seguindo o procedimento de Carvalho e Rua (2017), para isolar o componente cíclico relacionado à frequência do ciclo de negócios. A sensibilidade dos ciclos resultantes é explorada para diferentes tamanhos de janela. Até onde conhecemos, esta é a primeira aplicação sistemática de SSA para análise histórica dos ciclos de crescimento no Brasil no período 1980-2017.²

Em segundo lugar, a robustez dos "fatos estilizados" dos ciclos de crescimento do Brasil pela SSA é checada comparando seus resultados com os de outros métodos de remoção da tendência estabelecidos na literatura. Os picos e vales das séries filtradas são também contrastados à cronologia do CODACE, de modo a se estudar as relações entre os ciclos de negócios e os ciclos de crescimento. Por fim, uma vez que os diferentes métodos conferem algum grau de incerteza ao hiato do produto diante da incorporação de novas informações na ponta das séries (ORPHANIDES; VAN NORDEN, 2012), a consistência das estimativas dos ciclos com diferentes conjuntos informacionais é avaliada em tempo real, sem considerar a atualização de valores divulgados para os dados primários. Na nomenclatura usada por Orphanides e van Norden (2012), trata-se de um exercício em quase tempo real.

²Gonzalez et al. (2015) utilizam SSA univariado no PIB trimestral brasileiro entre 1996 e 2013 para fins de ilustração da técnica em seu estudo *cross-country* do ciclo de negócios e do ciclo financeiro. A ênfase do estudo, contudo, recai sobre este último.

Com estes exercícios, é possível responder a uma gama de perguntas fundamentalmente empíricas, por exemplo, "A SSA é apropriada para analisar os ciclos brasileiros?", "Quais as propriedades dos ciclos gerados?", "Esses ciclos são sensíveis à janela escolhida?", "Como estes ciclos se comparam a outros filtros?", "Como esses ciclos se comportam com relação ao *benchmark* do CODACE?" e finalmente, "A SSA supera a performance de outros filtros em tempo real para o PIB brasileiro?". De modo a responder a tais perguntas, o trabalho está dividido em sete seções, incluindo esta introdução. A segunda seção apresenta uma breve discussão sobre os ciclos de crescimento, enquanto a terceira sumariza a metodologia da SSA empregada. A quarta seção apresenta métodos alternativos para filtragem do componente cíclico. As duas seções seguintes descrevem os dados e apresentam análise dos resultados empíricos. Esta sexta seção, de análise, está dividida em três subseções. Cada uma explora, respectivamente i) as características dos ciclos extraídos com diferentes métodos de filtragem, ii) a análise de seus *turning points* e sua comparação com as datações dos ciclos clássicos estabelecida pelo CODACE e por fim, iii) sua performance em tempo real. Na última seção são expostas as conclusões do artigo.

3.2 Breve revisão sobre os ciclos de crescimento

Os ciclos de crescimento se relacionam com os ciclos clássicos, porém, diferem dos mesmos em alguns aspectos. Em primeiro lugar, os ciclos de crescimento são definidos como flutuações de curto prazo da série de referência em relação a sua tendência de longo prazo. De fato, é este o conceito de ciclo comumente utilizado na literatura macroeconômica moderna para estudar as flutuações econômicas, como evidenciado na literatura de ciclos reais de negócios e modelos dinâmico-estocásticos de equilíbrio geral (DSGE) (LUCAS, 1977; KYDLAND; PRESCOTT, 1982; LONG; PLOSSER, 1983; HIROSE; NAGANUMA, 2010). Portanto, exercícios de avaliação de políticas de estabilização e previsão do produto baseadas em simulações com estes modelos tem por base o ciclo de crescimento e não o ciclo de negócios clássico.

Ademais, neste conceito, os ciclos são mais frequentes e simétricos que os ciclos clássicos. Tipicamente, as fases de expansão inicial e intermediária no ciclo clássico coincidem com momentos acima da tendência de longo prazo no ciclo de crescimento, enquanto o *timing* do final das expansões econômicas e da fase de contração clássica correspondem à fase de crescimento abaixo da tendência (ZARNOWITZ, 1992). Assim, os *downturns* nos ciclos de crescimento ocorrem antes do que no ciclo de negócios clássico.

Moore (1983) destaca três outras características dos ciclos de crescimento: 1) os indicadores antecedentes do NBER são sensíveis a reduções no ritmo de atividade, sejam elas de caráter recessivo ou não, de modo que estes indicadores antevêm melhor os ciclos de

crescimento do que os ciclos de negócios. 2) estes indicadores antecedentes apresentam características similares para diferentes países com respeito aos ciclos de crescimento. 3) Por fim, há uma relação próxima entre esta interpretação do ciclo econômico e a taxa de inflação. De fato, a definição de ciclo de crescimento corresponde essencialmente à mesma do hiato do produto, qual seja, a de flutuações cíclicas em torno de uma tendência de longo prazo.

As diferenças conceituais na definição de ciclo empregada se traduzem também em diferenças na sua forma de mensuração. Enquanto no ciclo clássico períodos de queda absoluta do nível de atividade, caracterizados como recessões, podem ser estudados nos indicadores dessazonalizados sem a necessidade de estimação – e remoção – de sua tendência de longo prazo, o mesmo não pode ser realizado na abordagem dos ciclos de crescimento. Isto impõe um grau de arbitrariedade maior na estimação dos ciclos de crescimento, uma vez que *os turning points*, a volatilidade, a correlação dos componentes cíclicos de diferentes indicadores econômicos e outros “fatos estilizados” podem ser sensíveis ao método empregado de remoção da tendência (CANOVA, 1994; CANOVA, 1998; CANOVA, 1999; BURNSIDE, 1998).

No caso do Brasil, diferenças nos fatos estilizados dos ciclos econômicos também já foram notadas entre métodos variados. Teles et al. (2005), por exemplo, estudam as propriedades dos ciclos econômicos em um conjunto de séries macroeconômicas brasileiras e mostram, quantitativa e qualitativamente, que estes "fatos" variam de maneira significativa entre distintos filtros. Em outro exercício, Oliveira e Portugal (2013) comparam a estimação estrutural do hiato do produto com a de filtros tradicionais da literatura utilizando dados do PIB trimestral no período 2002-2011 e mostram que os resultados são em geral, diversos, tanto em termos visuais quanto com relação a seu poder preditivo sobre a inflação.

É possível notar também esforços na literatura em busca de métodos mais adequados para a extração do componente cíclico em séries econômicas brasileiras, e.g., reduzindo a parcela de ruído remanescente após a extração da tendência. Dias e Dias (2010), por exemplo, utilizam um procedimento recursivo a partir de um modelo ARIMA que permite quebras estruturais nos componentes de tendência e intercepto. Os ciclos são estimados como a soma da média e do desvio-padrão de cada uma das linhas da matriz de resíduos obtida com as regressões. Mais recentemente, Lopes et al. (2017) combinam uma coleção de componentes cíclicos extraídos por filtro HP com diferentes valores do parâmetro de suavização para formar um componente cíclico, que teria maior sincronia com os pontos de virada identificados pelo CODACE. Outro destaque é Chauvet (2002). Em uma abordagem distinta das demais, Chauvet estuda os ciclos de crescimento nos dados anuais do PIB brasileiro entre 1900 e 2000 utilizando um modelo univariado de mudança markoviana de regime com dois estados. A interpretação de ciclos de crescimento decorre do sinal estimado para a média dos dois regimes, ambas positivas.

Com intuito de investigar a adequação de novos métodos - em especial a Análise do Espectro Singular - para a extração do componente cíclico da série de PIB trimestral do Brasil, as próximas seções apresentam brevemente a estratégia de identificação utilizada a partir da SSA, as alternativas a esse método e seus resultados.

3.3 Estrutura básica da Análise do Espectro Singular

O método SSA em sua forma mais básica possui dois estágios, decomposição e reconstrução, cada um dos quais, por sua vez, segue dois passos. Estes são a) incorporação (*embedding*) e obtenção da matriz de trajetória, b) Decomposição do Valor Singular (*Singular Value Decomposition*, doravante SVD), c) Agrupamento (*Grouping*) e d) obtenção da média diagonal (*Diagonal Averaging*), onde a e b pertencem ao primeiro estágio e c e d ao segundo. A apresentação da SSA a seguir é baseada em Golyandina et al. (2001).

1. Decomposição

- Incorporação e Matriz de Trajetória

Seja $Y_N = (y_1, \dots, y_N)$ uma realização de um processo estocástico de tamanho N , $\{Y_t\}_{t \in \mathbb{Z}}$. Seja L uma janela, tal que $2 \leq L \leq N$ e seja $K = N - L + 1$. A incorporação ou *embedding* é um mapeamento da série unidimensional Y_t nas séries multidimensionais X_1, X_2, \dots, X_K , com vetores X_i , chamados vetores defasados ou L-defasados, da seguinte forma:

$$X_i = [y_i, y_{i+1}, y_{i+2}, \dots, y_{i+L-1}]^T \quad (3.1)$$

para $i = 1, 2, \dots, K$, onde T simboliza a transposta do vetor. Colecionamos então estes vetores numa matriz X , chamada Matriz de Trajetória,

$$X = [X_1, \dots, X_K] = (x_{i,j})_{i,j=1}^{L,K} = \quad (3.2)$$

$$\begin{bmatrix} y_1 & y_2 & y_3 & \dots & y_K \\ y_2 & y_3 & y_4 & \dots & y_{K+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ y_L & y_{L+1} & y_{L+2} & \dots & y_N \end{bmatrix}$$

Uma característica especial desta matriz é que todos os elementos da diagonal $i + j = \text{constante}$ são iguais, isto é, a matriz X é uma Matriz de Hankel.

- Decomposição do Valor Singular (SVD)

Seja $S = XX^T$. Seja $\lambda_1, \lambda_2, \dots, \lambda_L$ os autovalores de S , dispostos em ordem decrescente, tal que $0 \leq \lambda_L \leq \lambda_{L-1}, \dots, \leq \lambda_2, \lambda_1$. Seja $d = \text{posto}(S) =$

$\max(i, \text{tal que } \lambda_i > 0)$ (isto é, λ_i não-nulo) e U_1, U_2, \dots, U_L o sistema ortonormal de autovetores de S correspondente a esses autovalores. Considerando $V_i = X^T U_i / \sqrt{\lambda_i}$, a SVD da trajetória da matriz X pode ser escrita como:

$$X = X_1 + X_2 + \dots + X_d \quad (3.3)$$

onde $X_i = \sqrt{\lambda_i} U_i V_i^T$ e as matrizes X_i são elementares, de posto 1, portanto. A trinca (λ_i, U_i, V_i) é chamada de *eigen-triple* da SVD. Assim, X pode ser reescrito como:

$$X = \sqrt{\lambda_1} U_1 V_1^T + \sqrt{\lambda_2} U_2 V_2^T + \dots + \sqrt{\lambda_d} U_d V_d^T \quad (3.4)$$

2. Reconstrução

- Agrupamento

Primeiramente, parte-se o conjunto de índices $\{1, 2, \dots, d\}$ em m conjuntos disjuntos I_1, I_2, \dots, I_m . Seja $I = \{i_1, \dots, i_p\}$. Seja a matriz resultante X_I correspondente ao grupo I , tal que $X_I = X_{i_1}, X_{i_2}, \dots, X_{i_p}$. Estas matrizes são computadas para cada um dos conjuntos, $I = I_1, I_2, \dots, I_m$. O procedimento de escolha dos conjuntos I_1, I_2, \dots, I_m é chamado *eigen-triple grouping*. A separação do conjunto de índices $J = 1, 2, \dots, d$ em subconjuntos disjuntos I_1, I_2, \dots, I_m corresponde a

$$X = X_{I_1} + X_{I_2} + \dots + X_{I_m}$$

- Média Diagonal

O último passo é transformar cada matriz de (3.3) em uma nova série de tamanho N . Seja \tilde{X} uma matriz $L \times K$ com elementos $y_{i,j}$ $1 \leq i \leq L, 1 \leq j \leq K$. Seja $L^* = \min(L, K)$, $K^* = \max(L, K)$ e $N = L + K - 1$. Seja

$$y_{i,j}^* = \begin{cases} y_{i,j} & \text{se } L < K, \\ y_{j,i} & \text{caso contrário.} \end{cases} \quad (3.5)$$

A média diagonal transfere a matriz \tilde{X} para as séries g_0, g_1, \dots, g_{N-1} pela seguinte fórmula:

$$g_k = \begin{cases} \frac{1}{k+1} \sum_{m=1}^{k+1} y_{m,k-m+2}^* & \text{para } 0 \leq k < L^* - 1, \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+2}^* & \text{para } L^* - 1 \leq k < K^*, \\ \frac{1}{N-k} \sum_{m=k-K^*+2}^{N-K^*+1} y_{m,k-m+2}^* & \text{para } K^* \leq k < N. \end{cases} \quad (3.6)$$

A expressão acima corresponde à média dos elementos da matriz sobre as diagonais $i + j = k + 2$. Para $k = 0, g_0 = y_{11}$, para $k = 1, g_1 = (y_{12} + y_{21})/2$,

etc. O procedimento aplicado a uma matriz resultante X_{I_k} produz séries $\tilde{F}^{(k)} = \tilde{f}_0^{(k)}, \dots, \tilde{f}_{N-1}^{(k)}$, de forma que a série inicial f_0, \dots, f_{N-1} é decomposta na soma de m séries:

$$f_n = \sum_{k=1}^m \tilde{f}_n^k \quad (3.7)$$

Para maiores detalhes, ver Golyandina et al. (2001).

3.3.1 Parâmetros da SSA e identificação dos ciclos

A identificação dos componentes de interesse na análise, i.e., tendência, ciclo e ruído³ através da SSA exige tanto a especificação adequada do tamanho da janela, L , na fase de decomposição, quanto a identificação correta dos grupos para a reconstrução da série, de forma a garantir a separabilidade das séries (GOLYANDINA et al, 2001; GOLYANDINA, 2010). Neste processo, a definição dos componentes de interesse também pode auxiliar na escolha destes parâmetros.

Na fase de decomposição, a escolha da janela L , referente ao número de linhas da matriz de trajetória, envolve algum grau de subjetividade, devendo ser grande o suficiente para captar a dinâmica das séries, e.g. $L \sim N/2$ (GOLYANDINA et al, 2001) mas limitada o bastante para permitir um número alto de repetições da característica da série que se deseja estudar. Ademais, a janela deve ser um múltiplo do componente periódico de interesse Hassani (2007) - por exemplo, sazonalidade ou, no nosso caso, ciclo econômico. A escolha deve se relacionar aos objetivos da análise (GOLYANDINA, 2010).⁴

Por sua vez, a fase de agrupamento das autotriplas após a decomposição do valor singular também não é trivial e em geral depende do objetivo do estudo. Golyandina et al. (2001) sugerem uma série de diagnósticos visuais para identificação e agrupamento de componentes oscilatórios baseados no conceito de separabilidade. Por exemplo, a visualização do autoespectro, isto é, dos valores singulares em ordem decrescente, pode ajudar a identificar componentes harmônicos. Valores singulares iguais formam degraus no autoespectro e cada par de autotripla relacionado a esses degraus formam uma base para potenciais componentes harmônicos no sinal.

Outra forma de diagnóstico são os gráficos de autovetores correspondentes aos valores singulares no autoespectro. A forma de cada autovetor reflete a dinâmica da série de tempo associada a cada autotripla, sendo portanto útil na identificação de tendências e harmônicos. Pares de autovetores associados com componentes harmônicos oscilam na

³Como a série analisada é ajustada sazonalmente, assume-se que o componente sazonal foi totalmente removido.

⁴Golyandina e Korobeynikov (2014) ressaltam que na hipótese de existência de uma estrutura complexa na série sob análise, a chamada SSA sequencial pode ser recomendável. Esta consiste em dois estágios: extração de tendência com uma janela pequena e posterior detecção e extração dos resíduos com $L \sim N/2$

mesma frequência na quadratura de fase.

Além disso, diagramas dos sucessivos autovetores pareados associados a oscilações harmônicas puras, como senos e cossenos resultam em formas poligonais exatas. O número de vértices dos polígonos indica o período de oscilação associado. Assim, um hexágono formado pelos pares de autovetores representa um ciclo de seis períodos.

No contexto de identificação do componente de ciclo de negócios, contudo, formas sinoidais exatas são raras. A estratégia de identificação adotada na maior parte dos trabalhos na área se concentra em eliminar apropriadamente a tendência da série, interpretando o resíduo como ciclo (SELLA; MARCHIONATTI, 2012; GROTH et al, 2015). Contudo, uma estratégia interessante, que permite focar diretamente na identificação do componente cíclico, é sugerida em Carvalho et al. (2012) e formalizada em Carvalho e Rua (2017).

A idéia central é, dada uma janela escolhida na fase de decomposição, agrupar as autotriplas associadas a oscilações na frequência dos ciclos de negócios; no caso de dados trimestrais, períodos entre 6 e 32 trimestres. Carvalho et al. (2012) sugerem acessar a periodicidade através de uma inspeção visual da representação em série de tempo de cada uma das autotriplas reconstruídas. Buscando formalizar este procedimento, Carvalho e Rua (2017) propõem um pseudo-algoritmo baseado na estimação dos periodogramas, identificação de seu pico e avaliação de sua significância estatística baseado na estatística g de Fisher. Se significativo o componente é retido para fazer parte do agrupamento e reconstrução do componente cíclico. O pseudo-código é apresentado a seguir em linhas gerais. Detalhes podem ser encontrados em Carvalho e Rua (2017).

Deseja-se selecionar os componentes que atendem aos critérios descritos anteriormente. Considere um número d de autovetores da matriz S . O algoritmo é dividido em seis passos.

- Passo 1 - Obtem-se o periodograma do i -ésimo componente principal e calcula-se a frequência associada ao seu pico.
- Passo 2 - Se a frequência associada ao pico pertencer ao conjunto de frequências de interesse, ir para o passo 3, caso contrário, voltar ao passo 1, analisando o próximo componente.
- Passo 3 - Computa-se a estatística g de Fisher associada ao componente i salvando o resultado.
- Passo 4 - Computa-se o p -valor correspondente no passo anterior salvando o resultado.
- Passo 5 - Se a estatística calculada anteriormente é significativa a um nível predeterminado, α , retém-se o componente, juntamente com aqueles selecionados anteriormente, caso contrário, descarta-se o componente sob avaliação.
- Passo 6 - Caso haja componentes ainda a serem avaliados, analisa-se o próximo componente a partir do passo 1. Caso contrário, o algoritmo é terminado.

3.4 Alguns Métodos Alternativos

3.4.1 Tendência determinística polinomial

Uma das mais tradicionais abordagens para modelagem do crescimento econômico de longo prazo é entendê-lo como a projeção do logaritmo do PIB contra uma tendência linear ao longo do tempo.⁵ Nesta abordagem, desvios em relação à tendência, caracterizados pelos resíduos estacionários da regressão, são interpretados como componente cíclico. Esta caracterização dos ciclos implica que choques de qualquer natureza causam apenas desvios temporários em relação à tendência. Zarnowitz e Ozyildirim (2006) argumentam que esta abordagem possui pouco apelo empírico para modelar longos períodos, uma vez que mudanças estruturais e tecnológicas, algumas das quais fazem parte da história recente do Brasil, como períodos de alta e baixa inflação, crises financeiras e a transição entre fases de expansão e contração dos negócios, podem modificar a tendência de crescimento. Por estes motivos, parte excessiva das variações do produto acabam sendo atribuídas indevidamente ao ciclo de negócios. O modelo pode ser descrito como:

$$y_t = \alpha_1 + \beta_1 t + e_t$$

O componente cíclico assim, torna-se:

$$e_t = y_t - \alpha_1 - \beta_1 t$$

Em alguns casos é interessante também adicionar um termo quadrático à regressão. Cusinato et al. (2013), por exemplo, utilizam este modelo para comparar diferentes medidas de hiato do produto brasileiro em tempo real. Neste caso, o ciclo pode ser estimado como:

$$e_t = y_t - \alpha_1 - \beta_1 t - \beta_2 t^2$$

3.4.2 Tendência Estocástica

A visão de que variáveis macroeconômicas poderiam ser caracterizadas como estacionárias em torno de uma tendência foi amplamente questionada a partir do fim da década de 1970. Nelson e Plosser (1982), por exemplo, argumentam que movimentos seculares podem ser representados por um processo estocástico de raiz unitária sem a necessidade de imposição de um padrão determinístico. Processos caracterizados desta forma não apresentam reversão à sua tendência de longo prazo diante de choques aleatórios; a própria tendência é caracterizada por choques que se acumulam ao longo do tempo, sendo,

⁵Assumindo que o produto Y cresce exponencialmente a uma taxa β_1 , $Y_t = e^{\beta_1 t}$, o logaritmo de Y_t , denotado por y_t torna-se $y_t = \beta_1 t$

portanto, puramente estocástica.

No debate econômico, a especificação de modelos sob a hipótese de presença de raiz unitária tem implicações importantes, sugerindo que choques reais podem causar oscilações no próprio componente secular. Conseqüentemente, há pouco ou nenhum espaço para prescrições de política econômica anticíclica.

Na literatura empírica, contudo, a hipótese de presença de raiz unitária é constantemente posta em dúvida em diversas variáveis macroeconômicas, uma vez que boa parte dos testes de raiz unitária possui baixa capacidade de distinção entre processos de raiz unitária e quase-raiz unitária em amostras finitas, além de que tal hipótese muitas vezes não se sustenta quando incluída a possibilidade de quebras estruturais nas séries.⁶

O modelo pode ser descrito como:

$$y_t = y_{t-1} + \epsilon_t$$

onde as flutuações podem ser obtidas tomando-se a primeira diferença da série:

$$\Delta y_t = \epsilon_t$$

3.4.3 Filtro Hodrick-Prescott

No espectro entre o determinismo linear e a plena aleatoriedade da tendência, existe uma gama de medidas de tendências não lineares, dentre as quais se encontra o chamado filtro HP Hodrick e Prescott (1997). O filtro impõe três hipóteses principais sobre o conjunto de dados analisados: i) de que séries de agregados macroeconômicos podem ser desmembradas, de forma aditiva, entre dois componentes não observados - tendência e ciclo - os quais são independentes, ii) de que o componente cíclico apresenta média próxima de zero em períodos longos e iii) de que o componente de tendência destas séries, varia suavemente ao longo do tempo, de acordo com a teoria neoclássica de crescimento.

De maneira formal, seja y_t o logaritmo do produto, x_t a tendência e c_t o componente cíclico, de forma que:

$$y_t = x_t + c_t$$

O procedimento para obtenção do componente de tendência consiste em encontrar o processo $\{x_t\}_{t=1}^T$ que resolve o seguinte problema de otimização dinâmica:

$$\text{Min}_{\{x_t\}_{t=1}^T} \left\{ \sum_{t=1}^T [y_t - x_t]^2 + \lambda \sum_{t=1}^T [(x_{t+1} - x_t) - (x_t - x_{t-1})]^2 \right\}; \quad \lambda > 0$$

⁶A respeito das controvérsias acerca da hipótese de raiz unitária em séries de tempo macroeconômicas, ver Nelson e Plosser (1982), Perron (1989), Zivot e Andrews (1992), por exemplo.

O parâmetro λ permite controlar o grau de suavização da tendência. Quando $\lambda \rightarrow 0$, o termo de segunda diferença do problema de otimização se anula e a solução consiste em que a tendência x_t torne-se a própria série y_t . Por outro lado, quando $\lambda \rightarrow \infty$ a tendência se aproxima de um formato linear. Uma vez obtida a tendência x_t , o ciclo é computado como resíduo entre y_t e x_t .

3.4.4 Filtro Christiano-Fitzgerald

O filtro HP, ao remover os componentes de baixa frequência, associados à tendência da série de tempo, pode ser interpretado no domínio da frequência como um filtro passa-alto (*high-pass*). Neste caso, contudo, oscilações de alta frequência não relacionadas aos ciclos econômicos também seriam incorporadas à série filtrada.

Baxter e King (1999) desenvolvem uma aproximação ótima para o filtro passa-banda, capaz de reter frequências associadas aos ciclos de negócios. De posse de uma amostra finita, e na ausência de um filtro passa-banda ideal, a idéia é aproximar o filtro ao filtro ideal, no sentido de minimizar o erro quadrático médio entre os dois. Ao formular o problema no domínio da frequência, Christiano e Fitzgerald (2003) propõem escolher os pesos com base no espectro da série.

Assumindo que a série de interesse pode ser representada por um passeio aleatório, o filtro pode ser entendido da seguinte forma. A série de tempo pode ser decomposta em duas parcelas, c_t , a série que possui poder nas frequências dos ciclos de negócios, e.g. entre 1.5 e 8 anos e \tilde{x}_t , a série cujo poder somente existe em frequências diferentes daquelas dos ciclos.

$$y_t = \tilde{x}_t + c_t$$

O componente filtrado pode ser escrito como:

$$c_t = B_0 y_t + B_1 y_{t+1} + \dots + B_{T-1-t} y_{T-1} + \tilde{B}_T y_T + B_1 y_{t-1} + \dots + B_{t-2} y_2 + \tilde{B}_{t-1} y_1 \quad (3.8)$$

onde

$$B_j = \frac{\text{sen}(jb) - \text{sen}(ja)}{\pi j} \quad ; j > 1,$$

$$B_0 = \frac{b-a}{\pi}, \quad a = \frac{2\pi}{p_u}, \quad b = \frac{2\pi}{p_l},$$

$$\tilde{B}_k = -\frac{1}{2} B_0 - \sum_{j=1}^{k-1} B_j.$$

Os parâmetros p_u e p_l são os limiares do tamanho do ciclo, em trimestres. Assim, ciclos com períodos compreendidos entre estes dois limiares são retidos, enquanto ciclos de períodos distintos são eliminados.

3.4.5 Método dos Componentes Não-Observáveis

O modelo consiste em uma equação de medição e uma equação de movimento.

Uma forma geral do modelo permite a decomposição em componentes como tendência (μ_t), sazonal (γ_t) e cíclico (ψ_t), além de captar a contribuição de variáveis explicativas adicionais com coeficientes fixos ou variantes no tempo ($\sum_{j=1}^m \beta_j x_{jt}$). Tal modelo pode ser escrito como:

$$y_t = \mu_t + \gamma_t + \psi_t + \sum_{j=1}^m \beta_j x_{jt} + \epsilon_t$$

onde

$$\epsilon_t \sim \mathcal{N}(0, \sigma_\epsilon)$$

Uma vez que utilizamos variáveis já dessazonalizadas e que não estamos interessados na identificação do melhor modelo estocástico e sim na comparação de metodologias, não utilizaremos regressores auxiliares. Neste caso, o modelo se reduz a:

$$y_t = \mu_t + \psi_t + \epsilon_t$$

São necessárias duas equações de transição, uma para a tendência e uma para o ciclo. A equação de transição da tendência pode ser descrita como um modelo de tendência linear local, onde tanto o nível quanto a inclinação são componentes estocásticos:

$$\mu_t = \mu_{t-1} + \beta_t + \eta_t$$

$$\beta_t = \beta_{t-1} + \nu_t$$

onde $\eta_t \sim \mathcal{IIN}(0, \sigma_\eta)$ e $\nu_t \sim \mathcal{IIN}(0, \sigma_{\nu_t})$ são independentes e normalmente distribuídas.

Já a equação de transição do componente cíclico pode ser descrita como:

$$\begin{bmatrix} \psi_t \\ \psi_t^* \end{bmatrix} = \rho \begin{bmatrix} \cos \lambda & \sin \lambda \\ -\sin \lambda & \cos \lambda \end{bmatrix} \begin{bmatrix} \psi_{t-1} \\ \psi_{t-1}^* \end{bmatrix} + \begin{bmatrix} \omega_t \\ \omega_t^* \end{bmatrix}$$

Os termos ρ e λ representam, respectivamente, o fator de suavização e a frequência do ciclo. O modelo pode ser colocado na forma de estado-espço e seus parâmetros estimados através do filtro de Kalman. Para uma ampla revisão destes modelos, ver Harvey (1989).

3.4.6 Método da Regressão Linear de Hamilton (2017)

O filtro HP, apesar de permitir a extração ótima do sinal e a separação entre componentes ortogonais (KING; REBELO, 1993), apresenta também uma série de desvantagens, sobretudo relacionadas a suas características no fim da amostra (MISE et al, 2005). Hamilton (2017) critica o uso do filtro. A crítica se baseia em três pontos principais: i) produção de séries com relações dinâmicas espúrias, as quais não possuem embasamento no processo gerador de dados, ii) problemas de fim de amostra, onde os valores filtrados são muito distintos daqueles obtidos no meio da amostra e que também são caracterizados por dinâmica espúria e, finalmente, iii) a formalização estatística do problema gera valores do parâmetro de suavização conflitantes com aqueles utilizados na maior parte dos trabalhos.

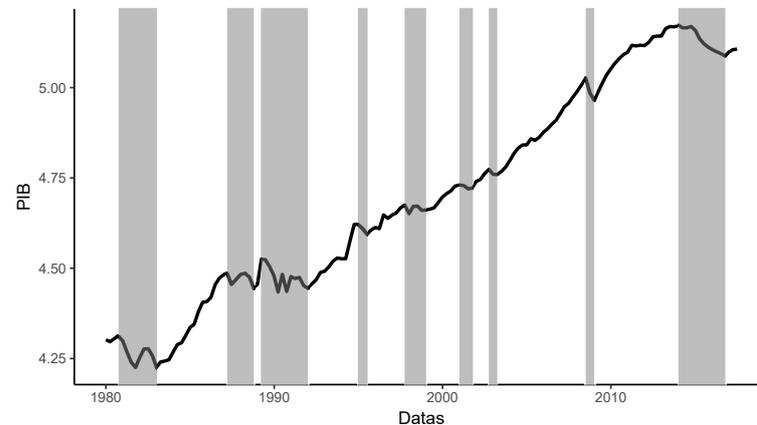
Como alternativa, Hamilton (2017) propõe uma simples projeção linear da variável observada em $t + h$ contra uma constante e quatro *lags* a partir da data t . Conforme o autor argumenta, "a principal razão pela qual nós estaríamos errados em prever o valor da maior parte das variáveis macroeconômicas e financeiras em um horizonte de $h = 8$ trimestres a frente seria fatores cíclicos como a ocorrência de uma recessão nos próximos dois anos e o tempo de recuperação de uma desaceleração"(HAMILTON, 2017, p.12). Assim, para a frequência trimestral, um modelo apropriado para obter dados suavizados do PIB seria a regressão:

$$y_t = \alpha + \beta_1 y_{t-8} + \beta_2 y_{t-9} + \beta_3 y_{t-10} + \beta_4 y_{t-11} + e_t \quad (3.9)$$

em que os resíduos e_t poderiam ser interpretados como componente cíclico.

3.5 Os dados

Para construção da série histórica do PIB trimestral entre 1980.I e 2017.III as séries históricas do PIB com ajuste sazonal disponíveis no site do IPEADData (1980.I a 2014.II) e do IBGE (2002.I a 2017.III) foram encadeadas, retropolando-se esta última para trás utilizando-se as variações da primeira. O resultado, em logaritmo, pode ser visualizado na Figura 3.1, juntamente com os período de recessão na economia brasileira identificados pelo CODACE.

Figura 3.1: PIB trimestral do Brasil (log) - 1980.I - 2017.III

Note: Áreas cinzas correspondem aos períodos de recessão identificados pelo CODACE/FGV-IBRE para a economia brasileira, incluindo-se os picos.

Fonte dos dados brutos: IBGE, IPEA e FGV. Elaboração própria.

3.6 Resultados empíricos

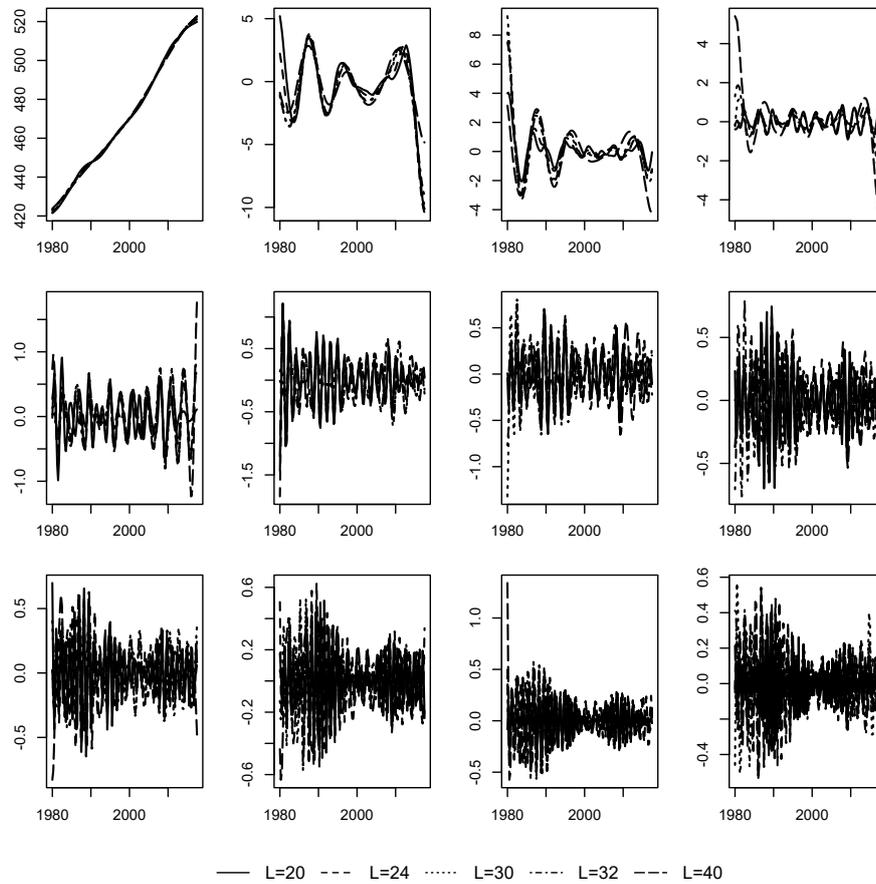
A seguir, os resultados empíricos são analisados.

3.6.1 Inspeção visual e estatísticas descritivas

Conforme discutido anteriormente, a estratégia adotada por Carvalho e Rua (2017), apesar de fornecer um método para agrupamento dos componentes principais em aplicações da SSA voltadas à análise dos ciclos de negócios, ainda deixa a escolha do tamanho da janela L como um procedimento *ad hoc*. Os autores justificam o tamanho de janela de 32 trimestres baseados no *cut-off* superior comumente utilizado na literatura para expurgar ciclos não relacionados à frequência dos ciclos de negócios, isto é, maiores do que 8 anos. No entanto, diversos outros valores podem ser encontrados na literatura.

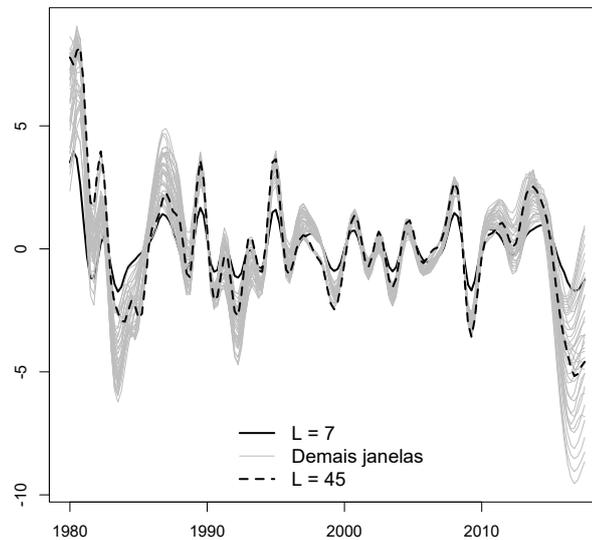
De modo a visualizar o efeito de diferentes escolhas de janela na decomposição do PIB brasileiro, a Figura 1 apresenta as séries de tempo reconstruídas com os autovetores obtidos no passo de decomposição do valor singular - os componentes principais - para diferentes janelas encontradas na literatura aplicada a flutuações econômicas: $L = 20$ (GONZALEZ et al., 2015), $L = 24$ (GROTH et al., 2015), $L = 30$ (SELLA; MARCHIONATTI, 2012), $L = 32$ (CARVALHO et al., 2012; CARVALHO; RUA, 2017), $L = 40$ (DUMAS et al., 2011). Nota-se que a maior parte destas janelas também obedece ao critério sugerido por Golyanidna et al. (2001), uma vez que os dados são trimestrais e as janelas são em sua maioria múltiplas de quatro.

Figura 3.2: 12 primeiros componentes principais para diferentes valores de L



Fonte: Elaboração própria.

Como pode ser observado, o primeiro componente principal responde pela maior parte da variância dos dados, caracterizando a tendência crescente do PIB ao longo do tempo, com poucas oscilações, havendo poucas diferenças notáveis entre as distintas janelas. A partir do segundo componente principal, a simples inspeção visual já permite identificar discrepâncias causadas por mudanças nas janelas. Estas diferenças se mostram mais nítidas, sobretudo, nas pontas das séries, justamente onde há maior necessidade de acurácia quanto à a magnitude do hiato do produto e ao *timing* de virada dos ciclos.

Figura 3.3: Séries reconstruídas

Fonte: Elaboração própria.

De modo a tornar a análise mais minuciosa, podemos expandir a grade de janelas estudadas. A figura 2 mostra a série de tempo do hiato do PIB reconstruída para todas as janelas entre 7 e 45 trimestres, utilizando para agrupamento o pseudo-algoritmo de Carvalho e Rua (2017). Note que essa grade abrange todas as janelas utilizadas na literatura anteriormente citadas. O primeiro fato a se observar, novamente, é a grande variabilidade das estimativas de ciclo nas pontas das séries em relação ao centro da amostra. O hiato do produto, se interpretado desta forma, varia, por exemplo entre +2,35% e +8,62% no primeiro trimestre de 1980 e entre -8,34% e +0,9% no terceiro trimestre de 2017. Ademais, é importante notar que não parece haver uma relação direta entre o limite inferior ou superior dos ciclos estimados e o tamanho da janela. Em diversos períodos, outras janelas apresentam valores do ciclo estimado maiores (menores) do que as janelas mínima e máxima analisadas.

De forma a sumarizar as propriedades dos ciclos obtidos com as diferentes janelas, computamos diversas estatísticas descritivas, tais como média, desvio padrão, coeficiente de autocorrelação, coeficiente de assimetria e de excesso de curtose. Como forma de comparação, computamos as mesmas estatísticas para uma série de outros filtros utilizados na literatura. Os filtros considerados foram: Tendência Linear (LT), Tendência Quadrática (QT), Primeira Diferença (FD), Filtro Hodrick-Prescott (HP), Filtro Christiano-Fitzgerald (CF), Método dos Componentes Não-Observáveis (UC) e Filtro de Regressão de Hamilton (HRF). A tabela 1 expõe os resultados.

Tabela 1: Estatísticas Descritivas

	Mínimo	Máximo	Média	Desvio-Padrão	Autocorrelação	Assimetria	Curtose
L=7	-1.74	1.67	-0.05	0.80	0.88	-0.04	-0.57
L=8	-2.73	3.10	-0.08	1.19	0.83	0.06	-0.21
L=9	-3.29	2.74	-0.11	1.29	0.89	-0.17	-0.27
L=10	-3.97	3.82	-0.16	1.60	0.86	-0.17	-0.10
L=11	-4.63	3.47	-0.20	1.74	0.91	-0.43	0.05
L=12	-5.39	3.27	-0.24	1.89	0.94	-0.63	0.38
L=13	-6.18	3.45	-0.28	2.03	0.96	-0.80	0.73
L=14	-6.82	3.85	-0.32	2.29	0.95	-0.79	0.65
L=15	-7.47	3.91	-0.36	2.43	0.96	-0.91	0.91
L=16	-8.12	4.12	-0.40	2.57	0.98	-0.99	1.14
L=17	-8.53	4.64	-0.44	2.78	0.97	-0.94	1.00
L=18	-9.05	4.69	-0.47	2.91	0.98	-0.99	1.10
L=19	-9.55	4.90	-0.50	3.03	0.99	-1.02	1.16
L=20	-3.23	3.05	-0.08	1.30	0.82	-0.03	-0.19
L=21	-3.50	2.96	-0.10	1.33	0.84	-0.11	-0.25
L=22	-3.80	2.96	-0.12	1.37	0.86	-0.16	-0.20
L=23	-4.07	2.95	-0.14	1.41	0.87	-0.22	-0.13
L=24	-4.26	3.28	-0.16	1.53	0.87	-0.18	-0.13
L=25	-4.51	3.31	-0.18	1.58	0.88	-0.20	-0.12
L=26	-4.66	3.35	-0.20	1.62	0.89	-0.20	-0.15
L=27	-4.67	3.36	-0.22	1.66	0.90	-0.21	-0.24
L=28	-4.88	3.61	-0.23	1.75	0.90	-0.20	-0.22
L=29	-5.06	3.64	-0.24	1.81	0.91	-0.22	-0.26
L=30	-5.04	3.63	-0.26	1.86	0.92	-0.23	-0.37
L=31	-5.30	3.76	-0.27	1.95	0.92	-0.25	-0.36
L=32	-5.50	3.99	-0.28	2.05	0.91	-0.25	-0.31
L=33	-5.31	3.79	-0.29	2.07	0.93	-0.30	-0.42
L=34	-5.40	3.74	-0.31	2.15	0.94	-0.34	-0.40
L=35	-5.65	3.86	-0.32	2.25	0.95	-0.39	-0.32
L=36	-6.09	3.90	-0.34	2.35	0.95	-0.46	-0.19
L=37	-6.69	3.94	-0.36	2.44	0.95	-0.52	-0.06
L=38	-7.13	3.93	-0.38	2.54	0.96	-0.58	0.03
L=39	-7.32	4.16	-0.40	2.64	0.97	-0.63	0.11
L=40	-4.09	3.28	-0.23	1.58	0.90	-0.29	-0.10
L=41	-4.27	3.48	-0.24	1.66	0.90	-0.31	-0.08
L=42	-4.61	3.50	-0.25	1.72	0.91	-0.37	-0.03
L=43	-4.95	3.62	-0.25	1.76	0.90	-0.34	-0.07
L=44	-4.91	3.63	-0.26	1.81	0.92	-0.41	-0.02
L=45	-5.17	3.65	-0.27	1.85	0.92	-0.44	0.06
LT	-9.02	8.99	-0.30	4.94	0.95	0.32	-1.11
QT	-11.91	8.74	-0.11	4.86	0.95	-0.13	-0.58
FD	-4.70	7.10	0.59	1.75	0.09	-0.10	1.96
HP	-5.78	5.43	-0.08	2.37	0.76	0.01	0.05
CF	-3.94	4.29	-0.12	1.64	0.86	0.18	-0.27
UC	-0.16	0.16	-0.00	0.11	0.92	0.05	-1.49
HRF	-13.31	11.00	-0.00	5.29	0.83	-0.38	-0.28

Os resultados são bastante diversos. Os valores mínimos oscilam entre -13,31 (HRF) e -0,16 (UC), enquanto os máximos estão entre 0,16 (UC) e 11,00 (HRF). Dentre as diferentes estimativas utilizando a SSA, os valores mínimos variam entre -9,55 (L=19) e -1,74 (L=7), e os máximos entre 1,67 e 4,9 para as mesmas janelas, respectivamente. As médias de todos os filtros são próximas de zero, enquanto o desvio-padrão varia entre 0,11 (UC) e 5,29 (HRF). É importante observar também que existe uma alta autocorrelação de ordem 1 para todos os filtros estimados, exceto para o filtro de primeira diferença (FD). Ademais, a maior parte dos filtros mostra-se levemente assimétrica à esquerda, com excessão dos filtros LT, HP, CF e UC. Por fim, há grande heterogeneidade nos valores das estatísticas de curtose, mesmo dentre as SSA, onde alguns filtros sugerem distribuições leptocúrticas, com excesso de valores extremos e outras sugerem distribuições platicúrticas. Utilizando-se um teste de Jarque-Bera para checagem da hipótese de normalidade dos dados, ao nível de 10%, os únicos filtros para os quais a hipótese de normalidade dos dados não é rejeitada são: LT, FD, UC e os SSA com janelas L=11 e L=19, inclusive, e L=35, L=36, L=37, L=38, L=39 e L=45.

É interessante computar também os coeficientes de correlação de Pearson entre os ciclos de cada uma das janelas e outros filtros utilizados na literatura (2). Percebemos que a maior correlação existente se dá entre as janelas 21 e 22 e o filtro CF, com coeficiente de 0,95, enquanto a menor correlação ocorre entre as janelas 16 e 19, com o método UC, com coeficiente de 0,13. Outro fato notável é que o próprio o padrão de correlação apresenta "ondas" ou "degraus". Por exemplo, conforme a janela aumenta, a correlação da SSA com os métodos de tendência linear e quadrática aumenta entre as janelas 7 e 19, cai bruscamente na janela 20 e volta a subir novamente até a janela 39, quando novamente cai e reinicia seu crescimento. Padrão similar, porém inverso, é encontrado no filtro CF. A correlação decresce inicialmente, sobe um "degrau" nas janelas 20 e 39 e volta a cair. No método UC este padrão se mostra presente também, com alguns repiques de crescimento, por exemplo entre as janelas 20 a 23. A partir da janela 40, contudo, a correlação se estabiliza entre 0,15 e 0,17. Já os métodos FD e HP apresentam coeficientes de correlação com comportamento cíclico, onde os ciclos no coeficiente de correlação são mais curtos no primeiro método do que no segundo. Por fim, o filtro HRF apresenta padrão semelhante ao dos filtros LT e QT, porém a correlação se estabiliza entre 0,55 e 0,56 após a janela 39.

Tabela 2: Correlação

	LT	QT	FD	HP	CF	UC	HRF
L= 7	0.66	0.72	0.16	0.82	0.88	0.22	0.55
L= 8	0.64	0.69	0.21	0.84	0.89	0.19	0.55
L= 9	0.68	0.75	0.18	0.84	0.88	0.20	0.60
L= 10	0.69	0.77	0.21	0.85	0.86	0.18	0.61
L= 11	0.72	0.80	0.19	0.83	0.84	0.18	0.63
L= 12	0.74	0.83	0.17	0.81	0.81	0.17	0.65
L= 13	0.75	0.84	0.17	0.79	0.77	0.16	0.66
L= 14	0.75	0.85	0.19	0.81	0.78	0.14	0.65
L= 15	0.76	0.86	0.17	0.79	0.75	0.14	0.65
L= 16	0.76	0.87	0.17	0.77	0.72	0.13	0.65
L= 17	0.77	0.88	0.18	0.78	0.72	0.13	0.66
L= 18	0.77	0.88	0.17	0.76	0.70	0.13	0.66
L= 19	0.77	0.88	0.17	0.75	0.68	0.13	0.66
L= 20	0.49	0.53	0.19	0.82	0.94	0.17	0.50
L= 21	0.52	0.56	0.18	0.84	0.95	0.18	0.52
L= 22	0.54	0.60	0.16	0.85	0.95	0.19	0.54
L= 23	0.57	0.62	0.16	0.86	0.94	0.19	0.55
L= 24	0.59	0.65	0.16	0.88	0.94	0.18	0.56
L= 25	0.60	0.67	0.14	0.88	0.93	0.17	0.56
L= 26	0.62	0.69	0.14	0.88	0.92	0.17	0.57
L= 27	0.64	0.71	0.13	0.88	0.90	0.16	0.58
L= 28	0.66	0.73	0.14	0.90	0.90	0.16	0.58
L= 29	0.67	0.74	0.13	0.89	0.89	0.15	0.59
L= 30	0.69	0.77	0.13	0.89	0.87	0.15	0.60
L= 31	0.71	0.79	0.14	0.89	0.86	0.15	0.60
L= 32	0.72	0.80	0.15	0.89	0.85	0.15	0.62
L= 33	0.73	0.82	0.14	0.87	0.83	0.15	0.62
L= 34	0.75	0.83	0.14	0.86	0.81	0.15	0.63
L= 35	0.76	0.85	0.15	0.86	0.80	0.14	0.63
L= 36	0.76	0.85	0.15	0.85	0.78	0.14	0.64
L= 37	0.77	0.86	0.15	0.83	0.76	0.14	0.65
L= 38	0.77	0.87	0.15	0.82	0.75	0.14	0.64
L= 39	0.78	0.88	0.16	0.81	0.73	0.14	0.65
L= 40	0.61	0.70	0.17	0.74	0.87	0.15	0.56
L= 41	0.63	0.71	0.17	0.75	0.86	0.17	0.56
L= 42	0.64	0.72	0.16	0.74	0.86	0.17	0.56
L= 43	0.64	0.73	0.16	0.76	0.86	0.16	0.56
L= 44	0.65	0.74	0.15	0.76	0.85	0.17	0.55
L= 45	0.67	0.75	0.14	0.76	0.83	0.16	0.56

3.6.2 Análise dos *turning points*

Utilizando como *benchmark* a cronologia dos ciclos do CODACE, o *timing* cíclico obtido com os diferentes filtros é avaliado, computando-se diversas estatísticas, tais como número de *turning points*, percentual de alarmes falsos, percentual de sinais perdidos,

número de vezes em que o pico ou o vale corresponde exatamente à data do *benchmark*, média e desvio padrão da distância, em trimestres, entre a data do ponto de virada no componente cíclico e aquela do *benchmark*. Seguindo Canova (1999), considera-se um sinal emitido - um pico ou um vale - como falso, caso não exista um sinal correspondente na cronologia do CODACE em um intervalo de até ± 3 trimestres ao redor da data do sinal emitido pelo filtro. Já um sinal perdido é computado caso não haja nenhum *turning point* emitido pelo filtro em um intervalo de até ± 3 trimestres ao redor da data sinalizada pelo CODACE. Os pontos de virada são computados aplicando-se o algoritmo Bry-Boschan trimestral Harding e Pagan (2002) aos componentes cíclicos obtidos através dos diferentes filtros. Apesar de o algoritmo ser tradicionalmente aplicado às séries em nível, o conjunto de regras permite identificar pontos de mínimos e máximos locais associados a *turning points* nos ciclos de crescimento (ver, por exemplo, Pagan (1997), para o caso de países desenvolvidos e Campelo et al. (2013) para o caso do Brasil).

No que tange a características dos *turning points*, existe pouca variabilidade na maior parte das estatísticas computadas para as diferentes janelas da SSA. Enquanto o número de picos encontrados varia entre 12 e 13, o número de vales gravita entre 13 e 14. A diferença ocorre porque o primeiro pico não foi captado pelo algoritmo Bry-Boschan por estar situado no início da amostra, havendo, portanto mais vales do que picos. O CODACE, contudo, aponta a existência de apenas 9 picos e 9 vales no ciclo clássico brasileiro até o momento. Conforme discutido na seção 3.2, o fato de haver mais pontos de virada em nossas estimativas deve ser visto como uma característica dos ciclos de crescimento. No que tange aos demais métodos, o número de picos varia entre 7 (QT) e 14 (FD) e de vales entre 7 (QT) e 13 (FD e CF). Ademais, os únicos filtros que apresentaram o mesmo número de picos e vales foram QT, UC e HRF.

Com relação ao percentual de alarmes falsos, 27 das 39 janelas testadas apontam que de 12 picos encontrados, 4 não possuem correspondência com algum pico do CODACE. Os percentuais variam entre 30, 77% (L=10) e 41, 67% (L=17). Já os percentuais de alarmes falsos nos vales apresentam maior variabilidade, não havendo uma frequência tão alta para um mesmo valor. Os valores variam entre 35, 71% (L=10) e 64, 29% (L=33 e L=34). Em comparação com os demais filtros testados, a amplitude de valores de percentuais falsos obtidos pelas diferentes janelas da SSA é menor do que a amplitude obtida com os demais filtros, tanto para os picos como para os vales. Os valores variam entre 12, 50% (LT) e 55, 60% (UC) no caso dos picos e entre 28, 57% (QT) e 88, 89% (UC) nos vales.

Enquanto a ocorrência de sinais falsos pode indicar apenas o surgimento de períodos de desaceleração na atividade sem que necessariamente isto se transforme em queda na atividade econômica, a existência de sinais perdidos pode indicar a falha de um método em alertar ou confirmar a ocorrência de uma recessão. Para todas as janelas testadas, contudo, o percentual de sinais perdidos é menor do que o de sinais falsos, tanto para os picos quanto para os vales. No caso dos picos, 38 das 39 janelas testadas apontam

um percentual de sinais perdidos de 11,11%, isto é, dos 9 picos datados pelo CODACE, apenas um - o de 1980.IV - não foi captado. A única exceção é a janela $L=17$, em que o pico de 1997.IV também foi tido como perdido, uma vez que o sinal surge em 1996.IV, logo com antecedência maior do que 3 trimestres. Considerando-se os demais métodos, a SSA, juntamente com o filtro CF obtiveram o menor percentual de sinais perdidos. O maior percentual de sinais perdidos (55,56%), por outro lado, ocorre com o método UC.

Por fim, para aqueles pontos de virada identificados com uma diferença de até 3 trimestres computamos também a média e o desvio padrão da diferença em trimestres entre a data do *turning point* nos ciclos de crescimento - de cada um dos filtros - e as datas dos turning points do CODACE. Os resultados mostram que, em média, os ciclos de crescimento antecipam os picos dos ciclos de negócios. Por outro lado, seus vales ocorrem, em média, menos de um trimestre após as datas do CODACE. Como os dados são trimestrais, pode-se dizer, portanto, que os vales são coincidentes. Este resultado está em conformidade com os registros da literatura, conforme discutido na seção 2.

Tabela 3: Análise dos Pontos de Virada - Picos

	Metodo	Numero	Perc. de Alarmes Falsos	Perc. de Missings	Num. de Acertos	Média do Sinal	Desv. Padrão do Sinal
1	L= 7	12	33.33	11.11	1.00	-0.50	1.41
2	L= 8	12	33.33	11.11	1.00	-0.25	1.58
3	L= 9	12	33.33	11.11	1.00	-0.50	1.41
4	L= 10	13	30.77	11.11	1.00	-0.75	0.89
5	L= 11	12	33.33	11.11	1.00	-0.38	1.30
6	L= 12	12	33.33	11.11	1.00	-0.62	1.19
7	L= 13	12	33.33	11.11	1.00	-0.62	1.19
8	L= 14	12	33.33	11.11	1.00	-0.88	1.46
9	L= 15	12	33.33	11.11	2.00	-1.00	1.31
10	L= 16	12	33.33	11.11	1.00	-1.00	1.20
11	L= 17	12	41.67	22.22	1.00	-1.00	1.15
12	L= 18	12	33.33	11.11	1.00	-1.38	1.41
13	L= 19	12	33.33	11.11	1.00	-1.25	1.39
14	L= 20	12	33.33	11.11	2.00	-0.38	1.41
15	L= 21	12	33.33	11.11	1.00	-0.88	1.46
16	L= 22	12	33.33	11.11	1.00	-1.00	1.60
17	L= 23	12	33.33	11.11	2.00	-1.12	1.46
18	L= 24	12	33.33	11.11	1.00	-0.88	1.46
19	L= 25	12	33.33	11.11	1.00	-1.12	1.25
20	L= 26	12	33.33	11.11	1.00	-1.25	1.39
21	L= 27	12	33.33	11.11	1.00	-1.25	1.39
22	L= 28	12	33.33	11.11	1.00	-1.12	1.25
23	L= 29	12	33.33	11.11	1.00	-1.00	1.20
24	L= 30	12	33.33	11.11	1.00	-1.12	1.25
25	L= 31	12	33.33	11.11	1.00	-1.12	1.25
26	L= 32	12	33.33	11.11	1.00	-1.12	1.25
27	L= 33	13	38.46	11.11	1.00	-1.12	1.25
28	L= 34	13	38.46	11.11	1.00	-1.12	1.25
29	L= 35	12	33.33	11.11	1.00	-1.00	1.20
30	L= 36	13	38.46	11.11	1.00	-1.12	1.25
31	L= 37	12	33.33	11.11	1.00	-1.12	1.25
32	L= 38	13	38.46	11.11	2.00	-1.00	1.31
33	L= 39	12	33.33	11.11	1.00	-1.00	1.20
34	L= 40	13	38.46	11.11	1.00	-1.12	1.25
35	L= 41	13	38.46	11.11	1.00	-1.12	1.25
36	L= 42	13	38.46	11.11	1.00	-1.25	1.28
37	L= 43	13	38.46	11.11	1.00	-1.12	1.25
38	L= 44	13	38.46	11.11	1.00	-1.12	1.25
39	L= 45	12	33.33	11.11	1.00	-1.00	1.20
40	LT	8	12.50	22.22	3.00	-0.86	1.07
41	QT	7	14.29	33.33	3.00	-0.50	0.55
42	FD	14	42.86	33.33	1.00	-1.33	2.42
43	HP	9	22.22	22.22	4.00	-0.43	0.53
44	CF	12	33.33	11.11	1.00	-0.50	1.41
45	UC	9	55.56	55.56	0.00	-1.50	1.73
46	HRF	10	40.00	33.33	4.00	0.00	0.63

Tabela 4: Análise dos Pontos de Virada - Vales

	Metodo	Numero	Perc. de Alarmes Falsos	Perc. de Missings	Num. de Acertos	Média do Sinal	Desv. Padrão do Sinal
1	L= 7	13	46.15	22.22	2.00	0.78	0.97
2	L= 8	13	46.15	22.22	3.00	0.89	0.78
3	L= 9	13	46.15	22.22	1.00	0.67	1.12
4	L= 10	14	35.71	0.00	3.00	0.67	0.50
5	L= 11	13	46.15	22.22	3.00	0.89	0.78
6	L= 12	13	46.15	22.22	3.00	0.89	0.78
7	L= 13	13	46.15	22.22	2.00	0.78	0.97
8	L= 14	13	46.15	22.22	3.00	0.89	0.78
9	L= 15	13	46.15	22.22	3.00	0.89	0.78
10	L= 16	13	46.15	22.22	2.00	0.78	0.97
11	L= 17	13	46.15	22.22	3.00	0.89	0.78
12	L= 18	13	46.15	22.22	3.00	0.89	0.78
13	L= 19	13	46.15	22.22	3.00	0.89	0.78
14	L= 20	13	53.85	33.33	1.00	0.44	1.59
15	L= 21	13	53.85	33.33	1.00	0.56	1.33
16	L= 22	13	53.85	33.33	1.00	0.56	1.33
17	L= 23	13	53.85	33.33	1.00	0.56	1.33
18	L= 24	13	53.85	33.33	1.00	0.56	1.33
19	L= 25	13	53.85	33.33	1.00	0.56	1.33
20	L= 26	13	53.85	33.33	1.00	0.56	1.33
21	L= 27	13	61.54	44.44	1.00	0.67	1.41
22	L= 28	13	53.85	33.33	1.00	0.56	1.33
23	L= 29	13	61.54	44.44	1.00	0.67	1.41
24	L= 30	13	53.85	33.33	1.00	0.78	1.20
25	L= 31	13	53.85	33.33	2.00	0.67	1.22
26	L= 32	13	53.85	33.33	2.00	0.67	1.22
27	L= 33	14	64.29	44.44	2.00	0.78	1.30
28	L= 34	14	64.29	44.44	2.00	0.78	1.30
29	L= 35	13	53.85	33.33	2.00	0.67	1.22
30	L= 36	14	57.14	33.33	2.00	0.89	1.05
31	L= 37	13	53.85	33.33	2.00	0.89	1.05
32	L= 38	14	50.00	22.22	2.00	0.78	0.97
33	L= 39	13	46.15	22.22	2.00	0.78	0.97
34	L= 40	14	57.14	33.33	1.00	0.56	1.33
35	L= 41	14	50.00	22.22	2.00	1.00	0.71
36	L= 42	14	50.00	22.22	2.00	1.00	0.71
37	L= 43	14	50.00	22.22	3.00	1.00	1.00
38	L= 44	14	50.00	22.22	2.00	1.11	0.93
39	L= 45	13	46.15	22.22	3.00	0.75	0.71
40	LT	9	33.33	33.33	6.00	0.62	1.19
41	QT	7	28.57	44.44	5.00	0.71	1.25
42	FD	13	69.23	55.56	2.00	-0.50	0.58
43	HP	10	40.00	33.33	6.00	0.62	1.19
44	CF	13	53.85	33.33	2.00	0.44	1.33
45	UC	9	88.89	88.89	0.00	-0.50	2.81
46	HRF	10	60.00	55.56	3.00	-0.33	1.63

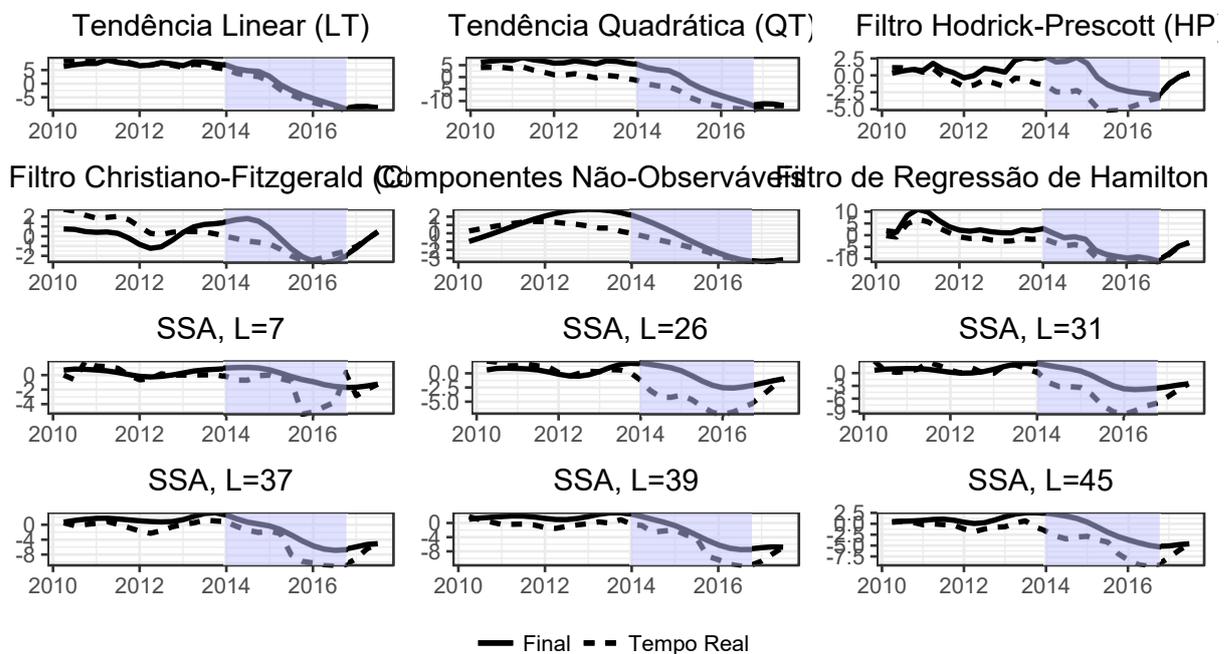
3.6.3 Performance em (quase) tempo real

Na seção anterior foi analisada a sensibilidade dos ciclos de crescimento a diferentes métodos de estimação, com ênfase na escolha do tamanho de janela da SSA, utilizando-se o conjunto de informação completo até o fim da amostra. Estimativas dos ciclos, contudo,

estão sujeitas a incerteza em tempo real, advindas não apenas da atualização dos valores divulgados pelos órgãos de informações estatísticas mas também devido ao recômputo das estimativas dos ciclos com a inclusão de observações adicionais (ORPHANIDES; VAN NORDE, 2002). Acessar o grau de confiabilidade nas estimativas dos ciclos em tempo real, portanto, é de particular importância para *policy makers* preocupados com o *timing* das políticas monetária e fiscal, bem como de gestores privados e famílias em suas decisões de consumo e investimento. Neste trabalho, o foco é voltado para a sensibilidade das estimativas em relação ao método/janela utilizada. Em face disso, nesta seção são conduzidos alguns exercícios em quase tempo real, isto é, a única fonte de alteração nos dados provém do recômputo das estimativas de ciclo com a inclusão de observações adicionais.

O exercício é conduzido sobre os 20% finais da amostra (2010.II a 2017.III): a cada novo trimestre o hiato do produto é recomputado e a última observação é salva. A série formada por estas observações salvas é chamada de série de estimativas em tempo real. A mesma é contrastada com a série de estimativa finais, que consiste nos 20% finais da série de hiato obtido utilizando-se o conjunto de informações até 2017.III. As diferenças podem ser visualizadas na Figura 3.4 para os métodos LT,QT,FD,HP,CF,UC e SSA com janelas selecionadas.

Figura 3.4: Estimativas Finais e em Quase Tempo Real - 2010.II a 2017.III



Fonte: Elaboração própria.

Adicionalmente, três estatísticas de confiabilidade das estimativas em quase tempo real são reportadas na tabela 5: o coeficiente de correlação entre as estimativas final e em tempo real, a razão ruído-sinal - computada como a divisão entre duas outras estatísticas:

o desvio padrão da distância vertical entre a estimativa final e a estimativa em tempo real e o desvio padrão da estimativa final - e o grau de concordância, isto é, o percentual do tempo em que as estimativas final e em tempo real apresentam o mesmo sinal (maior que zero ou menor que zero).

Tabela 5: Estatísticas de Confiabilidade

	Correlacao	Razao_Ruido_Sinal	Concordancia
SSA 7	0.64	1.53	0.53
SSA 8	0.79	1.30	0.73
SSA 9	0.74	1.11	0.67
SSA 10	0.63	1.04	0.67
SSA 11	0.84	0.81	0.77
SSA 12	0.88	0.67	0.67
SSA 13	0.90	0.56	0.60
SSA 14	0.91	0.50	0.57
SSA 15	0.92	0.44	0.60
SSA 16	0.93	0.40	0.63
SSA 17	0.93	0.39	0.57
SSA 18	0.93	0.39	0.57
SSA 19	0.94	0.36	0.63
SSA 20	0.76	3.77	0.63
SSA 21	0.77	3.00	0.63
SSA 22	0.74	2.42	0.70
SSA 23	0.69	1.44	0.67
SSA 24	0.74	1.49	0.70
SSA 25	0.70	1.62	0.77
SSA 26	0.69	1.70	0.77
SSA 27	0.71	1.51	0.67
SSA 28	0.73	1.37	0.57
SSA 29	0.80	1.19	0.67
SSA 30	0.82	1.13	0.70
SSA 31	0.84	1.18	0.83
SSA 32	0.89	0.83	0.57
SSA 33	0.90	0.71	0.53
SSA 34	0.92	0.63	0.60
SSA 35	0.93	0.59	0.63
SSA 36	0.94	0.51	0.63
SSA 37	0.96	0.43	0.70
SSA 38	0.96	0.38	0.63
SSA 39	0.96	0.35	0.53
SSA 40	0.86	1.25	0.57
SSA 41	0.87	0.94	0.67
SSA 42	0.88	0.61	0.63
SSA 43	0.80	0.74	0.50
SSA 44	0.83	0.72	0.43
SSA 45	0.88	0.62	0.50
LT	0.99	0.17	1.00
QT	0.97	0.26	0.77
FD	1.00	0.00	1.00
HP	0.53	1.04	0.57
CF	0.53	1.00	0.67
UC	0.88	0.48	0.73
HRF	0.99	0.20	0.60

O coeficiente de correlação mais alto corresponde ao método FD (1,00), seguido pelos métodos LT e HRF (0,99) e QT (0,97). Estes resultados são esperados, uma vez que a adição de uma nova observação - excetuando-se o caso de *outliers* - não altera o valor da primeira diferença das observações passadas e pouco altera a soma do quadrado dos resíduos nas regressões lineares, não movimentando, portanto, a reta de regressão. No caso da SSA, as janelas que apresentam maior correlação entre as séries final e em tempo real são $L = 37$, $L = 38$ e $L = 39$, todas com coeficiente de 0,96. Nota-se ainda que para qualquer uma das janelas consideradas, a correlação é maior do que no caso dos tradicionais filtros HP e CF, os quais apresentam a menor correlação entre os métodos apresentados (0,53).

A razão ruído-sinal permite captar os efeitos de revisões persistentes para cima ou para baixo nas reestimações dos ciclos. Quanto menor esta estatística, maior a consistência entre as estimativas final e em tempo real. Assim, pelos mesmos motivos, novamente os filtros lineares FD, LT, HRF e QT apresentaram as menores razões ruído-sinal. No entanto, 22 das 39 estimativas com SSA superaram, por este critério, os filtros CF e HP, cujas razões eram 1,00 e 1,04, respectivamente. Os menores valores obtidos com a SSA foram para as janelas $L = 19$ (0,36), $L = 38$ (0,38) e $L = 39$ (0,35).

Finalmente, o grau de concordância indica se a informação acerca do sobreaquecimento ou subaquecimento da economia - isto é, se o produto efetivo é maior ou menor que o potencial - é consistente entre as estimativas final e em tempo real. Os filtros FD e LT apresentaram concordância em 100% do tempo. Já o filtro HP teve a pior performance em tempo real dos métodos alternativos à SSA, com grau de concordância de 0,57. Algumas janelas, contudo, performaram pior, como $L=7$ e $L=33$, com grau de concordância de 0,53. Por outro lado, a janela $L = 31$ obteve a segunda melhor performance dentre todos os filtros considerados, com coeficiente de concordância de 0,83. Já empatados em terceiro lugar estão as janelas $L = 11$, $L = 25$, $L = 26$ e o filtro QT, todos com coeficiente de 0,77.

Os resultados apresentados evidenciam o potencial da SSA enquanto método de extração do componente cíclico do PIB brasileiro em relação a alguns dos principais filtros da literatura, particularmente os filtros CF e HP. Para determinados valores de janelas, por exemplo $L=37$, a SSA superou a performance destes filtros nas três estatísticas consideradas. Para a mesma janela, os únicos filtros que performaram melhor que a SSA foram LT, QT e FD, os quais envolvem hipóteses fortes acerca da tendência de longo prazo e das oscilações de curto prazo, conforme discutido anteriormente.

3.7 Conclusão

Flutuações cíclicas são características da maior parte das séries de tempo macroeconômicas. Estes movimentos de curto que ocorrem nos principais indicadores das economias

de mercado são conhecidos como ciclos de negócios. Neste trabalho, em complementação à abordagem dos ciclos clássicos utilizada pelo CODACE-IBRE/FGV, propõe-se estudar as flutuações do PIB trimestral do Brasil em torno de sua tendência de longo prazo, conhecidas como ciclos de crescimento, no período entre 1980 e 2017. Para tanto, a Análise do Espectro Singular (SSA) é empregada, utilizando-se o procedimento de agrupamento de Carvalho e Rua (2017).

Ao explorar diversas características dos ciclos obtidos com diferentes tamanhos de janela e contrastá-las a outros filtros utilizados na literatura, pode-se responder às perguntas propostas na introdução. Em primeiro lugar, a SSA com estratégia de agrupamento de Carvalho e Rua (2017) se mostra um método interessante para estudar os ciclos de crescimento no Brasil, sob diversos aspectos. A estratégia de agrupamento permite identificar os componentes associados à frequência dos ciclos de negócios, removendo componentes associados à tendência ou outras oscilações de curto prazo, gerando ciclos suaves. Os resultados, contudo, mostram-se sensíveis à escolha da janela, tanto em relação às estatísticas descritivas obtidas para a amostra, quanto à performance do exercício em quase-tempo real. À semelhança de outros filtros, os ciclos da SSA apresentam média próxima de zero e forte autocorrelação. Ademais, possuem forte correlação com o filtro Christiano-Fitzgerald. Quando contrastada à cronologia dos ciclos do CODACE, a SSA mostra baixo percentual de sinais perdidos e percentual de alarmes falsos compatível com outros filtros. Por fim, utilizando como critérios a correlação, razão ruído-sinal e a concordância entre as séries final e em tempo real e, levando-se em consideração os benefícios e limitações de cada um dos métodos, discutidos na seção 2, é possível argumentar que para alguns casos de janelas, a SSA apresenta resultados superiores a alguns dos principais métodos de filtragem da literatura.

Referências

- ALEXANDROV, T.; BIANCONCINI, S.; DAGUM, E. B.; MAAS, P.; MCELROY, T. S.. **A review of some modern approaches to the problem of trend extraction**, *Econometric Reviews*, 2012. Disponível em <<https://www.tandfonline.com/doi/abs/10.1080/07474938.2011.608032>>. Acesso em 12/12/2018.
- BAXTER, M. KING, R. G.. **Measuring business cycles**: approximate band-pass filters for economic time series, *Review of economics and statistics*, 1999. Disponível em <<https://www.mitpressjournals.org/doi/abs/10.1162/003465399558454>>. Acesso em 12/12/2018.
- BURNSIDE, C. . **Detrending and business cycle facts**: A comment, *Journal of*

Monetary Economics, 1998. Disponível em

<<https://www.sciencedirect.com/science/article/abs/pii/S0304393298000075>>. Acesso em 12/12/2018.

BURNS, A. F., MITCHELL W. C.. **Measuring business cycles**, NBER Books, 1946.

Disponível em <<https://www.nber.org/books/burn46-1>>. Acesso em 12/12/2018.

CAMPELO Jr, A. ; SIMA-FRIEDMAN, J. ; LIMA, S. ; OZYILDIRIM, A. ; PICCHETTI, P.. **Tracking business cycles in Brazil with composite indexes of coincident and leading economic indicators**, 2013. Disponível em

<https://conferenceboard.net/pdf_free/workingpapers/EPWP1306.pdf > .Acesso em 12/12/2018.

CANOVA, F.. **Detrending and turning points**, European Economic Review, 1994.

Disponível em <<http://apps.eui.eu/Personal/Canova/Articles/deturpoints.pdf>>. Acesso em 12/12/2018.

CANOVA, F..**Detrending and business cycle facts**, Journal of monetary economics, 1998. Disponível em

<<https://www.sciencedirect.com/science/article/abs/pii/S0304393298000063>>. Acesso em 12/12/2018.

CANOVA, F. **Does detrending matter for the determination of the reference cycle and the selection of turning points?**, The Economic Journal 1999. Disponível em <<https://onlinelibrary.wiley.com/doi/abs/10.1111/1468-0297.00395>>. Acesso em 12/12/2018.

de CARVALHO, M.; RODRIGUES, P. C.; RUA, A.. **Tracking the us business cycle with a Singular Spectrum Analysis**, Economics Letters, 2012. Disponível em

<<https://www.sciencedirect.com/science/article/pii/S0165176511003363>>. Acesso em 12/12/2018.

de CARVALHO, RUA A.. **Real-time nowcasting the us output gap: Singular Spectrum Analysis at work**, International Journal of Forecasting 33 (1), 2017. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0169207015001247>>. Acesso em 12/12/2018.

CHAUVET, M. **The Brazilian business and growth cycles**, Revista Brasileira de Economia, 2006. Disponível em <http://www.scielo.br/scielo.php?pid=S0034-71402002000100003script=sci_arttext > .Acesso em 12/12/2018.

CHRISTIANO, L. J. ; FITZGERALD, T. J.. **The band pass filter**, international economic review, 2003. Disponível em <<https://onlinelibrary.wiley.com/doi/full/10.1111/1468-2354.t01-1-00076>>. Acesso em 12/12/2018.

CUSINATO, R. T. ; MINELLA, A. ; PORTO-JÚNIOR, S. S. P. **Output gap in Brazil: a real-time data analysis**, Empirical Economics, 2013. Disponível em <<https://link.springer.com/article/10.1007/s00181-012-0583-3>>. Acesso em 12/12/2018.

DIAS, M. H. A. ; DIAS, J. **Measuring the cyclical component of a time series: a new proposed methodology**, Brazilian Review of Econometrics, 2010. Disponível em <<http://bibliotecadigital.fgv.br/ojs/index.php/bre/article/view/3503>>. Acesso em 12/12/2018.

DUMAS, P.; GHIL, M.; GROTH, A. , HALLEGATE, S.. **Dynamic coupling of the climate and macroeconomic systems**, Math. Social Sci, 2011. Disponível em <https://www.atmos.ucla.edu/tcd/PREPRINTS/Dyn_couple - EHESFinal.pdf > . Acesso em 12/12/2018.

GOLYANDINA, N. ; NEKRUTKIN, V. ; ZHIGLJAVSKY, A. A.. **Analysis of time series structure: SSA and related techniques**, Chapman and Hall, 2001. Disponível em <<https://www.taylorfrancis.com/books/9781420035841>>. Acesso em 12/12/2018.

GOLYANDINA, N. . **On the choice of parameters in singular spectrum analysis and related subspace-based methods**, Statistics and its Interface 2010. Disponível em <<https://arxiv.org/abs/1005.4374>>. Acesso em 12/12/2018.

GOLYANDINA, N. ; KOROBEYNIKOV, A.. **Basic singular spectrum analysis and forecasting with R**, Computational Statistics Data Analysis, 2014. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0167947313001394>>. Acesso em 12/12/2018.

GONZALEZ, R. B.; LIMA, J. ; MARINHO, L. **Business and financial cycles: an estimation of cycles' length focusing on macroprudential policy**, Tech. rep. 2015. Disponível em <<https://www.bcb.gov.br/pec/wps/ingl/wps385.pdf>>. Acesso em 12/12/2018.

GROTH, A. ; GHIL, M.; HALLEGATTE, S.; DUMAS, P.. **The role of oscillatory modes in us business cycles**, OECD Journal. Journal of Business Cycle Measurement and Analysis, 2015. Disponível em <<https://www.oecd-ilibrary.org/economics/the-role-of-oscillatory-modes-in-us-business->

cycles;bcma – 2015 – 5jrs0lv715wl > .Acessoem12/12/2018.

HAMILTON, J. D. **Why you should never use the Hodrick-Prescott filter**, Review of Economics and Statistics, 2017. Disponível em https://www.mitpressjournals.org/doi/abs/10.1162/REST_a00706 > .Acessoem12/12/2018.

HARDING, D. ; PAGAN, A.. **Dissecting the cycle: a methodological investigation**, Journal of Monetary economics, 2002. Disponível em <https://www.sciencedirect.com/science/article/abs/pii/S0304393201001088>>. Acesso em 12/12/2018.

HARVEY, A. **Forecasting, structural time series models and the Kalman filter**, Cambridge university press, 1989.

HASSANI, H..**Singular spectrum analysis: methodology and comparison**, Journal of Data Science 2007.Disponível em <http://www.jds-online.com/files/JDS-396.pdf>>. Acesso em 12/12/2018.

HASSANI, H.; THOMAKOS, D.. **A review on singular spectrum analysis for economic and financial time series**, Statistics and its Interface, 2010.Disponível em <https://www.intlpress.com/site/pub/pages/journals/items/sii/content/vols/0003/0003/a011/>>. Acesso em 12/12/2018.

HIROSE, Y. ; NAGANUMA, S.. **Structural estimation of the output gap: A Bayesian DSGE approach**, Economic Inquiry, 2010. Disponível em <https://onlinelibrary.wiley.com/doi/full/10.1111/j.1465-7295.2009.00228.x>>. Acesso em 12/12/2018.

HODRICK, R. J. ; PRESCOTT, E. C..**Postwar US business cycles: an empirical investigation**, Journal of Money, Credit, and Banking, 1997. Disponível em <https://www.jstor.org/stable/2953682>>. Acesso em 12/12/2018.

KING, R. G.; REBELO, S.. **Low frequency filtering and real business cycles**, Journal of Economic dynamics and Control, 1993. Disponível em <https://www.sciencedirect.com/science/article/pii/S0165188906800102>>. Acesso em 12/12/2018.

KYDLAND, F. E. ; PRESCOTT, E. C. . **Time to build and aggregate fluctuations**, Econometrica: Journal of the Econometric Society, 1982. Disponível em https://www.jstor.org/stable/1913386?seq=1page_scan_tabc_contents >

.Acessoem12/12/2018.

LONG, J. B.; PLOSSER, C. I. **Real business cycles**, Journal of political Economy 1983. Disponível em <<https://www.journals.uchicago.edu/doi/abs/10.1086/261128>>. Acesso em 12/12/2018.

LOPES, L. S. ; CHAUVET, M. ; de LIMA, J. E. **Trend-cycle decomposition of the Brazilian GDP: New facts for the period between 1947 and 2012**, 46º Encontro Nacional de Economia, 2017. Disponível em <https://www.anpec.org.br/encontro/2017/submissao/files_I/i4-bae187fd7b1462ea0657b6caef0922a4.pdf> .Acessoem12/12/2018.

LUCAS Jr., R. E. **Understanding business cycles**, in: Carnegie-Rochester conference series on public policy, Vol. 5, Elsevier, 1977. Disponível em <<https://www.sciencedirect.com/science/article/pii/0167223177900021>>. Acesso em 12/12/2018.

MINTZ, I. **Dating postwar business cycles: Methods and their application to Western Germany, 1950–67**, 1969. Disponível em <<https://www.nber.org/books/mint70-1>>. Acesso em 12/12/2018.

MISE, E. ; KIM, T.-H.; NEWBOLD, P. **On suboptimality of the Hodrick-Prescott filter at time series endpoints**, Journal of Macroeconomics, 2005. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0164070404000710>>. Acesso em 12/12/2018.

MOORE, G. H. **Growth cycles: A new-old concept**, in: Business Cycles, Inflation, and Forecasting, 2nd edition, Ballinger, 1983. Disponível em <<https://www.nber.org/books/moor83-1>>. Acesso em 12/12/2018.

NELSON, C. R. ; PLOSSER, C. R. **Trends and random walks in macroeconomic time series: some evidence and implications**, Journal of monetary economics, 1982. Disponível em <<https://www.sciencedirect.com/science/article/abs/pii/0304393282900125>>. Acesso em 12/12/2018.

OLIVEIRA,, L. P. C.; PORTUGAL, M. S. **Structural estimation of output gap: The case of Brazil**. XXVIII Jornadas Anuales de Economía, Montevideo, 2013. Disponível em <https://www.bcu.gub.uy/Comunicaciones/Paginas/Jornadas_dEEconomiaTrabaj2013.aspx>

.Acessoem12/12/2018.

ORPHANIDES, A. ; van NORDEN, S. v.. **The unreliability of output-gap estimates in real time**, Review of economics and statistics, 2002. Disponível em <<https://www.mitpressjournals.org/doi/abs/10.1162/003465302760556422>>. Acesso em 12/12/2018.

PAGAN, A.. **Towards an understanding of some business cycle characteristics**, Australian Economic Review, 1997. Disponível em <<https://onlinelibrary.wiley.com/doi/abs/10.1111/1467-8462.00001>>. Acesso em 12/12/2018.

PERRON, P..**The great crash, the oil price shock, and the unit root hypothesis**, Econometrica: Journal of the Econometric Society, 1989. Disponível em <https://www.jstor.org/stable/1913712?seq=1page_scan_tables_contents >. Acesso em 12/12/2018.

SELLA, L.; MARCHIONATTI, R.. **On the cyclical variability of economic growth in Italy, 1881-1913: a critical note**, Cliometrica, 2012. Disponível em <<https://link.springer.com/article/10.1007/s11698-011-0075-2>>. Acesso em 12/12/2018.

TELES, V.; SPRINGER, P.; GOMES, M. ; PAES, N; CAVALCANTI, A.. **Ciclos econômicos e métodos de filtragem: “fatos estilizados” para o caso brasileiro**, Revista EconomiA, 2005. Disponível em <<http://www.anpec.org.br/novosite/br/volume-6>>. Acesso em 12/12/2018.

ZARNOWITZ, V. **Business Cycles: Theory, History, Indicators, and Forecasting**, University of Chicago Press, 1992. Disponível em <<https://www.nber.org/books/zarn92-1>>. Acesso em 12/12/2018.

ZARNOWITZ, V.; OZYILDIRIM, A..**Time series decomposition and measurement of business cycles**, trends and growth cycles, Journal of Monetary Economics, 2006. Disponível em <<https://www.sciencedirect.com/science/article/abs/pii/S0304393206000596>>. Acesso em 12/12/2018.

ZIVOT, E. ; ANDREWS, D. W. K.. **Further evidence on the great crash, the oil-price shock, and the unit-root hypothesis**, Journal of Business Economic Statistics, 1992. Disponível em <<https://amstat.tandfonline.com/doi/abs/10.1198/073500102753410372>>. Acesso em 12/12/2018.

4 Recessões e desacelerações no Brasil: o que os indicadores antecedentes da OCDE indicam?

Resumo. O objetivo do trabalho é estudar o poder preditivo dos indicadores antecedentes da OCDE para o Brasil. É utilizada uma abordagem probabilística para a previsão de desacelerações e recessões dentro e fora da amostra. Os indicadores são avaliados com modelos logit univariados e uma combinação dos diferentes modelos é selecionada através do método *Bayesian Model Averaging*. Esta combinação é comparada com o indicador composto antecedente da OCDE em termos de sua capacidade preditiva. Os resultados mostram que, nos horizontes relevantes, a performance da combinação bayesiana dos modelos supera a do indicador composto da OCDE, tanto nas desacelerações quanto nas recessões. Por fim, os indicadores antecedentes selecionados pela OCDE mostram-se melhores previsores de recessões do que de desacelerações com os métodos adotados.

Palavras-chave: Indicadores Antecedentes. Modelos Logit. Bayesian Model Averaging. Ciclos de negócios.

JEL Classifications. E32. C53.

4.1 Introdução

Sistemas de indicadores antecedentes possuem uma longa tradição na análise e previsão dos ciclos de negócios. Desde os trabalhos iniciais do NBER (MITCHELL; BURNS, 1938), a abordagem atraiu a atenção não apenas de governos, investidores e famílias preocupados com o *timing* de suas decisões de política econômica, investimento e consumo mas também de pesquisadores interessados em identificar, desenvolver, avaliar e aprimorar indicadores capazes de antecipar as mudanças de estado da economia. Estas ferramentas são utilizadas por diversas instituições multilaterais, governamentais e privadas para monitoramento e previsão dos movimentos cíclicos da economia. Um dos mais conhecidos sistemas de indicadores antecedentes é o da Organização para a Cooperação e Desenvolvimento Econômico (OCDE). Inicialmente criado com o propósito de antecipar os *turning points* na economia de um conjunto de países membros, partir de 2006 passou a incorporar também informações de seis países não-membros, dentre os quais, o Brasil. A previsão é realizada de forma qualitativa através da localização de *turning points* no chamado *Composite Leading Indicator*, doravante CLI. Uma vez identificado um pico no CLI, espera-se que, poucos meses à frente, a economia transite de um estado de rápido para baixo crescimento, podendo inclusive atingir taxas de crescimento negativas. Esta previsão é confirmada somente através da identificação de um pico na série de referência, escolhida para representar os movimentos da atividade econômica. Análise análoga pode ser realizada quando da localização de um vale no CLI.

Duas características marcam o indicador da OCDE. Primeiramente, trata-se, como o próprio nome diz, de um indicador cíclico *composto*, isto é, uma média ponderada de séries de tempo selecionadas com o propósito de antecipar os *turning points* de uma economia. Estas medidas sintéticas são geralmente preferíveis à análise de séries individuais por gerarem menos sinais falsos, menos sinais perdidos e tempo de antecipação mais estável. Contudo, atenção aos componentes individuais também é necessária. Em última instância, a seleção dos componentes se dá com base em análises ao redor dos *turning points* das séries, de forma que informações contidas nas áreas complementares são ignoradas ou pelo menos minoradas. Estas séries geralmente apresentam *clusters* de picos e vales que antecedem aqueles do ciclo da série de referência. Entretanto, é importante lembrar que séries de tempo macroeconômicas, como o CLI e seus componentes, estão sujeitas a quebras estruturais, refletindo diversos tipos de choques, permanentes ou transitórios. Na economia brasileira há uma gama de exemplos, como o incremento da participação relativa do setor de serviços no PIB nas últimas décadas; os planos de estabilização monetária das décadas de 1980 e 1990 que impuseram, dentre outras medidas, congelamento de preços e sequestro de poupança, causando grande instabilidade no fluxo de produção; os choques financeiros internacionais da década de 1990, como os do México (1994), Ásia (1997) e Rússia (1998) que dificultaram a conciliação entre crescimento e estabilidade de preços

pautada na âncora cambial nos primeiros anos do Plano Real e, mais recentemente, a crise financeira de 2008 que desencadeou a maior recessão mundial desde a década de 1930, dentre muitos outros. Ademais, os fatores causais dominantes em cada um dos eventos que determinam a mudança de fases do ciclo econômico frequentemente muda no tempo. Cada desaceleração e cada recessão possui idiosincrasias e não são, portanto, iguais às anteriores. Com isso, alguns indicadores antecedentes podem performar melhor em determinadas circunstâncias do que em outras. Ao mesmo tempo, algumas séries podem perder seu poder preditivo enquanto outras estatísticas surgem, podendo revelar-se úteis com o decorrer dos anos. Assim, os indicadores compostos estão permanentemente sujeitos a mudanças.

Outra questão relacionada à composição do CLI se refere ao peso atribuído a cada um de seus componentes. O sistema da OCDE distribui igualmente os pesos entre os indicadores selecionados baseado em três premissas: transparência, fácil manutenção e replicação e redução de fontes de revisão nos dados. Na prática, essa escolha dos pesos reflete a importância equânime dada a cada indicador na antecipação dos ciclos. Contudo, diferentes escolhas de ponderação implicam uma multiplicidade de composições e, em alguns casos, podem afetar inclusive a sinalização de *turning points*. Diversos estudos já discutiram a questão dos pesos, frequentemente encontrando evidências de sub-optimalidade em alguns dos principais indicadores compostos antecedentes (ver Auerbach (1982), Diebold e Rudebusch (1989) e Nazmi (1993) para o CLI do BEA nos Estados Unidos e Emerson e Hendry (1996) para o indicador do CSO do Reino Unido)¹ De fato, Gyomai et al. (2017) admitem a possibilidade de que sistemas de pesos alternativos poderiam levar a melhores resultados preditivos. Ademais, Camba-Mendez et. al (2004) sugerem ganhos preditivos ao considerar um conjunto mais amplo de variáveis do que as selecionadas pela OCDE em uma amostra de países desenvolvidos.

Uma segunda característica importante do CLI da OCDE se refere ao conceito de ciclo envolvido na previsão. Duas definições são comumente encontradas na literatura. A primeira, conhecida como ciclo clássico, remete à definição de Burns e Mitchell (1946), na qual a alternância recorrente entre períodos de crescimento e de quedas absolutas no *nível* de atividade econômica caracterizam, respectivamente, as fases de expansão e recessão do ciclo de negócios. Esta definição do ciclos de negócios é adotada por instituições como o NBER e o CODACE/IBRE-FGV, por exemplo, como referência para suas cronologias. No caso da economia brasileira, a cronologia do CODACE tem se mostrado amplamente aceita em trabalhos recentes como referência dos períodos de expansão e recessão nacionais (CRAVO, 2011; ISSLER et al., 2009; MAGALHÃES; TOSCANO, 2015; GRUDTNER; ARAGON, 2017, dentre outros.). A OCDE, por outro lado, adota um conceito alternativo, conhecido como ciclo de crescimento ou ciclo de desvios (MINTZ, 1969). Diferentemente

¹BEA é o acrônimo para o *Bureau of Economic Analysis* do Departamento de Comércio do governo americano, enquanto CSO é o acrônimo do *Central Statistical Office* do Reino Unido.

do ciclo clássico que enfatiza variações no nível para identificar os *turning points*, o ciclo de crescimento foca nas flutuações da atividade econômica em torno de sua tendência de longo prazo. O período compreendido entre a ocorrência de um pico e um vale no ciclo de crescimento é caracterizado como desaceleração, enquanto os períodos entre vales e picos são de aceleração econômica. Na literatura de flutuações macroeconômicas, esta cisão dos componentes é geralmente interpretada como a separação entre as fontes de flutuação de curto prazo - o hiato do produto - e o elemento estrutural, de longo prazo, associado ao produto potencial da economia.²

Embora distintos, os conceitos se relacionam. As contrações nos ciclos de crescimento incluem não apenas reduções nas taxas de crescimento, como também declínios absolutos no nível de atividade econômica, caracterizados no ciclo clássico como recessões e nos ciclos de crescimento por taxas de crescimento negativas. Quando a tendência de longo prazo torna-se horizontal, os dois ciclos se sobrepõem um ao outro. Ademais, os picos nos ciclos de crescimento comumente antecipam ou pelo menos coincidem com os dos ciclos clássicos. Os vales, por sua vez, ocorrem com certo atraso. Ademais, conforme discutido em Boehm e Liew (1994), Zarnowitz (1992), Zarnowitz e Ozyildirim (2006), dentre outros, os ciclos de crescimento tendem a apresentar maior frequência de *turning points*, menor duração e maior simetria de fases.

A utilidade de indicadores antecedentes compostos em realizar previsões da atividade econômica, em especial dos *turning points*, é frequentemente submetida a escrutínios na literatura. O maior exemplo é o *Composite Index of Leading Indicators* inicialmente desenvolvido pelo *National Bureau of Economic Research* e pelo *Bureau of Economic Analysis* do Departamento de Comércio do governo americano e, a partir de 1995, sob encargo do *The Conference Board*. O índice e seus componentes - os quais sofreram significativas revisões ao longo do tempo - foram amplamente avaliados em relação a sua performance de previsão sobre o valor de variáveis cíclicas contínuas, como o PIB, produção industrial ou outros indicadores coincidentes (AUERBACH, 1982; HAMILTON; PEREZ-QUIROS, 1996). Diversos estudos também avaliaram sua capacidade de prever *turning points* - principal tarefa da abordagem dos indicadores (DIEBOLD; RUDEBUSCH, 1989; NAZMI, 1993; CAMACHO; PEREZ-QUIROS, 2002).

Por sua vez, o CLI da OCDE recebeu menor atenção da literatura. Embora também houvesse interesse em avaliar sua performance preditiva frente a medidas contínuas de atividade econômica, como a produção industrial (Weale (1996), Camba-Mendez et al. (2004)), esforços recentes se concentraram em investigar a sensibilidade dos indicadores em relação ao método de extração da tendência (NILSSON; GYOMAI, 2011; GYOMAI; WILDI, 2012). Estes estudos focaram inteiramente em amostras de países desenvolvidos.

²É importante notar que, nesta literatura, a maior parte dos estudos foca nas características de variância e correlação entre componentes cíclicos de diferentes séries de tempo macroeconômicas ou em sua utilização como insumo para estimação e previsão de variáveis contínuas como inflação e balanço estrutural. Atenção aos pontos de virada é notada em raras exceções.

Economias emergentes, dentre as quais o Brasil, são abordadas em raras exceções, devido à maior escassez e qualidade inferior de dados.³ Considerando a utilidade da abordagem dos indicadores na previsão de *turning points*, é desejável investigar mais a fundo as características preditivas do CLI e seus componentes, especialmente em uma economia historicamente instável como a do Brasil. Ademais, tendo em vista que a cronologia do CODACE está cumprindo no Brasil o mesmo papel que a cronologia do NBER nos Estados Unidos é interessante questionar que informações o CLI pode fornecer, não apenas sobre as desacelerações identificadas pela OCDE, mas também sobre as recessões apontadas pelo CODACE. Estes são importantes *gaps* a serem preenchidos na literatura nacional de ciclos.

Diante das questões expostas, o presente trabalho propõe avaliar a performance dos indicadores antecedentes da OCDE na previsão de desacelerações e recessões clássicas na economia brasileira. Em particular, busca-se responder a duas perguntas: 1) os indicadores são capazes de prever tanto desacelerações quanto recessões clássicas? e 2) o CLI é a melhor forma de extrair informações cíclicas destes indicadores? Para respondê-las, uma série de exercícios econométricos de previsão com variáveis latentes são conduzidos dentro e fora da amostra. Os horizontes de interesse variam de zero a doze meses. Primeiramente, cada um dos componentes do CLI, além do próprio indicador composto, é avaliado através de modelos logit univariados, com intuito de identificar o *timing* e a força dos sinais probabilísticos emitidos em cada uma das fases dos ciclos. Exercícios similares podem ser encontrados com modelos probit em Estrella e Mishkin (1998) e Shoesmith (2003) para avaliar a capacidade preditiva da curva de juros sobre as recessões nacionais e subnacionais, respectivamente, nos Estados Unidos e em Morais e Chauvet (2011) como *benchmark* para avaliação de modelos mais complexos de indicadores antecedentes da indústria de bens de capital brasileira. Ganhos de poder preditivo poderiam ser alcançados movendo-se de uma estrutura univariada para modelos multivariados com diferentes combinações de componentes. O problema então se resumiria a encontrar a melhor combinação de variáveis preditivas, isto é, aquela que minimiza alguma função perda. Contudo, encontrar o melhor modelo e descartar a informação de modelos inferiores pode não ser ótimo.

É amplamente reconhecido que o cômputo da média (*averaging*) é um método útil na presença de incerteza sobre a escolha do melhor modelo, com frequência levando a melhores resultados preditivos do que a escolha de um modelo individual (ver Timmermann (2006)). Neste trabalho, o tipo de incerteza mencionado é abordado com o uso da *Bayesian Model Averaging* (BMA) aplicada a modelos de resposta binária. Esta estratégia foi recentemente utilizada por Berge (2015) junto a outros métodos para analisar um grupo

³O único estudo encontrado foi Nilsson e Brunet (2006). É interessante notar que nele os indicadores antecedentes selecionados para o Brasil são distintos dos divulgados atualmente para o país, como em OECD (2018). A primeira lista conta com oito variáveis, enquanto na atual constam apenas seis.

de indicadores antecedentes para os Estados Unidos. A BMA permite uma varredura abrangente de combinações possíveis de modelos formados a partir de um conjunto de K variáveis, realizando uma média ponderada entre os mesmos. O peso da previsão de cada modelo é dado pela probabilidade *a posteriori* daquele modelo ser o verdadeiro.

O trabalho está dividido em cinco seções, incluindo esta introdução. A segunda seção traz um resumo da literatura de previsão de *turning points* no Brasil, enquanto a terceira seção faz uma breve apresentação dos modelos empregados no trabalho, bem como das estatísticas utilizadas para avaliação da performance preditiva. Na seção seguinte os dados, tanto das variáveis de resposta binária quanto das variáveis preditivas são apresentados e discutidos. A quarta seção expõe os resultados, dentro e fora da amostra, para os ciclos de crescimento e para os ciclos de negócios, respectivamente. Por fim, a última seção traz as conclusões do artigo.

4.2 Revisão da literatura de previsão de *turning points* no Brasil

É possível encontrar uma série de trabalhos sobre a previsão de *turning points* na economia brasileira. As investigações tem por base, em sua maioria, a alternância recorrente entre períodos de crescimento e de queda em alguma medida de atividade econômica, em maior consonância com a definição de Burns e Mitchell (1946) do ciclo clássico, com algumas exceções. Ressalta-se que trabalhos anteriores a 2009 não contavam com a cronologia do CODACE como referência, de modo que boa parte dos esforços na literatura se concentravam também em testar abordagens paramétricas e não paramétricas para identificação dos *turning points*. As abordagens podem ser divididas em dois grupos. No primeira, uma medida de atividade econômica, como o PIB, por exemplo, é utilizada para previsão em modelos autoregressivos lineares e não lineares. Chauvet (2002), por exemplo, utiliza modelos de mudança markoviana entre dois regimes, seguindo Hamilton (1989), para prever dentro e fora da amostra os ciclos de negócios usando dados trimestrais e anuais do PIB. Com a frequência mais alta, as médias dos regimes estimados permitem caracterizar ciclos de negócios clássicos, com um regime de recessão (média de crescimento negativa) e outro de expansão (média de crescimento positiva). Com dados anuais, são identificadas fases de alto e baixo crescimento, onde os dois regimes apresentam médias estimadas de crescimento positivas. Adicionalmente, o trabalho mostra ganhos de poder preditivo ao considerar não linearidades na taxa de crescimento do PIB frente a modelos lineares mais simples. Extensões destes modelos também indicam evidências em favor da não-linearidade no processo gerador de dados do PIB brasileiro. Céspedes et al. (2006) comparam a performance de modelos de mudança markoviana considerando processos de raiz unitária (modelos do tipo de Hamilton (1989)) e estacionários em torno de uma tendência determinística (modelos baseados em Lam (1990)). Intervenções para tratar o

período de perturbações durante os Planos Collor I e Collor II são também exploradas na forma de *dummies* ou *outliers* e quando consideradas aumentam a habilidade preditiva dos modelos fora da amostra. Resultados similares são encontrados com exercícios em tempo real (CHAUVET et al., 2015). Já Pereira e Vieira (2013) consideram uma estrutura GARCH para a variância dos modelos de mudança markoviana de regime e encontram algumas diferenças importantes em relação à cronologia proposta por Chauvet (2002), sobretudo antes da década de 1930.

Um segundo grupo de estudos lança mão da abordagem dos indicadores coincidentes e antecedentes para previsão dos *turning points* da economia brasileira. Iniciado com os trabalhos de Contador (CONTADOR, 1977), o primeiro a desenvolver índices de atividade econômica para o Brasil baseados na abordagem do NBER, estudos utilizando indicadores cíclicos tornaram-se mais numerosos a partir da década de 2000. Usando três distintas metodologias, Duarte et al. (2004) constroem índices coincidentes de atividade, a partir dos quais determinam os *turning points* da economia com o uso do algoritmo Bry-Boschan. Variáveis antecedentes são identificadas com o uso de testes de causalidade de Granger. Já Chauvet e Silva (2004) determinam os *turning points* da economia brasileira com o uso de modelos de fatores dinâmicos com mudança markoviana de regime enquanto classificam indicadores antecedentes através de uma série de critérios econômicos e estatísticos, dentre os quais o uso de modelos probit. Hollauer e Issler (2006) identificam indicadores antecedentes para a indústria brasileira. A dinâmica cíclica é captada através de um indicador composto coincidente mensal, bem como pelo PIB industrial trimestral. A identificação dos antecedentes é realizada através de correlação cruzada e testes de causalidade de Granger. A performance dos indicadores antecedentes é testada em relação a variáveis contínuas e binárias para horizontes de um, três e seis meses. No caso contínuo, são realizadas previsões do indicador coincidente com uso de modelos lineares VAR e VECM, enquanto o poder de previsão dos indicadores sobre as fases de recessão e expansão na indústria é estudado por modelos probit. Campelo et al. (2013) desenvolvem indicadores compostos coincidentes e antecedentes da economia brasileira seguindo a abordagem do *The Conference Board* (TCB). O índice coincidente é construído agregando séries encontradas nas bases de dados nacionais análogas aos indicadores coincidentes usados pelo TCB nos Estados Unidos. São tradicionais variáveis que representam um conceito amplo de atividade econômica, como produção, emprego, vendas e renda. Testes para a seleção dos indicadores antecedentes consideram relações teóricas de precedência ou causalidade, bem como a análise dos *turning points* dos candidatos pelo algoritmo Bry-Boschan, análise de correlação, *Quadratic Probability Score*, testes de causalidade de Granger e modelos de mudança markoviana de regime seguindo a metodologia proposta em Levanon (2010). Após a construção dos indicadores compostos, a performance é avaliada através da análise dos *turning points* tanto em relação ao ciclo clássico quanto ao ciclo de crescimento - onde a tendência é removida com um filtro HP.

Mais recentemente, Oliveira (2016) examina o poder preditivo, fora da amostra, de uma gama de séries de tempo dos setores real e financeiro através de modelos binários de recessão entre um e oito trimestres a frente. Ao contrário dos demais estudos que consideram a função *link* Normal nos modelos probabilísticos, resultando em modelos probit, o estudo utiliza uma função de valor extremo.⁴

4.3 Metodologia

A seguir, apresenta-se a metodologia.

4.3.1 Modelo Logit simples

Uma forma simples de quantificar o poder preditivo dos indicadores antecedentes sobre as diferentes fases do ciclo econômico é através de modelos lineares generalizados. Estes modelos são comumente encontrados na literatura de previsão de recessões (ESTRELLA; MISHKIN, 1998; SHOESMITH, 2003; MORAIS; CHAUVET, 2011; OLIVEIRA, 2016; dentre outros.). Assume-se que a variável de resposta (y) é binária, onde o período t está associado a distintos regimes: recessão ou desaceleração ($y = 1$) e expansão ou aceleração ($y = 0$). Formalmente, assume-se uma relação linear teórica entre uma variável latente e uma ou mais variáveis explanatórias, da seguinte forma:

$$y_{t+j}^* = \beta' x_t + \epsilon_t \quad (4.1)$$

Na equação 4.1, y^* é a variável latente que representa o estado da economia, ϵ_t é um termo de erro com distribuição logística, j é o horizonte de previsão, β é o vetor de coeficientes associado a cada uma das variáveis explicativas, incluindo a constante. A variável latente y^* se conecta à variável observável – o indicador binário de desaceleração (recessão) – através da seguinte regra:

$$y = \begin{cases} 1, & \text{se } y^* < 0. \\ 0, & \text{caso contrário.} \end{cases}$$

⁴O modelo, em síntese, pode ser escrito como $P(Y_t = 1 | X_t) = f(X_t)$, em que $f(X_t) = \frac{e^{-X_t}}{1 + e^{-X_t}}$ é a função de valor extremo.

O objetivo final é obter as probabilidades condicionais de recessão j passos à frente, $P(y_{t+j} = 1|x)$. Para tanto, a seguinte equação deve ser estimada:

$$P(y_{t+j} = 1|x) = \Lambda(\beta' x_t) \quad (4.2)$$

onde $\Lambda(z) \equiv \exp(z)/[1 + \exp(z)]$ é a função de distribuição logística. Os parâmetros são estimados por máxima verossimilhança.

De modo a testar a capacidade dos indicadores antecedentes em antecipar tanto recessões clássicas quanto desacelerações utilizamos dois conjuntos de variáveis resposta nos modelos logit. O primeiro refere-se aos períodos de desaceleração nos ciclos de crescimento brasileiro identificados pela OCDE, onde $y_1 = 1$ se a economia está desacelerando e $y_1 = 0$ em caso contrário. Cabe lembrar que os indicadores antecedentes da OCDE foram selecionados com vistas a antecipar estes eventos. O segundo conjunto representa a cronologia das recessões na economia brasileira divulgada pelo CODACE, onde $y_2 = 1$ se a economia está em recessão e $y_2 = 0$ se está em expansão.

4.3.2 Bayesian Model Averaging em modelos lineares generalizados

Os modelos logit simples (univariados) apresentados anteriormente permitem estudar o poder preditivo de diferentes indicadores antecedentes individualmente no contexto de previsões probabilísticas. Contudo, seria interessante considerar combinações destes indicadores na busca por melhorias no desempenho das previsões. O problema consiste então em selecionar as combinações relevantes entre os diferentes preditores possíveis. Tal busca se torna mais custosa quanto maior o número de preditores. Por exemplo, para um conjunto de p preditores, existem 2^p diferentes modelos logit possíveis. Esta forma de incerteza que permeia os modelos aqui considerados pode ser contornada com o uso de Bayesian Model Averaging (BMA). Hoeting et al. (1999) e Clyde (2004) fornecem uma boa revisão das motivações para seu uso.

A idéia básica da BMA pode ser expressa da seguinte forma. Suponha que se deseja prever o comportamento de uma variável estocástica y a partir de um conjunto de preditores X . O problema consiste em selecionar as variáveis relevantes e, conseqüentemente, os modelos estatísticos relevantes. Neste problema, existe um conjunto M_1, M_2, \dots, M_K de modelos, onde $K = 2^p$. Aplicando a lei da probabilidade total, a distribuição *a posteriori* de y pode ser expressa como o produto da distribuição *a posteriori* de y dado o modelo M_k e a probabilidade *a posteriori* de que M_k é o modelo correto, dado que algum dos modelos

considerados é o correto, para cada um dos k modelos.

$$p(y|X) = \sum_{k=1}^K p(y|X, M_k)p(M_k|X) \quad (4.3)$$

Seguindo o mesmo princípio, a média pode ser obtida como:

$$E[y|X] = \sum y^{(k)}p(M_k|X) \quad (4.4)$$

A probabilidade *a posteriori* de M_k é dada por:

$$p(M_k|X) = \frac{p(X|M_k)p(M_k)}{\sum_{l=1}^K p(X|M_l)p(M_l)} \quad (4.5)$$

onde $p(X|M_k)$ é a verossimilhança integrada do modelo M_k , obtida através da integração sobre os parâmetros desconhecidos, da seguinte forma:

$$p(X|M_k) = \int p(X|\psi_k, M_k)p(\psi_k|M_k)d\psi_k \quad (4.6)$$

onde ψ_k é o parâmetro do modelo M_k e $p(X|\psi_k, M_k)$ é a probabilidade (likelihood) de ψ_k sob o modelo M_k .

Considerando cada ponto da amostra, a previsão da BMA pode ser escrita como a soma ponderada pelas probabilidades das previsões de cada um dos modelos:

$$\hat{y}_t^{BMA} = \sum_{k=1}^K \hat{y}_{kt}p(M_k|X_{t-h-1}) \quad (4.7)$$

Existem duas principais dificuldades em se realizar a BMA. A primeira é que, analiticamente, as integrais requeridas para o cômputo da distribuição marginal dos dados podem ser difíceis de calcular analiticamente. Note, por exemplo, que a integral em 4.6 é calculada sobre todos os parâmetros dos modelos. Desta forma, métodos aproximados de integração como o método de Laplace, métodos de Monte Carlo ou mesmo aproximações

por critérios de informação podem ser necessários. Ademais, ressalta-se que no caso de modelos lineares generalizados, atenção também deve ser dada à escolha da distribuição *a priori*. Enquanto em modelos lineares a família Normal-Gamma de distribuições *a priori*, em especial a *g-prior* de Zellner (ZELLNER, 1986) ou misturas de *g-priors*, são largamente utilizadas, devido a sua simplicidade e outras características, não há consenso sobre uma *g-prior* objetiva para modelos GLM. Li e Clyde (2018) unificam diversas destas misturas de *g-priors* propostas na literatura para esta classe de modelos.

Outra dificuldade deriva do fato de que, conforme discutido anteriormente, o número de modelos cresce exponencialmente, conforme aumenta o número de variáveis consideradas (2^p). Assim, mesmo que as distribuições marginais possam ser calculadas, o número de modelos a serem visitados pode ser tornar computacionalmente impraticável. Para reduzir a dimensão do problema, visitando apenas subconjuntos dos modelos, diversos algoritmos foram propostos, como *Markov Chain Monte Carlo* e *Bayesian Adaptive Sampling* (BAS) (CLYDE et al., 2011). Uma das principais diferenças entre ambos refere-se à amostragem: enquanto o primeiro permite a reamostragem dos modelos, o segundo a realiza sem reposição, garantindo que em espaços de baixa dimensão todos os modelos sejam enumerados.

Há bibliotecas disponíveis em diversos programas para implementação da BMA. Comparações entre elas podem ser encontradas em Amini e Parmeter (2011) e Blazejowski e Kwiatkowski (2013). Neste trabalho o pacote BAS do *software R* (CLYDE, 2018)) é utilizado, o qual implementa a BMA baseado em misturas de *g-priors* de Li e Clyde (2018) usando aproximações pelo método de Laplace.

4.3.3 Estatísticas de performance

Existem diversas formas de se avaliar a capacidade preditiva dos modelos probabilísticos, tanto dentro quanto fora da amostra. Como ocorre frequentemente na análise empírica, não há um critério único qualitativamente superior aos demais. Assim, para avaliação da performance dos modelos, três estatísticas são consideradas.

O *Quadratic Probability Score* (QPS) (BRIER, 1950) avalia a correspondência entre a ocorrência do evento e a previsão probabilística do mesmo, sendo análogo a uma função de perda quadrática em aplicações onde a variável dependente é limitada. Formalmente, o QPS pode ser expresso como:

$$QPS = \frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2$$

Outra estatística comumente utilizada é a acurácia (ACC), a qual contabiliza a pro-

porção do tempo em que uma previsão probabilística atinge ou supera determinado *cut-off* (c), identificando assim corretamente a existência de uma recessão ou desaceleração. Neste trabalho o valor de $c = 0.5$ é escolhido. Em outras palavras, consideram-se sinais corretamente previstos os casos em que a probabilidade estimada é superior àquela obtida meramente ao acaso, como no lançamento de uma moeda.

$$ACC = \frac{1}{T} \sum_{t=1}^T [I(\hat{y}_t \geq c)y_t + (1 - I(\hat{y}_t \geq c))(1 - y_t)]$$

Por fim, é interessante considerar outros *cut-offs* na análise. Uma forma natural de fazê-lo de forma abrangente é através da curva Característica de Operação do Receptor (ROC). A curva mostra a relação entre a taxa de positivos verdadeiros (eixo y) e a taxa de positivos falsos (eixo x) para cada *cut-off* entre 0 e 1. A área sob a curva (AUC) geralmente varia entre 0.5 e 1, embora casos abaixo de 0,5 sejam possíveis. Uma AUC igual a zero indicaria que o classificador identificaria erroneamente todos os pontos de expansão e recessão. Assim, quanto maior seu valor, melhor a capacidade de classificação do modelo. Berge (2015) a utiliza, juntamente com as duas outras estatísticas aqui apresentadas para avaliar a previsão obtida com métodos de média de modelos, bem como de algoritmos originados na literatura de *machine learning* como *boosting*, enquanto Oliveira (2016) considera a curva ROC, dentre outras estatísticas de performance.

4.4 Investigação empírica

A investigação empírica compreende tanto a descrição dos dados, como a análise dos resultados.

4.4.1 Os dados

A seguir são apresentadas as variáveis resposta e as variáveis preditivas.

4.4.1.1 Variáveis resposta

Conforme discutido, o objetivo do trabalho é explorar a capacidade preditiva dos indicadores antecedentes da OCDE para o Brasil tanto em relação ao ciclo clássico quanto ao ciclo de crescimento. Para tanto as variáveis binárias dos modelos da seção 4.3 representam os períodos de desaceleração/aceleração no ciclo de crescimento e de recessão/expansão no ciclo clássico. A tabela 1 mostra as características de ambos.

A primeira diferença é que a cronologia do CODACE se inicia em 1980, enquanto a OCDE tem registros de desaceleração apenas de 1997 em diante. No período entre

fevereiro de 1996 e dezembro de 2017 - onde ambas as séries coexistem - a OCDE registrou seis fases de desaceleração, sendo a primeira iniciada em outubro de 1997, com duração média de 19,5 meses, enquanto o CODACE datou cinco períodos recessivos, com duração média de 14 meses.⁵ Considerando todos os dados disponíveis do CODACE, contudo, o tempo médio de recessão no Brasil sobe para 17,4 meses.

É interessante notar também algumas particularidades dos ciclos clássicos e dos ciclos de crescimento no Brasil. Por exemplo, as duas recessões clássicas, de jan./2000 a set./2001 e de nov./2002 a jun./2003 foram captadas pela OCDE como um longo período de desaceleração com duração de 31 meses, entre jan./2000 e jul./2003. Ademais, as desacelerações brandas de out./2004 a nov./2005 e de jun./2011 a fev./2012 não geraram *turning points* no ciclo clássico.

Não obstante, nos períodos em que se registram tanto desacelerações quanto recessões, os *turning points* de ambos os ciclos apresentam algum grau de correspondência. Nestes casos, os picos no ciclo de crescimento antecedem, em média, em dois meses os no ciclo de negócios, enquanto os vales no ciclo clássico, ocorrem em média um mês antes do registro do vale no hiato do produto.

⁵Tanto os períodos de desaceleração quanto os períodos de recessão, neste trabalho, foram contabilizados pelo chamado "método do vale", que consiste em iniciar a contagem do período de desaceleração/recessão do mês seguinte ao pico até o vale, inclusive. Assim, o pico é interpretado como o último mês de aceleração/expansão, enquanto o vale representa o último mês do período de desaceleração/recessão. Esta escolha é justificada com fins de padronização, uma vez que o CODACE a utiliza em sua cronologia, enquanto a OCDE fornece apenas as datas de pico e vale, não definindo o método para contagem dos períodos recessivos. Datações pelo "método do ponto médio" e pelo "método do pico" podem ser encontradas em <https://fred.stlouisfed.org/series/BRARECD>. Acesso em 06/06/2018.

Tabela 1: Comparação entre os ciclos de crescimento (OCDE) e os ciclos de negócios (CODACE) no Brasil

Ciclo de crescimento da OCDE			Ciclo de negócios do CODACE			Antecipação (-) ou Defasagem (+) dos ciclos de crescimento em relação ao ciclo clássico (em meses)	
Pico	Vale	Duração	Pico	Vale	Duração	Pico	Vale
-	-	-	out-80	fev-83	28	-	-
-	-	-	fev-87	out-88	20	-	-
-	-	-	jun-89	dez-91	30	-	-
-	-	-	dez-94	set-95	9	-	-
set-97	mai-99	20	out-97	fev-99	16	-1	3
dez-00	-	-	dez-00	set-01	9	0	-
-	jul-03	31	out-02	jun-03	8	-	1
set-04	nov-05	14	-	-	-	-	-
mai-08	mar-09	10	jul-08	jan-09	6	-2	2
mai-11	fev-12	9	-	-	-	-	-
nov-13	ago-16	33	fev-14 *	nov-16 *	31	-5	-3

* Como a cronologia da última recessão foi estabelecida pelo CODACE em bases trimestrais apenas, optou-se por utilizar os meses centrais dos trimestres datados pelo CODACE como meses de pico e vale.

4.4.1.2 Variáveis preditivas

O sistema de indicadores antecedentes consiste na reunião de um grupo de séries de tempo que, em conjunto, possuem capacidade de antecipar os pontos de virada no ciclo de crescimento. Para o Brasil, atualmente o sistema incorpora seis variáveis: Ibovespa, tendência futura da produção da indústria de transformação, demanda (order books) da indústria de transformação, taxa selic, tendência futura da evolução da demanda de serviços e balança comercial com a União Européia. A seleção destas séries é baseada em critérios econômicos, estatísticos e de cunho prático.⁶ Do ponto de vista econômico, as séries devem possuir uma justificativa econômica para a relação de antecipação dos ciclos. A OCDE classifica os potenciais indicadores antecedentes em pelo menos uma das quatro categorias de racionalidade econômica a seguir, buscando balancear a composição entre as diferentes categorias na seleção final. *Estágios Iniciais*, os quais medem os estágios iniciais de produção, como encomendas (*new orders*), ordens de compra e venda (*order books*), que desvendam as necessidades de reposição de estoques, aprovações de projetos de construção, etc. *Resposta rápida*, que reagem rapidamente a mudanças no cenário econômico, tais como média de horas trabalhadas, lucros, estoques, etc. *Sensíveis a expectativas*, i.e. variáveis que medem diretamente ou são sensíveis a expectativas, como preço de ações, indicadores de confiança, etc. E finalmente, *causadores primários* (*prime movers*) - indi-

⁶Detalhes da metodologia podem ser verificados em Gyomai e Guidetti (2012) e Gyomai et al. (2017).

cadores relacionados à política monetária e eventos ocorridos no cenário internacional, os quais podem desencadear reações na economia doméstica, como oferta monetária, termos de troca, etc. Utilizando estes conceitos, é possível classificar os indicadores do Brasil. A tabela 2 ilustra a classificação aqui sugerida:

Tabela 2: Indicadores Antecedentes da OCDE para o Brasil

Indicador	Sigla	Conceito	Classificação	Fonte
Taxa Selic (% a.a.) - meta	STIR	Short term interest rate	Causadores primários	Fundo Monetário Internacional (FMI)
Ind. De Transformação - Produção prevista para os 3 meses seguintes	Prod	Production	Sensíveis a expectativas	FGV - Sondagem da Indústria - Índice de Confiança
Ind. De Transformação - Demanda Total	OB	Order Books	Sensíveis a expectativas	FGV - Sondagem da Indústria - Índice de Confiança
Serviços - Volume de demanda de serviços previsto para os 3 meses seguintes	DO	Demand or Orders Inflow	Sensíveis a expectativas	FGV - Sondagem de Serviços - Índice de Confiança
Ibovespa	SP	Share Prices	Sensíveis a expectativas	Brazil Yahoo Finance e Fundo Monetário Internacional (FMI)
Comércio Exterior - balança comercial com a União Européia (a preços FOB)	NT	Net Trade	Causadores primários	Ministério do Desenvolvimento, Indústria e Comércio Exterior (MDIC)

Fonte: OCDE. Elaboração própria.

Após o crivo econômico, as séries são submetidas a um processo de filtragem com vistas a remover padrões sazonais, *outliers* e outros componentes de alta e baixa frequência. Séries mensais são preferidas a séries trimestrais. Quando há necessidade de utilização de séries trimestrais, as mesmas são mensalizadas através de interpolação linear. Componentes sazonais e *outliers* são identificados e removidos através dos métodos X12 e TRAMO-SEATS.⁷, enquanto a eliminação tanto da tendência quanto do ruído é realizada com o filtro HP. O filtro age desta forma, como um filtro passa-banda⁸. Para tanto, o filtro HP é aplicado duas vezes à série. Na primeira, componentes de baixa frequência (a tendência) são eliminados utilizando um valor alto para o parâmetro de suavização. O resultado é um ciclo de negócios ainda ruidoso, o qual é submetido a um novo processo de filtragem, desta vez com parâmetro de suavização baixo, resultando em uma série de ciclos suavizados.

Os pontos de virada dos ciclos são identificados através de uma versão simplificada do algoritmo Bry-Boschan original (BRY; BOSCHAN, 1971), uma vez que os ciclos resultantes do processo de filtragem com o filtro HP duplo são bastante suaves, não havendo necessidade de suavização durante a execução da rotina, o que reduz o número de iterações durante o processo. Desta forma, o algoritmo modificado simplesmente identifica picos e vales sequencialmente, impondo duração mínima de fases de cinco meses - isto é, qualquer período de desaceleração ou aceleração deve durar pelo menos isso - e de duração mínima

⁷Atualmente é utilizado o X13-ARIMA-SEATS que congrega os dois programas.

⁸Os valores utilizados para o parâmetro de suavização em cada passo, λ , podem ser encontrados em <http://www.oecd.org/sdd/compositeleadingindicatorsclifrequentlyaskedquestionsfaqs.htm>

de um ciclo completo, de pico a pico ou de vale a vale, de pelo menos 15 meses.⁹

Como forma de padronizar as séries para construção do indicador antecedente composto, garantindo que as mesmas estejam mensuradas nas mesmas unidades e escalas, os indicadores são normalizados, removendo-se de cada observação filtrada (x) a média da série, dividindo-se o resultado pelo desvio médio absoluto e adicionando 100 a cada observação, da seguinte forma:

$$x_i^{norm} = 100 + n \left(\frac{x_i - \mu}{\sum_{i=1}^n |x_i - \mu|} \right) \quad (4.8)$$

Neste ponto as séries candidatas são submetidas a testes estatísticos de modo a avaliar seu grau de antecipação em relação aos *turning points* da série de referência. O primeiro é o tempo de antecedência, em meses. O objetivo é escolher séries que antecipem os *turning points* entre 6 e 9 meses em média, com baixo desvio padrão. Antecedentes de curto e médio prazo devem possuir tempo de antecipação mediano entre 2 e 8 meses enquanto antecedentes de longo prazo podem apresentar pontos de virada com tempo superior. Ademais, é desejável que as séries não dêem sinais perdidos, isto é, deixarem de anunciar a ocorrência de um *turning point* na série de referência nem mesmo sinais falsos, isto é, a sinalização de um *turning point* na série de referência quando não há nenhum. Em segundo lugar, o grau de conformidade cíclica é avaliado identificando-se o pico na função de correlação cruzada entre os indicadores e a série de referência. Variáveis antecedentes devem possuir, no período t correlação mais forte com a série de referência no período $t + k$, em que $k > 0$ não deve ser muito distinto do tempo mediano de antecipação dos *turningpoints*.

Finalmente, o indicador antecedente composto é obtido através da agregação das séries pela média das taxas de crescimento de cada componente cíclico escolhido nas etapas anteriores. Os pesos são iguais para cada componente, embora pelo processo de normalização, implicitamente cada componente seja ponderado pelo inverso de seu desvio médio absoluto. A taxa de crescimento média é então encadeada, de forma a se obter o indicador final.

Nas análises a seguir, são considerados cinco dos seis indicadores antecedentes da OCDE para o Brasil. A série de Serviços - Volume de demanda de serviços previsto para os 3 meses seguintes é excluída da análise por apresentar dados apenas a partir de maio de 2008. A série curta não apenas dificultaria a inferência com os exercícios econométricos, sobretudo fora da amostra, como também a comparação com os resultados das demais séries, uma vez que tratar-se-iam de períodos distintos. Por exemplo, como

⁹É interessante notar que o glossário empregado pela OCDE admite fases de no mínimo 9 meses e duração mínima de 2 anos, conforme pode ser visto em <http://www.oecd.org/sdd/leading-indicators/glossaryforoecdcompositeleadingindicators.htm>

pode se deprender a partir da tabela 1, a duração e a frequência das recessões e expansões econômicas é bastante distinta entre a segunda metade da década de 1990 e a segunda metade da década de 2000. Além disso, a última recessão não encontra paralelo nem ao menos com as fortes recessões da década de 1980, em termos de duração. Assim, vinte e duas variáveis são utilizadas, a partir de quatro transformações nos dados. Na primeira, os dados originais são apenas padronizados, utilizando a equação 4.8. Esta transformação visa apenas a tornar comparáveis as magnitudes dos indicadores, não removendo a tendência das séries. Variáveis em nível também foram consideradas na análise de Oliveira (2016). Em seguida, é aplicado o logaritmo neperiano. Na segunda, são utilizados os indicadores ciclicamente ajustados, chamados de normalizados pela OCDE, isto é, após passarem por todas as etapas descritas nesta seção, inclusive remoção da tendência e suavização, antes da agregação. Também é aplicada a função logaritmo neperiano aos dados. Na terceira, toma-se a diferença trimestral do primeiro conjunto de dados. Este procedimento permite diminuir a variabilidade dos dados em relação à diferença mensal e torna a série estacionária, sendo utilizado também por Berge (2015). Por fim, a primeira diferença dos dados normalizados também é considerada.

4.4.2 Resultados dos modelos

A seguir, os resultados empíricos são analisados.

4.4.2.1 Previsão dentro da amostra

A amostra utilizada contém dados mensais de janeiro de 1997 a março de 2016 para todas as variáveis consideradas. O poder preditivo das variáveis explicativas sobre as desacelerações e recessões é avaliado individualmente através de modelos logit univariados e coletivamente através de uma combinação de diferentes modelos logit com o uso de *Bayesian Model Averaging*. As previsões probabilísticas para a amostra inteira são comparadas com a efetiva ocorrência dos eventos nas datas indicadas pela OCDE e pelo CODACE. Os resultados são sumarizados pelas estatísticas QPS, ACC e AUC e apresentados nas tabelas A.1, A.2, A.5 e A.6 em apêndice.

Conforme a tabela A.1, para os casos em nível e normalizado, a maior parte dos indicadores apresenta maior poder preditivo contemporaneamente às desacelerações da OCDE, isto é, em $h = 0$. A exceção é o indicador de exportações líquidas. Por outro lado, tanto a taxa trimestral das variáveis em nível quanto a taxa mensal das variáveis normalizadas indicam maior poder preditivo, em sua maioria, entre 0 e 3 meses, com a maior parte das estatísticas apontando este último como preferível. A exceção é a variação mensal dos ciclos do IBOVESPA e da Selic, cujo maior poder de previsão se dá com precedência de 6 meses nas três estatísticas consideradas. Resultados similares são obtidos com relação às recessões do CODACE, de acordo com a tabela A.2. Contudo,

no caso das variáveis expressas em taxas o maior poder preditivo se dá em horizontes de zero e um mês.

A combinação destas variáveis preditivas em modelos logit multivariados geralmente aumenta o desempenho das previsões dentro da amostra, levando a R^2 mais altos por construção; contudo, o mesmo não é necessariamente verdadeiro fora da amostra, o que motiva a busca pela melhor combinação de variáveis preditivas. Esta busca, no entanto, torna-se mais custosa quanto maior o número de variáveis consideradas, fazendo com que o número de modelos a serem testados cresça exponencialmente. É preciso ressaltar, ainda, que mesmo quando essa busca é computacionalmente factível, pode ser interessante considerar informações de modelos sub-ótimos, isto é não minimizam algum tipo de função perda. Neste trabalho, a combinação de todas as variáveis possíveis, excluindo-se o indicador antecedente composto da OCDE (CLI), levaria à estimação de 32 modelos diferentes (2⁵). Conforme discutido anteriormente, a seleção dos modelos mais relevantes e a probabilidade de inclusão no modelo de cada variável pode ser computada através da BMA. A tabela A.5 mostra as estatísticas de performance para os quatro grupos de variáveis. Os resultados apontam, em geral, performances superiores com a BMA, isto é, menores QPS e maiores ACC e AUC, sobretudo nos horizontes selecionados (em negrito). A seleção dos horizontes relevantes com a BMA obedece ao padrão encontrado com os modelos logit univariados, isto é, maior poder preditivo das variáveis em nível e normalizadas com $h = 0$ e das variáveis em diferença ao redor de 3 meses de precedência. Novamente, resultados similares são alcançados quando a variável resposta é representada pelas recessões do CODACE (tabela A.6), embora os horizontes de maior poder preditivo estejam concentrados em horizontes de até dois meses.

As figuras 4.1 e 4.2 representam as probabilidades marginais de inclusão (PIP) de cada uma das variáveis consideradas, por grupo, em modelos de previsão de desacelerações e recessões, respectivamente. Em cada um, cinco horizontes de previsão são considerados, variando entre 0 e 12 meses: $h = 0, h = 1, h = 3, h = 6$ e $h = 12$. Analisando a figura 4.1, nota-se que a previsão de curto prazo de desacelerações utilizando as variáveis em nível depende basicamente da expectativa de produção nos próximos três meses (Prod) e da taxa Selic (STIR). As outras variáveis exercem maior influência em horizontes mais longos. No caso das variáveis normalizadas, em todos os horizontes, todas as variáveis cumprem papel importante, com exceção do Ibovespa (SP). Já quando são consideradas as variações trimestrais dos indicadores em nível, as previsões de curto prazo se baseiam mais fortemente na taxa Selic e na demanda total da indústria de transformação (OB). Em horizontes mais longos, além destas duas, o Ibovespa (SP) também exerce papel importante, com exceção de $h=12$. Por fim, com relação à variação mensal das variáveis normalizadas, as previsões de curto prazo são baseadas na demanda da indústria (OB) e na taxa de juros de curto prazo (STIR) ($h=1$). Considerando os outros horizontes, novamente a expectativa de produção da indústria de transformação (Prod) passa a ser relevante. Em todos

os casos a constante é incluída. No caso das recessões é interessante notar que algumas variáveis mostram-se irrelevantes em qualquer dos períodos considerados. É o caso do Ibovespa (SP) com variáveis em nível e variação mensal das variáveis normalizadas; da expectativa de produção da indústria de transformação (Prod) nas variações considerada e da balança comercial em variação trimestral.

Figura 4.1: Desacelerações - Covariadas selecionadas dentro da amostra (Probabilidade de inclusão - PIP)

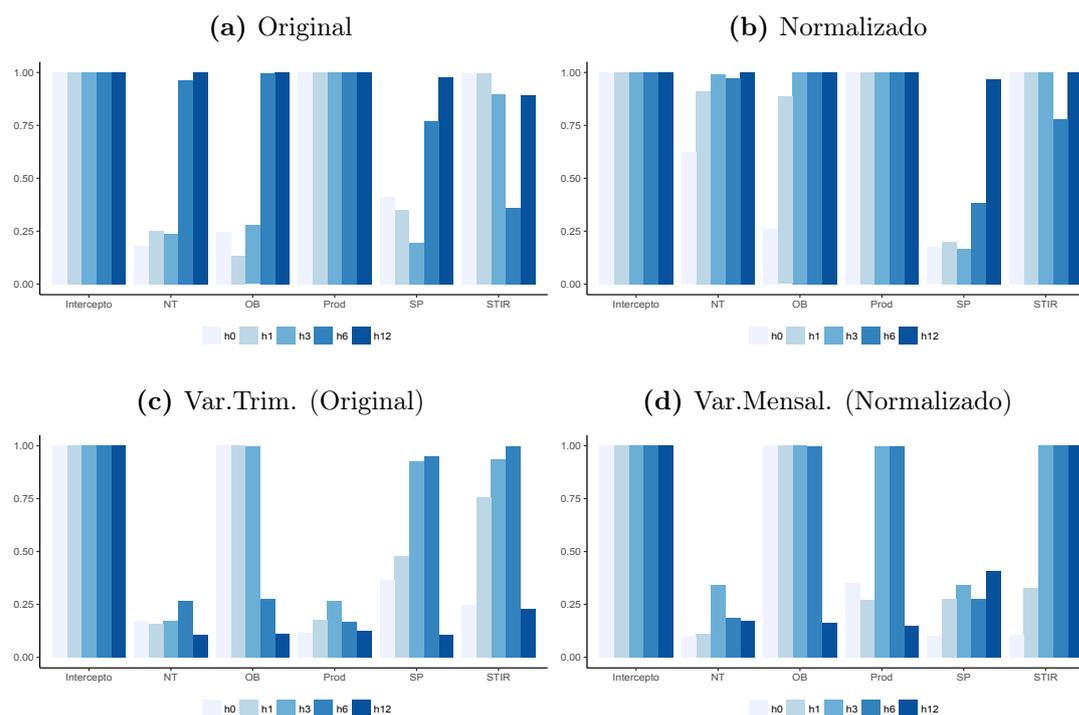
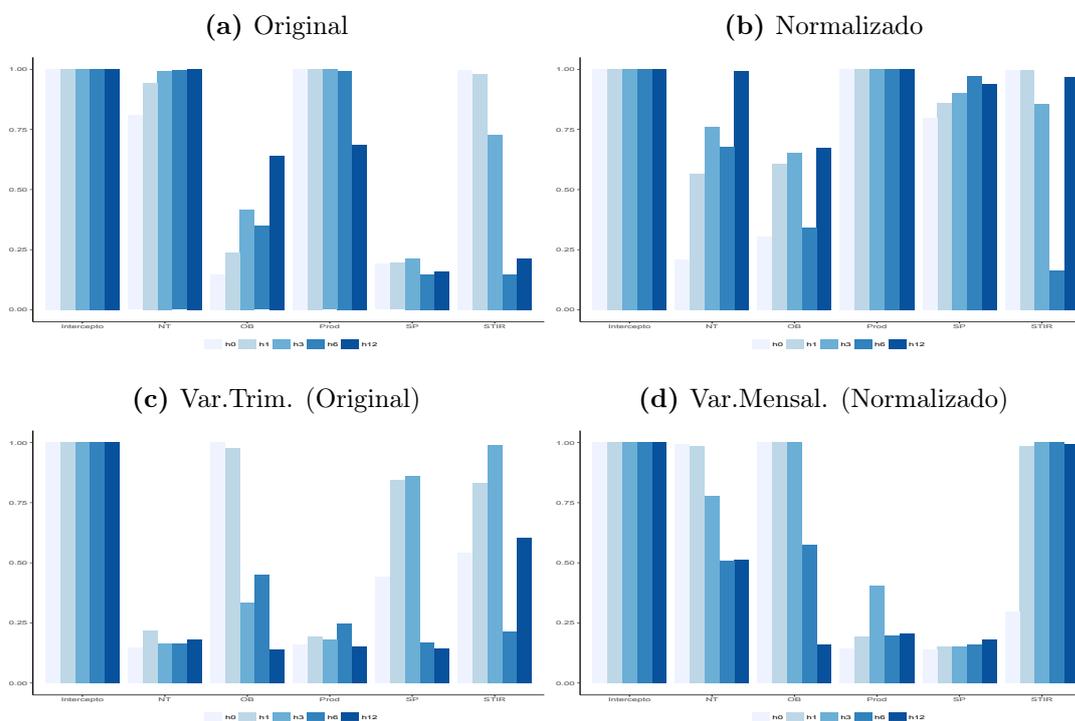


Figura 4.2: Recessões - Covariadas selecionadas dentro da amostra (Probabilidade de inclusão - PIP)



É importante comparar a performance dos modelos BMA, os quais em última instância reponderam os indicadores selecionados pela OCDE, com a apresentada em um modelo logit univariado formado apenas pelo indicador composto da OCDE (CLI), que, como mostrado na seção 4.4.1, incorpora todas estas variáveis com pesos iguais.¹⁰ As figuras 4.3 e 4.4 apresentam as probabilidades de desaceleração e recessão, respectivamente, obtidas pelos dois métodos.

Os sinais probabilísticos emitidos pelos dois métodos são bastante semelhantes dentro da amostra para $h = 0$. Em todos os períodos de desaceleração apontados pela OCDE os sinais emitidos se aproximam de 100%. O sinal mais fraco, da desaceleração de 2011-2012 se aproxima de 75%. Nas desacelerações de 1997-1999 e de 2008-2009 as probabilidades sobem rapidamente, emitindo sinais fortes contemporaneamente ao início das desacelerações. Já nas desacelerações de 2011-2012 e 2013-2016, as probabilidades iniciam o movimento de subida já alguns meses antes de seu início. Os sinais superam a marca dos 50% aproximadamente quando a desaceleração se inicia. Ressalta-se ainda que na primeira, apenas a BMA emitiu sinais fortes. Nas desacelerações de 2000-2003 e 2004-2005, os modelos emitem sinais fortes apenas alguns meses após o início da fase de baixa do ciclo. É interessante notar que no longo período de desaceleração de 2000-2003 datado pela OCDE, o CLI apresenta dois picos de probabilidade, embora não baixando

¹⁰A partir de 2008, o indicador da OCDE também incorpora a previsão de demanda do setor de serviços para os próximos três meses.

da faixa de 50%. Contudo o modelo BMA com variáveis normalizadas divide o período em dois ciclos, de maneira semelhante à cronologia de recessões clássicas do CODACE. Por fim, é interessante notar que, na desaceleração de 2004-2005 - a qual não se converteu em recessão - tanto o modelo logit univariado quanto a BMA emitem sinais fortes mesmo após o fim da desaceleração.

No caso das recessões resultados similares são encontrados. Nota-se, contudo, o sinal falso emitido pelos indicadores normalizados na desaceleração de 2004-2005. Considerando as variações mensais, além deste, outro sinal falso também é emitido na desaceleração de 2012.

Figura 4.3: Probabilidades de desaceleração dentro da amostra - $h=0$

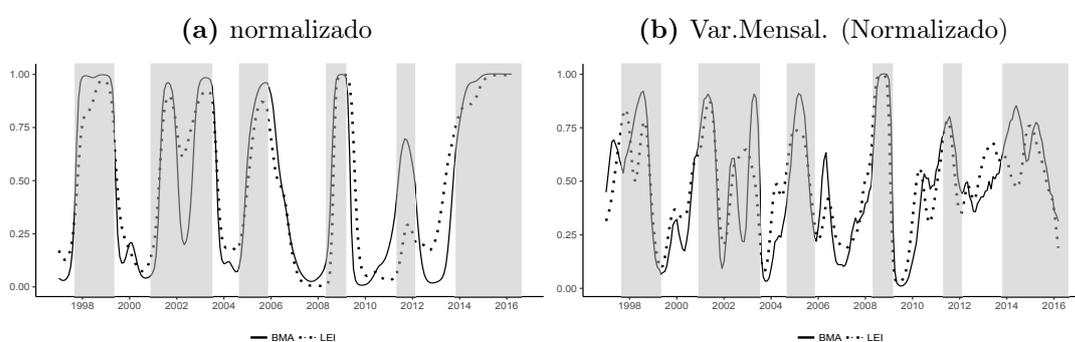
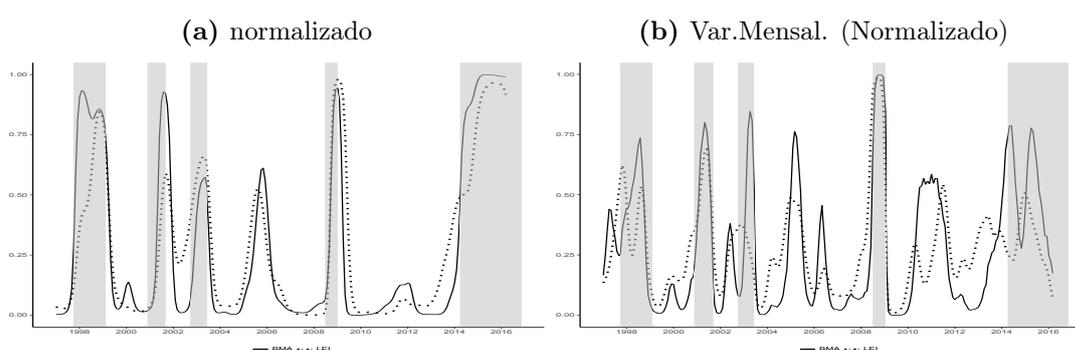


Figura 4.4: Probabilidades de recessão dentro da amostra - $h=0$



4.4.2.2 Previsão fora da amostra

Para avaliar o poder preditivo dos modelos fora da amostra, a seguinte estratégia é adotada. De maneira semelhante a Estrella e Mishkin (1998), primeiramente, os modelos são estimados em uma amostra de treino, com os dados entre janeiro de 1997 e dezembro de 2006 para cada um dos horizontes entre $h = 0$ e $h = 12$. Desta forma, são 13 modelos logit

estimados e 13 modelos BMA. Nota-se que este período engloba três ciclos de crescimento e três ciclos de negócios, conforme a tabela 1. Com os parâmetros estimados, os valores das variáveis preditivas de janeiro de 2007 são utilizados para se obter probabilidades de desaceleração (recessão) entre $h = 0$ e $h = 12$, isto é, entre janeiro de 2007 e janeiro de 2008. As probabilidades estimadas neste ponto são guardadas na primeira linha de uma matriz $Z_{111 \times 13}$, onde cada coluna representa um horizonte de previsão e cada linha representa um mês fora da amostra. Em seguida, os modelos são reestimados, desta vez, com dados entre janeiro de 1997 e janeiro de 2007. Novamente, utiliza-se os valores das variáveis preditivas de fevereiro de 2007 para, a partir dos modelos estimados se obter as probabilidades de desaceleração (recessão) entre fevereiro de 2007 e fevereiro de 2008. Guarda-se, novamente, a probabilidade estimada, desta vez na segunda linha da matriz Z . O processo se repete até o fim da amostra, em março de 2016, no qual a última linha da matriz Z é preenchida.¹¹

$$Z = \begin{bmatrix} p_{2007.1,h=0} & p_{2007.1,h=1} & \cdots & p_{2007.1,h=12} \\ p_{2007.2,h=0} & p_{2007.2,h=1} & \cdots & p_{2007.2,h=12} \\ \vdots & \vdots & \ddots & \vdots \\ p_{2016.3,h=0} & p_{2016.3,h=1} & \cdots & p_{2016.3,h=12} \end{bmatrix}$$

Com a estratégia adotada, é possível verificar quais variáveis ganham ou perdem importância nas proximidades de cada período recessivo ou de desaceleração. Conforme notado em Stock e Watson (2003), cada recessão apresenta suas idiosincrasias, de modo que alguns indicadores podem performar melhor em determinadas circunstâncias do que em outras. As figuras 4.5 e 4.6 apresentam as probabilidades marginais de inclusão (PIP) das covariadas nos modelos usados para produzir as previsões fora da amostra em cada ponto do tempo, para diferentes horizontes com o conjunto de dados normalizados. No caso das desacelerações (figura 4.5), em horizontes mais curtos ($h = 0$ e $h = 1$), a relevância do ibovespa (SP) para previsão cai substancialmente, sobretudo nas desacelerações de 2008-2009 e 2013-2016. Já a partir de um horizonte de 3 meses o ibovespa torna-se relevante apenas na primeira desaceleração. As demais variáveis mantêm probabilidades altas de inclusão em todos os períodos nos horizontes de previsão apresentados. A exceção é o horizonte de 12 meses ($h = 12$). No caso das recessões, há maior variabilidade nas PIP. Em horizontes mais curtos, somente a taxa selic (STIR) e a produção da indústria (Prod) permanecem com probabilidades altas de inclusão durante todo o período.

¹¹Uma desvantagem desta estratégia é a hipótese de que os períodos de desaceleração/recessão tornam-se conhecidos no momento em que ocorrem. Contudo, tanto a OCDE, quanto o CODACE apresentam um atraso, que pode chegar a mais de 12 meses na atualização da cronologia.

Figura 4.5: Desacelerações - Probabilidade de inclusão (PIP) de cada covariada nos modelos BMA usados para produzir previsões fora da amostra.

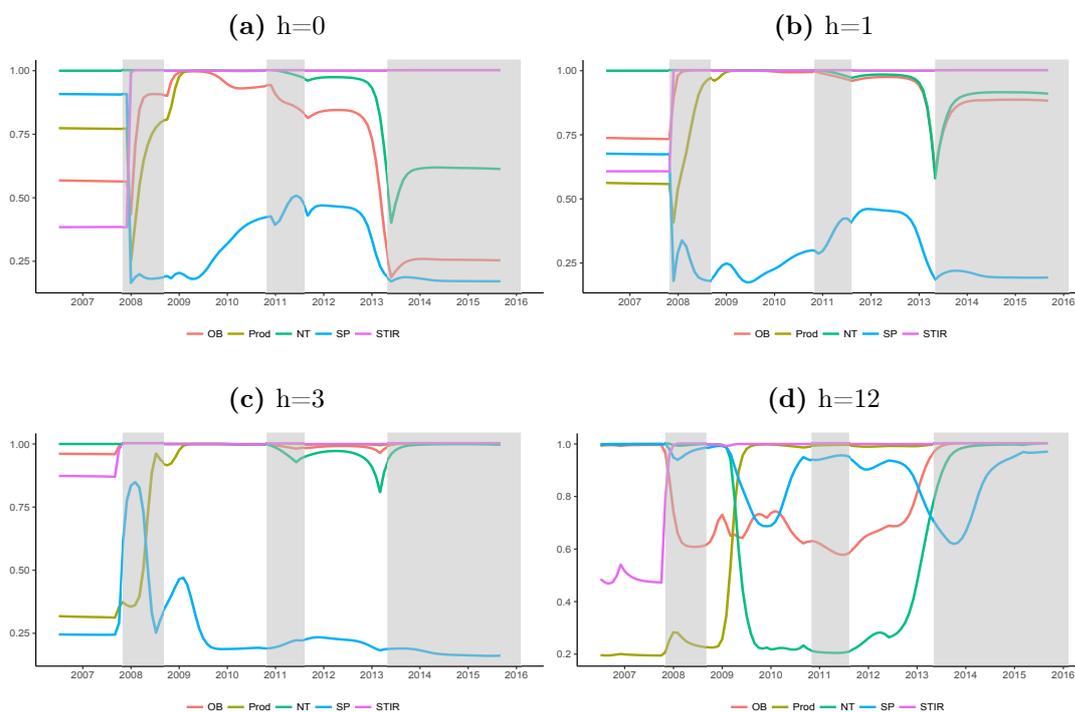
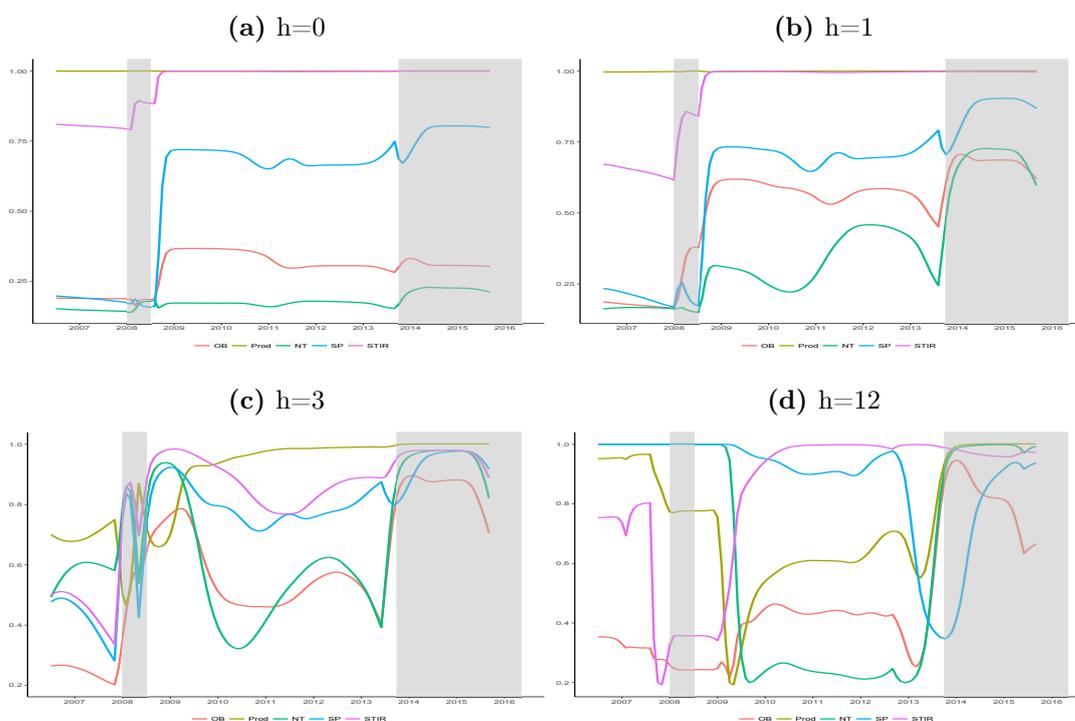


Figura 4.6: Recessões - Probabilidade de inclusão (PIP) de cada covariada nos modelos BMA usados para produzir previsões fora da amostra.



Por fim, é importante verificar a performance dos sinais probabilísticos emitidos pela

BMA e pelo logit univariado da CLI fora da amostra. Comparando os resultados das tabelas A.3 e A.7, nota-se que a performance preditiva é melhorada com o uso da BMA, com menores QPS e maiores ACC e AUC. Ademais, conforme notado na figura 4.7, ambos os modelos, para $h = 0$, dão sinais tardios nas desacelerações de 2008-2009 e de 2011-2012, considerando os dados normalizados. Nesta última, inclusive, a probabilidade obtida com o logit univariado nem ao menos chega próximo de 50%. No entanto, ambos os modelos apresentam fortes sinais de desaceleração com antecedência de alguns meses na mais recente desaceleração. Tomada a variação mensal, estes sinais ultrapassam o limiar de 50% pouco antes do início da desaceleração de 2012. Contudo, após isso as probabilidades se mantêm altas, não identificando o período entre as desacelerações.

Consideradas as recessões, os resultados melhoram substancialmente. Com os dados normalizados, a previsão é bem sucedida em ambos os períodos recessivos de 2008-2009 e 2014-2016. Apesar de as probabilidades, tanto no caso da BMA, quanto do CLI se elevarem no período próximo ao da desaceleração de 2012, as probabilidades não atingem nem ao menos 25%, não caracterizando, portanto, um sinal falso do modelo. Finalmente, considerando as taxas mensais, ambos os modelos do CLI e da BMA antecipam as duas recessões. Contudo, sinais mais fortes de desaceleração em 2012 são emitidos, ainda que não ultrapassem os 50% de probabilidade.

Figura 4.7: Probabilidades de desaceleração fora da amostra - $h=0$

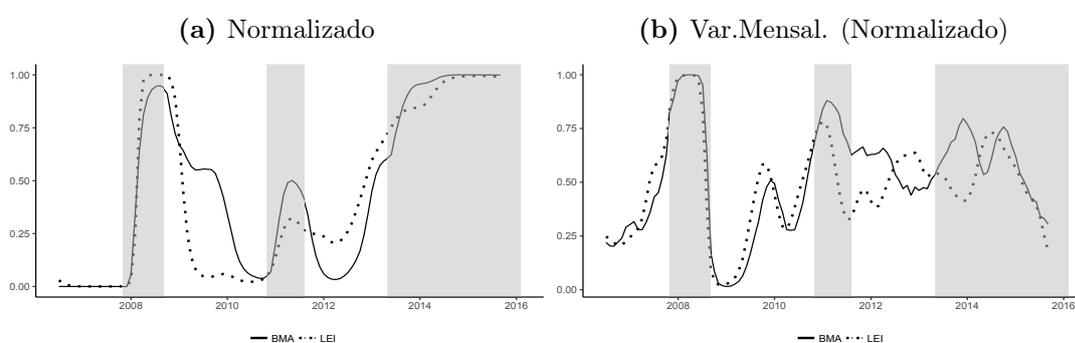
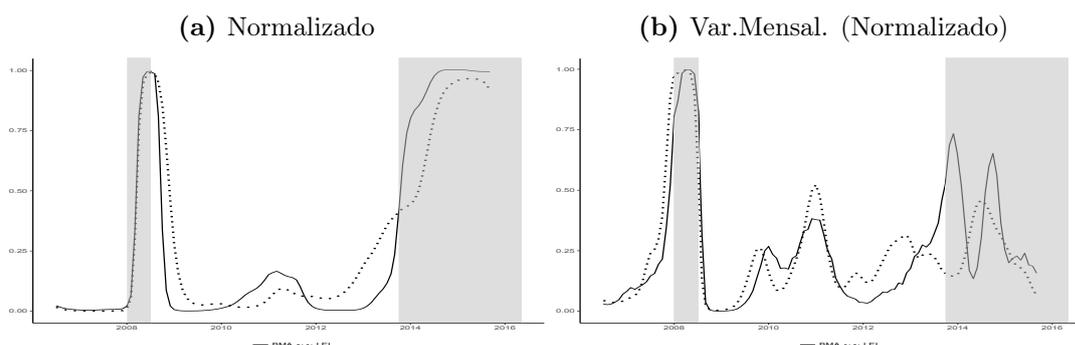


Figura 4.8: Probabilidades de recessão fora da amostra - $h=0$



4.5 Conclusão

A previsão dos ciclos econômicos não é uma tarefa fácil. Por se tratar de um fenômeno altamente não-linear, a previsão através de modelos tradicionais pode - e deve - ser complementada com a observação dos movimentos de uma gama de indicadores econômicos, em especial daqueles identificados como antecedentes da atividade econômica. Para o Brasil, a OCDE elegeu seis indicadores, combinando-os em um indicador composto cujos *turning points* precedem os dos ciclos de crescimento da economia brasileira. No entanto, conforme discutido, há uma relação entre o ciclo de crescimento e o ciclo de negócios clássico, de modo que se torna importante explorar o conteúdo informacional dos indicadores antecedentes da OCDE acerca de ambos os fenômenos. Para tanto, este trabalho utilizou uma abordagem probabilística, lançando mão de modelos logit univariados e combinações de modelos logit através do método BMA em uma gama de transformações dos indicadores selecionados.

Os principais resultados apontam que: 1) mudanças na cronologia dos ciclos implicam mudanças na relevância das variáveis preditivas, sendo, portanto, de extrema importância a boa definição e mensuração do fenômeno cíclico que se deseja prever, 2) da mesma forma, os indicadores individualmente perdem ou ganham relevância conforme o horizonte de previsão varia, 3) a importância dos indicadores muda ao longo do tempo, corroborando os registros de Zarnowitz (1992), Stock e Watson (2003) e outros de que cada recessão ou desaceleração apresenta idiosincrasias, de forma que alguns indicadores "funcionam" melhor do que outros para cada evento distinto, 3) os indicadores apresentam, em geral, maior acurácia na previsão de recessões do que de desacelerações, mesmo no caso dos indicadores normalizados e 4) há ganhos em termos de acurácia preditiva de desacelerações e recessões, tanto dentro quanto fora da amostra, ao se utilizar combinações dos indicadores da OCDE através da BMA no lugar do indicador composto antecedente (CLI) (ver tabelas em apêndice). Embora as diferenças não sejam muito grandes, em alguns casos estas diferenças podem levar à sinalização falsa ou a sinais perdidos, dependendo do *cut-off* de probabilidade escolhido.

Por fim, é importante ter em mente que os exercícios aqui realizados, embora visem a contribuir com um melhor entendimento do indicador da OCDE, em particular no contexto de uma economia emergente como a do Brasil, onde esses estudos são mais escassos, possuem importantes limitações. Primeiramente, a hipótese de que os parâmetros dos modelos considerados são constantes deve ser testada em trabalhos futuros. Constatando-se instabilidade, métodos que permitam a mudança dos parâmetros ao longo do tempo em extensões da BMA, como a *Dynamic Model Averaging* (DMA) devem ser considerados. Em segundo lugar, ganhos de poder preditivo podem ser alcançados considerando formas funcionais que capturem efeitos dinâmicos das fases cíclicas, como mostrado em Kauppi e Saikkonen (2008) e Morais e Chauvet (2011) e devem ser explorados. Em terceiro lugar,

em complementação ao estudo de *turning points*, seria importante também avaliar o poder preditivo dos indicadores em relação a variáveis contínuas de atividade econômica, como a PIB, o IBC-BR ou a produção industrial. Estes são importantes complementos para um melhor entendimento do poder preditivo destes indicadores. Por fim, é imperativo explorar um conjunto mais amplo de potenciais variáveis antecedentes, onde os esforços de seleção de modelos da BMA possam ser melhor aproveitados. Além disso, este novo exercício tem o potencial de revelar indicadores que i) aumentem a performance do CLI, ii) permitam explorar um indicador composto alternativo ou iii) simplesmente mereçam ser monitorados no acompanhamento dos ciclos econômicos em sistemas livres de agregação¹². Estas e outras questões deverão ser estudadas com mais profundidade em uma agenda de trabalhos futuros.

Referências

- AMINI, S. M.; PARMETER, C. F. **Bayesian model averaging in R**. *Journal of Economic and Social Measurement* 36 (4), 253–287, 2011. Disponível em <<https://content.iospress.com/articles/journal-of-economic-and-social-measurement/jem00350>>. Acesso em 12/12/2018.
- AUERBACH, A. J. **The index of leading indicators: "measurement without theory" thirty-five years later**. *The Review of Economics and Statistics* 64 (4), 589–595, 1982. Disponível em <<https://www.jstor.org/stable/1923943>>. Acesso em 12/12/2018.
- BERGE, T. J. **Predicting recessions with leading indicators: Model averaging and selection over the business cycle**. *Journal of Forecasting* 34 (6), 455–471, 2015. Disponível em <<https://onlinelibrary.wiley.com/doi/full/10.1002/for.2345>>. Acesso em 12/12/2018.
- BLAZEJOWSKI, M.; KWIATKOWSKI, J. **Bayesian model averaging and jointness measures for GRET**. *Journal of Statistical Software* 68, 2013. Disponível em <<https://www.jstatsoft.org/article/view/v068i05>>. Acesso em 12/12/2018.
- BOEHM, E. A.; LIEW, W. T. **A review of australia's recent business cycle experiences and a forecast length of the current expansion**. *Australian Economic Review* 27 (3), 4–19, 1994. Disponível em <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1467-8462.1994.tb00844.x>>. Acesso

¹²Um exemplo é o Monitor da Economia Gaúcha (MEG) (ver Colombo et al. (2018)), onde o monitoramento de indicadores coincidentes, antecedentes e defasados é realizado sem a agregação em um indicador composto.

em 12/12/2018.

BRIER, G. W.. **Verification of forecasts expressed in terms of probability.**

Monthly Weather Review 78 (1), 1–3, 1950. Disponível em

<<https://journals.ametsoc.org/>>. Acesso em 12/12/2018.

BRY, G.; BOSCHAN, C.. **Cyclical Analysis of Time Series: Selected Procedures and Computer Programs.** NBER, 1971. Disponível em

<<https://www.nber.org/books/bry71-1>> .Acessoem12/12/2018.

BURNS, A. F.; MITCHELL, W. C. **Measuring business cycles**, NBER, 1946.

Disponível em <<https://www.nber.org/books/burn46-1>>. Acesso em 12/12/2018.

CAMACHO, M.; PEREZ-QUIROS, G.. **This is what the leading indicators lead.**

Journal of Applied Econometrics 17 (1), 61–80, 2002. Disponível em

<<https://onlinelibrary.wiley.com/doi/abs/10.1002/jae.641>>. Acesso em 12/12/2018.

CAMBA-MENDEZ, G.; KAPETANIOS, G.; WEALE, M. R.; SMITH, R. J. **The forecasting performance of the OECD composite leading indicators for France, Germany, Italy, and the UK.** A Companion to Economic Forecasting, 386–408, 2004.

CAMPELO Jr, A. ; SIMA-FRIEDMAN, J.; LIMA, S.; OZYILDIRIM, A.; PICCHETTI, P.. **Tracking business cycles in brazil with composite indexes of coincident and leading economic indicators.** Disponível em

<<https://www.conferenceboard.org/pdf/free/workingpapers/EPWP1306.pdf>> .Acessoem01/10/2018, 2013.

CÉSPEDES, B. J.; CHAUVET, M.; LIMA, E. C. **Forecasting Brazilian output and its turning points in the presence of breaks: A comparison of linear and nonlinear models.** Estudos Econômicos (São Paulo) 36 (1), 5–46, 2006. Disponível em

<http://www.scielo.br/scielo.php?pid=S0101-41612006000100001script=sci_arttext> .Acessoem12/12/2018.

CHAUVET, M. **The brazilian business and growth cycles.** Revista Brasileira de Economia 56 (1), 75–106, 2002. Disponível em

<http://www.scielo.br/scielo.php?pid=S0034-71402002000100003script=sci_arttext> .Acessoem12/12/2018.

CHAUVET, M.; LIMA, E. C., VASQUEZ, B. **Forecasting brazilian output in real time in the presence of breaks: a comparison of linear and nonlinear models**, 2015.

Disponível em <<http://repositorio.ipea.gov.br/handle/11058/4918>>. Acesso em 12/12/2018.

CHAUVET, M.; SILVA, J. d. **Indicadores antecedentes de recessões brasileiras.** XXVI ENCONTRO BRASILEIRO DE ECONOMETRIA. João Pessoa 10, 11–12. 33, 2004. Disponível em <<https://www.researchgate.net/profile/MarcelleChauvet/publication/267408043IndicadoresAntecedentesAcessoem12/12/2018>>.

CLYDE, M. **BAS: Bayesian Variable Selection and Model Averaging using Bayesian Adaptive Sampling.** R package version 1.5.3, 2018.

CLYDE, M.; GEORGE, E. I. **Model uncertainty.** *Statistical science*, 81–94, 2004. Disponível em <https://www.jstor.org/stable/4144374?seq=1page_scan_tabs_contents> .Acessoem12/12/2018.

CLYDE, M. A.; GHOSH, J.; LITTMAN, M. L. **Bayesian adaptive sampling for variable selection and model averaging.** *Journal of Computational and Graphical Statistics* 20 (1), 80–101, 2011. Disponível em <<https://www.tandfonline.com/doi/abs/10.1198/jcgs.2010.09049>>. Acesso em 12/12/2018.

COLOMBO, J. A.; CORTES, R. X.; CRUZ, F. I.; PAESE, L. H. **Building state-level business cycle tracer tools: Evidence from a large emerging economy.** *International Journal of Economics and Finance* 10 (5), 14, 2018. Disponível em <<http://ccsenet.org/journal/index.php/ijef/article/view/73490/0>>. Acesso em 12/12/2018.

CONTADOR, C. R. **Ciclos econômicos e indicadores de atividade no Brasil.** Vol. 35. Instituto de Planejamento Econômico e Social, Instituto de Pesquisas, 1977.

CRAVO, T. A. **Are small employers more cyclically sensitive?** Evidence from Brazil. *Journal of Macroeconomics* 33 (4), 754–769, 2011. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0164070411000486>>. Acesso em 12/12/2018.

DIEBOLD, F. X.; RUDEBUSCH, G. D. **Scoring the leading indicators.** *Journal of business*, 369–391, 1989. Disponível em <<https://www.jstor.org/stable/2353352>>. Acesso em 12/12/2018.

DUARTE, A. J.; ISSLER, J. V.; SPACOV, A. **Indicadores coincidentes de**

atividade econômica e uma cronologia de recessões para o Brasil, 2004.

Disponível em <<http://repositorio.ipea.gov.br/handle/11058/4635>>. Acesso em 12/12/2018.

EMERSON, R. A.; HENDRY, D. F.. **An evaluation of forecasting using leading indicators**. Journal of Forecasting 15 (4), 271–291, 1996. Disponível em

<<https://onlinelibrary.wiley.com/toc/1099131x/1996/15/4>>. Acesso em 12/12/2018.

ESTRELLA, A.; MISHKIN, F. S.. **Predicting US recessions: Financial variables as**

leading indicators. Review of Economics and Statistics 80 (1), 45–61, 1998. Disponível

em <<https://www.mitpressjournals.org/doi/abs/10.1162/003465398557320>>. Acesso em 12/12/2018.

GRUDTNER, V.; ARAGON, E. K. D. S. B.. **Multiplicador dos gastos do governo em períodos de expansão e recessão: evidências empíricas para o Brasil**. Revista

Brasileira de Economia 71 (3), 321–345, 2017. Disponível em

<http://www.scielo.br/scielo.php?pid=S0034-71402017000300321script=sci_arttextlng=pt> .Acessoem12/12/2018.

GYOMAI, E.; GUIDETTI, G., 2012. **OECD system of composite leading indicators**. Disponível em

<<http://www.oecd.org/sdd/leading-indicators/41629509.pdf>>. Acesso em 01/10/2018.

GYOMAI, G.; WILDI, M.. **OECD composite leading indicators for G7**

countries: a comparison of the hodrick-prescott filter and the multivariate direct filter approach. Tech. rep., OECD Publishing, 2012. Disponível em

<<https://www.oecd-ilibrary.org/economics/oecd-composite-leading-indicators-for-g7-countries5k4dhnzwxr3-en>> .Acessoem12/12/2018.

GYOMAI, G.; AHMAD, N.; ASTOLFI, R.. **The OECD system of composite leading indicators**, In: Mazzi, G. L. (Ed.), Handbook on Cyclical Composite

Indicators for Business Cycle Analysis. Eurostat, The Conference Board and the United Nations Statistics Division. Disponível em <

<https://ec.europa.eu/eurostat/documents/3859598/8232150/KS-GQ-17-003-EN-N.pdf/868e9a5b-9bae-450b-a2d9-c668524c738d>>. Acesso em 01/10/2018, 2017.

HAMILTON, J. D. **A new approach to the economic analysis of nonstationary time series and the business cycle**. Econometrica: Journal of the Econometric

Society, 357–384. 3, 1989. Disponível em <<https://www.jstor.org/stable/1912559>>.

Acesso em 12/12/2018.

HAMILTON, J. D.; PEREZ-QUIROS, G.. **What do the leading indicators lead?** *Journal of Business*, 27–49, 1996. Disponível em <<https://www.jstor.org/stable/2353248>>. Acesso em 12/12/2018.

HOETING, J. A.; MADIGAN, D., RAFTERY, . E., VOLINSKY, C. T., **Bayesian model averaging**: a tutorial. *Statistical science*, 382–401, 1999. Disponível em <<https://www.jstor.org/stable/2676803>>. Acesso em 12/12/2018.

HOLLAUER, G., ISSLER, J. V.. **Construção de indicadores antecedentes para a atividade industrial brasileira e comparação de metodologias**, 2006. Disponível em <<http://repositorio.ipea.gov.br/handle/11058/2117>>. Acesso em 12/12/2018.

ISSLER, J. V., NOTINI, H. H., RODRIGUES, C. O. d. F.. **Um indicador coincidente e antecedente da atividade econômica brasileira**, 2009. Disponível em <<https://bibliotecadigital.fgv.br/dspace/handle/10438/2681>>. Acesso em 12/12/2018.

KAUPPI, H., SAIKKONEN P.. **Predicting US recessions with dynamic binary response models**. *The Review of Economics and Statistics* 90 (4), 777–791, 2008. Disponível em <<https://www.mitpressjournals.org/doi/abs/10.1162/rest.90.4.777>>. Acesso em 12/12/2018.

LAM, P.-s.. **The Hamilton model with a general autoregressive component**: estimation and comparison with other models of economic time series. *Journal of Monetary Economics* 26 (3), 409–432, 1990. Disponível em <<https://www.sciencedirect.com/science/article/abs/pii/0304393290900050>>. Acesso em 12/12/2018.

LEVANON, G.. **Evaluating and comparing leading and coincident economic indicators**. *Business Economics* 45 (1), 16–27, 2010. Disponível em <<https://link.springer.com/article/10.1057/be.2009.29>>. Acesso em 12/12/2018.

LI, Y., CLYDE, M. A.. **Mixtures of g-priors in generalized linear models**. *Journal of the American Statistical Association*, 2018. Disponível em <<https://www.tandfonline.com/doi/abs/10.1080/01621459.2018.1469992>>. Acesso em 12/12/2018.

MAGALHÃES, M. A. d.; TOSCANO, V. N.. **Ocorre um "mito monetário" no Brasil?** um estudo do padrão cíclico de índices de preços nacionais. *Estudos*

Econômicos (São Paulo) 45 (3), 567–591, 2015. Disponível em <http://www.scielo.br/scielo.php?pid=S0101-41612015000300567script=sci_arttext> .Acessoem12/12/2018.

MINTZ, I. **Dating Postwar Business Cycles: Methods and Their Application to Western Germany, 1950–67.** NBER, 1969. Disponível em <<https://www.nber.org/books/mint69-1>>. Acesso em 12/12/2018.

MITCHELL, W. C., BURNS, A. F.. **Statistical indicators of cyclical revivals.** In: Statistical indicators of cyclical revivals. NBER, pp. 1–12, 1938. Disponível em <<https://www.nber.org/books/mitc38-1>>. Acesso em 12/12/2018.

MORAIS, I. A. C., CHAUVET, M.. **Leading indicators for the capital goods industry.** Brazilian Review of Econometrics 31 (1), 137–171, 2011. Disponível em <<http://bibliotecadigital.fgv.br/ojs/index.php/bre/article/view/3630>>. Acesso em 12/12/2018.

NAZMI, N.. **Forecasting cyclical turning points with an index of leading indicators: A probabilistic approach.** Journal of Forecasting 12 (3-4), 215–225, 1993. Disponível em <<https://onlinelibrary.wiley.com/doi/abs/10.1002/for.3980120304>>. Acesso em 12/12/2018.

NILSSON, R., BRUNET, O., et al.. **Composite leading indicators for major OECD nonmember economies: Brazil, China, India, Indonesia, Russian Federation, South Africa.** Tech. rep., OECD Publishing, 2006. Disponível em <<https://www.oecd-ilibrary.org/content/paper/834716666802>>. Acesso em 12/12/2018.

NILSSON, R., GYOMAI, G.. **Cycle extraction: A comparison of the phase-average trend method, the hodrick-prescott and christiano-fitzgerald filters.** Disponível em <<https://www.oecd-ilibrary.org/economics/cycle-extraction-a-comparison-of-the-phase-5kg9srt7f8g0-en>>. Acesso em 01/10/2018, 2011.

OECD. **OECD composite leading indicators: Turning points of reference series and component series.** Disponível em <<https://www.oecd.org/sdd/leading-indicators/CLI-components-and-turning-points.pdf>>. Acesso em 01/10/2018, 2018.

OLIVEIRA, F. N. d.. **Financial and real sector leading indicators of recessions in Brazil using probabilistic models.** Revista Brasileira de Economia 70 (3), 337–355, 2016. Disponível em <http://www.scielo.br/scielo.php?pid=S0034-71402016000300337script=sci_arttext> .Acessoem12/12/2018.

PEREIRA, P. L. V., VIEIRA, H. P., **A study of the Brazilian business cycles (1900–2012)**. *Brazilian Review of Econometrics* 33 (2), 123–143, 2013. Disponível em <<http://bibliotecadigital.fgv.br/ojs/index.php/bre/article/view/17176>>. Acesso em 12/12/2018.

SHOESMITH, G. L.. **Predicting national and regional recessions using probit modeling and interest-rate spreads**. *Journal of Regional Science* 43 (2), 373–392, 2003. Disponível em <<https://onlinelibrary.wiley.com/doi/abs/10.1111/1467-9787.00303>>. Acesso em 12/12/2018.

STOCK, J. H., WATSON, M. W.. **How did leading indicators perform during the 2001 recession?** *Economic Quarterly*. Federal Reserve Bank of Richmond, 89 (3), 71–90, 2003. Disponível em <<https://www.richmondfed.org>>. Acesso em 12/12/2018.

TIMMERMANN, A.. **Forecast combinations** in: *Handbook of economic forecasting* 1, 135– 196, 2006. Disponível em <<https://www.sciencedirect.com/handbook/handbook-of-economic-forecasting>>. Acesso em 12/12/2018.

WEALE, M.. **An assessment of OECD and UK leading indicators**. *National Institute Economic Review* 156 (1), 63–71, 1996. Disponível em <<https://journals.sagepub.com/doi/abs/10.1177/002795019615600105>>. Acesso em 12/12/2018.

ZARNOWITZ, V.. **Business Cycles: Theory, History, Indicators, and Forecasting**. University of Chicago Press, 1992. Disponível em <<https://www.nber.org/books/zarn92-1>>. Acesso em 12/12/2018.

ZARNOWITZ, V., OZYILDIRIM, A.. **Time series decomposition and measurement of business cycles, trends and growth cycles**. *Journal of Monetary Economics* 53 (7), 1717–1739, 2006. Disponível em <<https://www.sciencedirect.com/science/article/abs/pii/S0304393206000596>>. Acesso em 12/12/2018.

ZELLNER, A.. **On assessing prior distributions and bayesian regression analysis with g-prior distributions**. *Studies in Bayesian Econometrics and Statistics*. Bayesian inference and decision techniques. New York, Vol. 6, 1986.

Apêndice A - Performances preditivas

Tabela A.1: Ciclos de crescimento - Estatísticas de ajuste dentro da amostra para os modelos Logit univariados.

		Horizonte de previsão					Horizonte de previsão								
		h = 0	h = 1	h = 3	h = 6	h = 12			h = 0	h = 1	h = 3	h = 6	h = 12		
NÍVEL	OB	QPS	0,161	0,183	0,219	0,246	0,246	TAXA TRIMESTRAL (NÍVEL)	OB	QPS	0,199	0,195	0,201	0,232	0,250
		ACC	0,797	0,762	0,688	0,563	0,550		ACC	0,667	0,693	0,697	0,680	0,519	
		AUC	0,840	0,799	0,710	0,572	0,573		AUC	0,758	0,773	0,773	0,712	0,583	
	Prod	QPS	0,157	0,177	0,206	0,234	0,250		Prod	QPS	0,236	0,237	0,240	0,243	0,249
		ACC	0,758	0,727	0,667	0,571	0,524		ACC	0,550	0,554	0,550	0,576	0,576	
		AUC	0,844	0,807	0,735	0,629	0,533		AUC	0,614	0,612	0,599	0,606	0,549	
	NT	QPS	0,231	0,231	0,237	0,238	0,224		NT	QPS	0,248	0,249	0,250	0,250	0,250
		ACC	0,593	0,610	0,610	0,619	0,680		ACC	0,519	0,519	0,502	0,489	0,511	
		AUC	0,649	0,660	0,638	0,634	0,695		AUC	0,523	0,524	0,530	0,499	0,505	
	SP	QPS	0,231	0,234	0,238	0,243	0,248		SP	QPS	0,231	0,228	0,220	0,228	0,250
		ACC	0,610	0,606	0,597	0,554	0,576		ACC	0,593	0,606	0,680	0,662	0,502	
		AUC	0,679	0,669	0,643	0,597	0,531		AUC	0,652	0,669	0,706	0,702	0,464	
	STIR	QPS	0,215	0,219	0,230	0,244	0,250		STIR	QPS	0,240	0,232	0,227	0,224	0,247
		ACC	0,615	0,593	0,567	0,558	0,455		ACC	0,671	0,680	0,736	0,723	0,550	
		AUC	0,714	0,703	0,669	0,598	0,523		AUC	0,692	0,739	0,792	0,776	0,604	
NORMALIZADO	CLI	QPS	0,122	0,145	0,194	0,241	0,242	TAXA MENSAL (NORMALIZADO)	CLI	QPS	0,201	0,176	0,143	0,160	0,246
		ACC	0,827	0,797	0,736	0,628	0,550		ACC	0,706	0,745	0,818	0,792	0,576	
		AUC	0,908	0,871	0,775	0,609	0,598		AUC	0,755	0,814	0,873	0,855	0,604	
	OB	QPS	0,151	0,175	0,214	0,245	0,245		OB	QPS	0,178	0,161	0,157	0,193	0,248
		ACC	0,801	0,766	0,684	0,563	0,576		ACC	0,745	0,762	0,766	0,736	0,576	
		AUC	0,863	0,819	0,725	0,578	0,585		AUC	0,811	0,844	0,853	0,794	0,584	
	Prod	QPS	0,132	0,152	0,190	0,230	0,250		Prod	QPS	0,224	0,213	0,207	0,221	0,245
		ACC	0,801	0,775	0,706	0,584	0,511		ACC	0,632	0,654	0,680	0,654	0,606	
		AUC	0,892	0,858	0,776	0,639	0,462		AUC	0,691	0,730	0,749	0,730	0,609	
	NT	QPS	0,243	0,244	0,247	0,248	0,241		NT	QPS	0,248	0,248	0,248	0,250	0,248
		ACC	0,632	0,623	0,615	0,571	0,545		ACC	0,545	0,558	0,550	0,506	0,455	
		AUC	0,630	0,620	0,592	0,564	0,599		AUC	0,541	0,552	0,554	0,475	0,526	
	SP	QPS	0,180	0,192	0,221	0,249	0,233		SP	QPS	0,225	0,212	0,191	0,191	0,250
		ACC	0,723	0,710	0,667	0,541	0,563		ACC	0,615	0,667	0,706	0,766	0,502	
		AUC	0,805	0,780	0,711	0,573	0,634		AUC	0,670	0,718	0,776	0,793	0,463	
STIR	QPS	0,145	0,159	0,198	0,244	0,215	STIR	QPS	0,235	0,216	0,175	0,154	0,229		
	ACC	0,801	0,771	0,693	0,567	0,658	ACC	0,593	0,649	0,727	0,762	0,628			
	AUC	0,872	0,847	0,764	0,592	0,714	AUC	0,653	0,715	0,816	0,857	0,661			

Tabela A.2: Ciclos de negócios - Estatísticas de ajuste dentro da amostra para os modelos Logit univariados.

		Horizonte de previsão					Horizonte de previsão										
		h = 0	h = 1	h = 3	h = 6	h = 12			h = 0	h = 1	h = 3	h = 6	h = 12				
NÍVEL	OB	QPS	0,120	0,141	0,172	0,191	0,207	TAXA TRIMESTRAL (NÍVEL)	OB	QPS	0,162	0,177	0,198	0,208	0,211		
		ACC	0,840	0,797	0,749	0,710	0,701		ACC	0,779	0,753	0,693	0,680	0,693			
		AUC	0,866	0,824	0,746	0,690	0,591		AUC	0,751	0,724	0,696	0,660	0,565			
	Prod	QPS	0,110	0,130	0,162	0,183	0,202		Prod	QPS	0,182	0,189	0,201	0,209	0,211		
		ACC	0,840	0,805	0,775	0,740	0,688		ACC	0,758	0,745	0,693	0,684	0,693			
		AUC	0,887	0,849	0,783	0,718	0,612		AUC	0,633	0,611	0,603	0,602	0,509			
	NT	QPS	0,175	0,174	0,175	0,184	0,169		NT	QPS	0,200	0,202	0,205	0,211	0,211		
		ACC	0,736	0,745	0,736	0,701	0,758		ACC	0,719	0,714	0,714	0,701	0,701			
		AUC	0,741	0,744	0,745	0,731	0,773		AUC	0,512	0,517	0,531	0,520	0,542			
	SP	QPS	0,193	0,196	0,203	0,210	0,211		SP	QPS	0,186	0,184	0,194	0,210	0,211		
		ACC	0,727	0,723	0,714	0,693	0,693		ACC	0,736	0,719	0,706	0,693	0,693			
		AUC	0,660	0,648	0,617	0,571	0,532		AUC	0,655	0,679	0,672	0,591	0,551			
	STIR	QPS	0,172	0,180	0,193	0,209	0,211		STIR	QPS	0,186	0,184	0,186	0,209	0,207		
		ACC	0,797	0,766	0,732	0,693	0,680		ACC	0,753	0,745	0,740	0,701	0,697			
		AUC	0,669	0,653	0,609	0,551	0,516		AUC	0,680	0,716	0,724	0,616	0,625			
	NORMALIZADO	CLI	QPS	0,102	0,124	0,162	0,193		0,209	TAXA MENSAL (NORMALIZADO)	CLI	QPS	0,165	0,156	0,158	0,196	0,210
			ACC	0,866	0,823	0,758	0,727		0,693		ACC	0,762	0,762	0,745	0,675	0,693	
			AUC	0,916	0,875	0,785	0,667		0,560		AUC	0,762	0,792	0,815	0,752	0,586	
OB		QPS	0,109	0,132	0,164	0,190	0,207	OB	QPS		0,137	0,138	0,163	0,199	0,210		
		ACC	0,844	0,801	0,762	0,727	0,701	ACC	0,818		0,810	0,745	0,667	0,693			
		AUC	0,904	0,861	0,776	0,683	0,579	AUC	0,836		0,839	0,813	0,734	0,590			
Prod		QPS	0,084	0,107	0,146	0,176	0,198	Prod	QPS		0,168	0,163	0,175	0,200	0,210		
		ACC	0,879	0,853	0,788	0,740	0,710	ACC	0,792		0,801	0,779	0,671	0,693			
		AUC	0,951	0,920	0,842	0,728	0,619	AUC	0,694		0,727	0,730	0,692	0,588			
NT		QPS	0,197	0,199	0,203	0,207	0,194	NT	QPS		0,199	0,201	0,205	0,208	0,208		
		ACC	0,719	0,714	0,706	0,693	0,723	ACC	0,719		0,714	0,706	0,693	0,688			
		AUC	0,622	0,616	0,604	0,593	0,653	AUC	0,556		0,551	0,545	0,574	0,605			
SP		QPS	0,170	0,179	0,194	0,208	0,211	SP	QPS		0,184	0,181	0,185	0,205	0,211		
		ACC	0,775	0,745	0,714	0,693	0,693	ACC	0,732		0,736	0,723	0,684	0,693			
		AUC	0,729	0,703	0,646	0,572	0,495	AUC	0,671		0,686	0,710	0,666	0,543			
STIR		QPS	0,134	0,148	0,179	0,208	0,205	STIR	QPS		0,182	0,171	0,158	0,183	0,200		
		ACC	0,797	0,792	0,771	0,693	0,693	ACC	0,745		0,749	0,723	0,693	0,688			
		AUC	0,821	0,794	0,720	0,592	0,614	AUC	0,685		0,736	0,793	0,726	0,638			

Tabela A.3: Ciclos de crescimento - Estatísticas de ajuste fora da amostra para os modelos Logit univariados.

		Horizonte de previsão					Horizonte de previsão								
		h = 0	h = 1	h = 3	h = 6	h = 12			h = 0	h = 1	h = 3	h = 6	h = 12		
NÍVEL	OB	QPS	0,144	0,163	0,203	0,249	0,286	TAXA TRIMESTRAL (NÍVEL)	OB	QPS	0,192	0,183	0,196	0,243	0,253
		ACC	0,811	0,793	0,721	0,495	0,459		ACC	0,676	0,694	0,721	0,685	0,450	
		AUC	0,855	0,827	0,741	0,506	0,456		AUC	0,765	0,808	0,811	0,731	0,445	
	Prod	QPS	0,121	0,141	0,177	0,224	0,265		Prod	QPS	0,236	0,234	0,238	0,247	0,252
		ACC	0,838	0,802	0,784	0,595	0,441		ACC	0,550	0,523	0,523	0,577	0,477	
		AUC	0,894	0,862	0,811	0,647	0,419		AUC	0,575	0,588	0,593	0,615	0,486	
	NT	QPS	0,230	0,233	0,254	0,252	0,225		NT	QPS	0,253	0,256	0,266	0,264	0,256
		ACC	0,613	0,631	0,559	0,541	0,676		ACC	0,477	0,495	0,432	0,405	0,459	
		AUC	0,648	0,649	0,565	0,575	0,701		AUC	0,448	0,436	0,458	0,444	0,439	
	SP	QPS	0,245	0,248	0,256	0,266	0,270		SP	QPS	0,235	0,236	0,240	0,239	0,260
		ACC	0,586	0,577	0,559	0,541	0,523		ACC	0,613	0,613	0,640	0,667	0,450	
		AUC	0,846	0,834	0,790	0,693	0,544		AUC	0,665	0,677	0,697	0,671	0,449	
	STIR	QPS	0,243	0,242	0,238	0,246	0,256		STIR	QPS	0,250	0,245	0,237	0,232	0,248
		ACC	0,586	0,577	0,559	0,523	0,441		ACC	0,486	0,523	0,595	0,676	0,495	
		AUC	0,964	0,939	0,834	0,634	0,465		AUC	0,442	0,555	0,671	0,730	0,536	
NORMALIZADO	CLI	QPS	0,138	0,149	0,187	0,239	0,305	TAXA MENSAL (NORMALIZADO)	CLI	QPS	0,213	0,195	0,177	0,179	0,259
		ACC	0,793	0,793	0,793	0,577	0,387		ACC	0,595	0,640	0,721	0,748	0,541	
		AUC	0,888	0,857	0,784	0,579	0,450		AUC	0,701	0,764	0,822	0,818	0,557	
	OB	QPS	0,135	0,156	0,196	0,248	0,288		OB	QPS	0,163	0,145	0,146	0,195	0,251
		ACC	0,829	0,793	0,730	0,514	0,459		ACC	0,766	0,793	0,829	0,784	0,514	
		AUC	0,877	0,845	0,759	0,517	0,482		AUC	0,863	0,902	0,903	0,856	0,524	
	Prod	QPS	0,094	0,115	0,158	0,215	0,263		Prod	QPS	0,218	0,207	0,200	0,216	0,244
		ACC	0,865	0,838	0,802	0,658	0,459		ACC	0,595	0,622	0,658	0,757	0,586	
		AUC	0,941	0,911	0,848	0,677	0,452		AUC	0,673	0,720	0,759	0,794	0,611	
	NT	QPS	0,337	0,339	0,331	0,295	0,239		NT	QPS	0,277	0,292	0,323	0,323	0,289
		ACC	0,495	0,486	0,486	0,441	0,640		ACC	0,459	0,450	0,396	0,342	0,477	
		AUC	0,479	0,461	0,448	0,433	0,642		AUC	0,534	0,536	0,511	0,449	0,488	
	SP	QPS	0,157	0,172	0,211	0,256	0,290		SP	QPS	0,236	0,225	0,217	0,209	0,269
		ACC	0,775	0,775	0,757	0,468	0,468		ACC	0,613	0,640	0,685	0,685	0,432	
		AUC	0,849	0,833	0,765	0,488	0,551		AUC	0,670	0,730	0,779	0,760	0,451	
STIR	QPS	0,125	0,129	0,166	0,246	0,280	STIR	QPS	0,265	0,262	0,245	0,183	0,217		
	ACC	0,847	0,838	0,766	0,514	0,468	ACC	0,405	0,459	0,595	0,703	0,694			
	AUC	0,925	0,924	0,877	0,539	0,560	AUC	0,418	0,514	0,655	0,791	0,752			

Tabela A.4: Ciclos de negócios - Estatísticas de ajuste fora da amostra para os modelos Logit univariados.

		Horizonte de previsão					Horizonte de previsão								
		h = 0	h = 1	h = 3	h = 6	h = 12			h = 0	h = 1	h = 3	h = 6	h = 12		
NÍVEL	OB	QPS	0,082	0,107	0,149	0,185	0,24	TAXA TRIMESTRAL (NÍVEL)	QPS	0,157	0,178	0,214	0,227	0,236	
		ACC	0,901	0,874	0,811	0,757	0,64		ACC	0,793	0,739	0,676	0,640	0,640	
		AUC	0,909	0,879	0,818	0,729	0,546		AUC	0,774	0,772	0,773	0,775	0,588	
	Prod	QPS	0,063	0,089	0,134	0,163	0,222		Prod	QPS	0,176	0,189	0,216	0,224	0,236
		ACC	0,946	0,91	0,811	0,784	0,676		ACC	0,766	0,739	0,667	0,649	0,640	
		AUC	0,931	0,896	0,828	0,808	0,605		AUC	0,656	0,628	0,597	0,646	0,609	
	NT	QPS	0,188	0,188	0,187	0,2	0,185		NT	QPS	0,207	0,212	0,222	0,228	0,235
		ACC	0,703	0,721	0,739	0,685	0,712		ACC	0,712	0,703	0,685	0,658	0,658	
		AUC	0,711	0,714	0,737	0,734	0,787		AUC	0,525	0,532	0,556	0,611	0,621	
	SP	QPS	0,22	0,223	0,229	0,241	0,25		SP	QPS	0,197	0,197	0,217	0,242	0,236
		ACC	0,73	0,721	0,703	0,676	0,64		ACC	0,676	0,658	0,676	0,631	0,640	
		AUC	0,925	0,899	0,857	0,801	0,739		AUC	0,671	0,697	0,645	0,614	0,606	
	STIR	QPS	0,218	0,219	0,223	0,229	0,236		STIR	QPS	0,197	0,199	0,205	0,223	0,230
		ACC	0,73	0,721	0,703	0,676	0,64		ACC	0,712	0,721	0,703	0,676	0,658	
		AUC	0,935	0,921	0,866	0,781	0,704		AUC	0,712	0,756	0,771	0,688	0,714	
NORMALIZADO	CLI	QPS	0,075	0,097	0,136	0,193	0,262	TAXA MENSAL (NORMALIZADO)	QPS	0,182	0,186	0,194	0,228	0,232	
		ACC	0,892	0,856	0,793	0,739	0,595		ACC	0,730	0,730	0,721	0,658	0,640	
		AUC	0,952	0,923	0,876	0,701	0,432		AUC	0,719	0,725	0,741	0,755	0,676	
	OB	QPS	0,076	0,098	0,134	0,184	0,24		OB	QPS	0,143	0,145	0,176	0,226	0,233
		ACC	0,892	0,874	0,838	0,757	0,631		ACC	0,811	0,802	0,712	0,622	0,640	
		AUC	0,935	0,91	0,858	0,727	0,548		AUC	0,827	0,837	0,852	0,827	0,646	
	Prod	QPS	0,048	0,07	0,109	0,147	0,215		Prod	QPS	0,155	0,153	0,185	0,227	0,237
		ACC	0,955	0,919	0,847	0,811	0,694		ACC	0,802	0,838	0,766	0,649	0,640	
		AUC	0,975	0,947	0,893	0,84	0,641		AUC	0,709	0,721	0,709	0,688	0,608	
	NT	QPS	0,232	0,23	0,225	0,224	0,209		NT	QPS	0,216	0,226	0,243	0,240	0,225
		ACC	0,604	0,622	0,685	0,676	0,658		ACC	0,748	0,712	0,685	0,631	0,640	
		AUC	0,545	0,539	0,559	0,615	0,768		AUC	0,517	0,511	0,506	0,549	0,662	
	SP	QPS	0,141	0,158	0,191	0,243	0,3		SP	QPS	0,189	0,191	0,200	0,229	0,237
		ACC	0,802	0,757	0,739	0,604	0,568		ACC	0,703	0,721	0,703	0,649	0,640	
		AUC	0,877	0,852	0,73	0,519	0,452		AUC	0,705	0,712	0,717	0,686	0,642	
STIR	QPS	0,136	0,146	0,174	0,221	0,257	STIR	QPS	0,204	0,209	0,207	0,200	0,215		
	ACC	0,82	0,802	0,73	0,676	0,604	ACC	0,712	0,676	0,640	0,676	0,658			
	AUC	0,883	0,874	0,817	0,604	0,526	AUC	0,573	0,617	0,697	0,740	0,770			

Tabela A.5: Ciclos de Crescimento - Previsão dentro da amostra - Bayesian Model Averaging (BMA)

Transformação nos indicadores	Estatística	Horizonte de previsão												
		0	1	2	3	4	5	6	7	8	9	10	11	12
NÍVEL	QPS	0,140	0,160	0,179	0,195	0,203	0,204	0,209	0,207	0,211	0,203	0,193	0,180	0,176
	ACC	0,775	0,745	0,719	0,684	0,654	0,662	0,667	0,667	0,662	0,701	0,714	0,732	0,745
	AUC	0,873	0,840	0,804	0,766	0,744	0,744	0,723	0,739	0,728	0,753	0,779	0,806	0,813
NORMALIZADO	QPS	0,095	0,111	0,132	0,152	0,171	0,187	0,199	0,202	0,197	0,189	0,178	0,167	0,158
	ACC	0,870	0,853	0,831	0,805	0,771	0,745	0,710	0,693	0,675	0,697	0,723	0,719	0,762
	AUC	0,946	0,923	0,888	0,851	0,820	0,787	0,756	0,748	0,763	0,786	0,813	0,834	0,852
VAR. EM 3 MESES (ORIGINAL)	QPS	0,196	0,189	0,186	0,190	0,195	0,201	0,211	0,229	0,239	0,245	0,248	0,249	0,249
	ACC	0,667	0,701	0,723	0,745	0,736	0,710	0,701	0,697	0,623	0,597	0,589	0,537	0,489
	AUC	0,767	0,786	0,794	0,787	0,777	0,766	0,753	0,707	0,656	0,616	0,580	0,577	0,578
VAR. MENSAL (NORMALIZADO)	QPS	0,176	0,158	0,133	0,116	0,111	0,114	0,127	0,148	0,175	0,197	0,211	0,222	0,226
	ACC	0,732	0,766	0,797	0,840	0,866	0,844	0,823	0,810	0,745	0,693	0,658	0,641	0,645
	AUC	0,815	0,855	0,898	0,913	0,915	0,912	0,896	0,860	0,814	0,762	0,724	0,691	0,675

Tabela A.6: Ciclos de Negócios - Previsão dentro da amostra - Bayesian Model Averaging (BMA)

Transformação nos indicadores	Estatística	Horizonte de previsão													
		0	1	2	3	4	5	6	7	8	9	10	11	12	
NÍVEL	QPS	0,085	0,107	0,121	0,138	0,147	0,160	0,166	0,167	0,170	0,170	0,170	0,170	0,168	0,163
	ACC	0,892	0,861	0,835	0,801	0,784	0,784	0,771	0,779	0,775	0,762	0,762	0,758	0,753	0,775
	AUC	0,920	0,889	0,860	0,826	0,808	0,780	0,770	0,766	0,765	0,771	0,774	0,774	0,777	0,792
NORMALIZADO	QPS	0,069	0,091	0,111	0,129	0,144	0,153	0,159	0,163	0,167	0,168	0,167	0,161	0,161	0,152
	ACC	0,909	0,866	0,831	0,818	0,810	0,792	0,792	0,779	0,758	0,732	0,714	0,714	0,714	0,762
	AUC	0,954	0,928	0,901	0,870	0,834	0,808	0,794	0,790	0,792	0,800	0,813	0,827	0,827	0,842
VAR. EM 3 MESES (ORIGINAL)	QPS	0,158	0,167	0,172	0,179	0,192	0,203	0,207	0,209	0,211	0,212	0,212	0,212	0,209	0,207
	ACC	0,788	0,762	0,745	0,745	0,714	0,688	0,688	0,684	0,684	0,684	0,684	0,684	0,697	0,701
	AUC	0,766	0,750	0,726	0,707	0,689	0,672	0,664	0,665	0,652	0,634	0,601	0,611	0,611	0,632
VAR. MENSAL (NORMALIZADO)	QPS	0,127	0,123	0,128	0,137	0,150	0,165	0,178	0,187	0,192	0,195	0,198	0,198	0,198	0,197
	ACC	0,792	0,801	0,801	0,749	0,749	0,719	0,675	0,675	0,654	0,649	0,645	0,675	0,693	0,693
	AUC	0,864	0,881	0,875	0,860	0,832	0,793	0,752	0,718	0,704	0,692	0,682	0,672	0,663	0,663

Tabela A.7: Ciclos de Crescimento - Previsão fora da amostra - Bayesian Model Averaging (BMA)

Transformação nos indicadores	Estatística	Horizonte de previsão												
		0	1	2	3	4	5	6	7	8	9	10	11	12
NÍVEL	QPS	0,116	0,138	0,16	0,184	0,206	0,215	0,235	0,242	0,267	0,276	0,269	0,238	0,23
	ACC	0,829	0,811	0,766	0,73	0,694	0,667	0,649	0,604	0,577	0,541	0,586	0,64	0,649
	AUC	0,918	0,911	0,896	0,847	0,795	0,827	0,817	0,771	0,741	0,73	0,728	0,763	0,759
NORMALIZADO	QPS	0,131	0,161	0,183	0,199	0,211	0,218	0,227	0,227	0,223	0,223	0,223	0,217	0,207
	ACC	0,748	0,712	0,712	0,712	0,712	0,721	0,721	0,721	0,667	0,631	0,622	0,667	0,685
	AUC	0,896	0,867	0,831	0,779	0,743	0,723	0,704	0,71	0,726	0,712	0,727	0,741	0,759
VAR. TRIMESTRAL (NÍVEL)	QPS	0,195	0,189	0,196	0,212	0,217	0,215	0,228	0,254	0,269	0,27	0,263	0,256	0,253
	ACC	0,658	0,694	0,676	0,703	0,667	0,694	0,676	0,649	0,568	0,532	0,495	0,486	0,477
	AUC	0,76	0,79	0,765	0,734	0,737	0,729	0,708	0,651	0,576	0,495	0,484	0,471	0,452
VAR. MENSAL (NORMALIZADO)	QPS	0,168	0,166	0,171	0,176	0,182	0,181	0,187	0,203	0,215	0,227	0,242	0,251	0,254
	ACC	0,739	0,685	0,73	0,757	0,757	0,766	0,712	0,667	0,658	0,649	0,595	0,55	0,577
	AUC	0,854	0,852	0,828	0,818	0,817	0,813	0,799	0,763	0,728	0,7	0,658	0,619	0,611

Tabela A.8: Ciclos de Negócios - Previsão fora da amostra - Bayesian Model Averaging (BMA)

Transformação nos indicadores	Estatística	Horizonte de previsão												
		0	1	2	3	4	5	6	7	8	9	10	11	12
NÍVEL	QPS	0,073	0,101	0,121	0,142	0,152	0,168	0,182	0,192	0,200	0,212	0,220	0,223	0,225
	ACC	0,892	0,865	0,847	0,820	0,811	0,793	0,784	0,730	0,730	0,658	0,676	0,676	0,676
	AUC	0,945	0,922	0,906	0,893	0,865	0,814	0,801	0,806	0,810	0,775	0,765	0,740	0,731
NORMALIZADO	QPS	0,042	0,060	0,078	0,098	0,121	0,141	0,161	0,183	0,211	0,235	0,249	0,238	0,220
	ACC	0,955	0,919	0,919	0,901	0,847	0,793	0,784	0,766	0,712	0,676	0,649	0,649	0,667
	AUC	0,982	0,962	0,944	0,912	0,889	0,864	0,834	0,773	0,723	0,676	0,660	0,683	0,743
VAR. TRIMESTRAL (NÍVEL)	QPS	0,160	0,184	0,199	0,210	0,226	0,231	0,232	0,233	0,238	0,236	0,234	0,233	0,234
	ACC	0,766	0,685	0,685	0,703	0,676	0,658	0,631	0,631	0,631	0,631	0,640	0,640	0,640
	AUC	0,777	0,731	0,688	0,665	0,661	0,669	0,676	0,682	0,680	0,672	0,640	0,641	0,634
VAR. MENSAL (NORMALIZADO)	QPS	0,130	0,143	0,164	0,178	0,187	0,194	0,201	0,209	0,217	0,214	0,213	0,218	0,228
	ACC	0,838	0,802	0,775	0,766	0,730	0,703	0,667	0,658	0,622	0,622	0,640	0,640	0,631
	AUC	0,852	0,834	0,803	0,789	0,788	0,787	0,788	0,792	0,800	0,800	0,793	0,725	0,641

5 Considerações Finais

A presente tese foi composta por três ensaios contendo estudos empíricos sobre os ciclos de negócios no Brasil, com o intuito de adicionar evidências à literatura macroeconômica, em especial em países em desenvolvimento. Os temas aqui abordados tratam da mensuração, caracterização e previsão dos ciclos de negócios.

No primeiro ensaio foram estudados os ciclos na produção industrial nacional, sua relação com o ciclo de negócios e com os ciclos setoriais e regionais da indústria. Probabilidades de transição entre estados da economia foram estimadas através de modelos de mudança markoviana com dois regimes. Os resultados mostraram uma alta correlação entre os ciclos na produção industrial e os ciclos de negócios, definidos pela cronologia do CODACE. Este é um resultado esperado, dado que o índice de produção industrial constitui-se como um dos mais tradicionais indicadores coincidentes de atividade, muitas vezes sendo usado como *proxy* do PIB.

Para identificação de períodos de expansão e recessão ou aquecimento e desaquecimento na análise desagregada optou-se pelo uso de modelos de Cadeia de Markov Oculta com mudança de regime na variância. A análise dos setores da indústria foi conduzida para a indústria extrativa e de transformação. O estudo apontou que esta última apresenta maior sincronia com os ciclos da indústria nacional, identificando-se períodos recessivos com maior frequência na indústria extrativa. Finalmente, a análise regional abordou 13 estados para os quais havia séries de produção da indústria geral. Os resultados apontaram que alguns estados não sofreram recessões, apenas desacelerações no período estudado. Ademais, de acordo com os modelos estimados há um padrão de espalhamento durante a recessão de 2008-2009, que não se observou na recessão de 2014-2016, com estados transitando entre regimes. Em alguns casos, este pode ser um indicativo de que erros de especificação estão presentes nos modelos utilizados, devendo-se considerar em estudos futuros componentes autoregressivos e um maior número de regimes.

Já o segundo ensaio estudou os ciclos de negócios em sua interpretação de hiato do produto - os chamados ciclos de crescimento ou ciclos de desvios - utilizando a Análise do Espectro Singular (SSA). A partir do procedimento de Carvalho e Rua (2017) para o agrupamento de componentes, o estudo explorou as características dos ciclos encontrados com o uso de diferentes escolhas para o tamanho de janela. Os resultados também foram contrastados com outros filtros utilizados na literatura de ciclos de negócios. Pôde-se constatar: i) a sensibilidade da SSA à escolha do tamanho da janela, ii) maior semelhança

entre as características da SSA com o filtro CF, dentre os tradicionais mais tradicionais, iii) performance superior em quase tempo real da SSA, sob alguns critérios, em relação a outros filtros, notando-se novamente a sensibilidade deste resultado à escolha das janelas.

Por fim, o terceiro ensaio avaliou a capacidade preditiva dos indicadores antecedentes da OCDE sobre o ciclo de negócios brasileiro utilizando modelos probabilísticos de previsão de eventos binários. Foram estudados dois tipos de eventos: recessões, conforme cronologia do CODACE e desacelerações, conforme cronologia da OCDE. Os exercícios avaliaram o poder preditivo dos indicadores individualmente, em horizontes de 0 a 12 meses, através de modelos logit univariados e de combinações dos indicadores através da Bayesian Model Averaging. Os resultados encontrados sugerem melhores resultados preditivos em prazos mais curtos. Nota-se também que os resultados variam de acordo com o evento que se deseja prever e com o horizonte de previsão; contudo, de maneira geral os indicadores mostraram-se melhores previsores de recessões do que de desacelerações. Por fim, há ganhos preditivos em se considerar combinações dos indicadores.

Em resumo, os ensaios utilizaram diferentes métodos de análise de séries de tempo, paramétricos e não paramétricos, com vistas a explorar diferentes aspectos dos ciclos no Brasil. Avanços, contudo, ainda são necessários. Neste sentido, o trabalho aponta alguns pontos a serem explorados em estudos futuros, sugerindo uma agenda de pesquisa com vistas a aprofundar e expandir as investigações aqui iniciadas.

Referências

BURNS, A. F.; MITCHELL, W. C. **Measuring business cycles**. NBER Books, National Bureau of Economic Research, Inc, 1946. Disponível em <<https://www.nber.org/books/burn46-1>>. Acesso em 12/12/2018.

CANOVA, F. **Detrending and business cycle facts**. Journal of monetary economics, Elsevier, v. 41, n. 3, p. 475–512, 1998. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0304393298000063>>. Acesso em 12/12/2018.

CANOVA, F. **Does detrending matter for the determination of the reference cycle and the selection of turning points?** The Economic Journal, Wiley Online Library, v. 109, n. 452, p. 126–150, 1999. Disponível em <<https://onlinelibrary.wiley.com/doi/abs/10.1111/1468-0297.00395>>. Acesso em 12/12/2018.

CARVALHO, M. de; RODRIGUES, P. C.; RUA, A. **Tracking the US business cycle with a singular spectrum analysis**. Economics Letters, Elsevier, v. 114, n. 1, p. 32–35, 2012. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0165176511003363>>. Acesso em 12/12/2018.

CARVALHO, M. de; RUA, A. **Real-time nowcasting the US output gap: Singular spectrum analysis at work**. International Journal of Forecasting, Elsevier, v. 33, n. 1, p. 185–198, 2017. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0169207015001247>>. Acesso em 12/12/2018.

CUNHA, A. B.; MOREIRA, L. P. **Brazilian regional business cycles from 1985 to 2002: an introduction**. Revista de Economia Contemporânea, SciELO Brasil, v. 10, n. 1, p. 115–138, 2006. Disponível em <http://www.scielo.br/scielo.php?pid=S1415-98482006000100005script=sci_arttext> .Acessoem12/12/2018.

FRIEDMAN, M. **The permanent income hypothesis**. In: A theory of the

consumption function. 1957. Disponível em <<https://www.nber.org/books/frie57-1>>. Acesso em 12/12/2018.

HAMILTON, J. **Why you should never use the Hodrick-Prescott filter**. Review of Economics and Statistics, MIT Press, n 0, 2017. Disponível em <https://www.mitpressjournals.org/doi/abs/10.1162/REST_a00706> .Acessoem12/12/2018.

JACOBS, J. **Econometric Business Cycle Research**. Springer Science Media, 2012. Disponível em <<https://www.springer.com/fr/book/9780792382546>>. Acesso em 12/12/2018.

LUCAS, R. E. **Models of business cycles**. Basil Blackwell Oxford, v. 26. 1987.

LUCAS, R. E. **Macroeconomic priorities**. The American Economic Review, American Economic Association, v. 93, n. 1, p. 1, 2003. Disponível em <<http://pubs.aeaweb.org/doi/pdf/10.1257/000282803321455133>>. Acesso em 12/12/2018.

MISE, E.; KIM, T.-H.; NEWBOLD, P. **The Hodrick-Prescott filter at time series endpoints**. University of Nottingham Economics Discussion Paper, n. 03/08, 2003. Disponível em <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=422563> .Acessoem12/12/2018.

ORPHANIDES, A.; NORDEN, S. V. **The unreliability of output-gap estimates in real time**. Review of economics and statistics, MIT Press, v. 84, n. 4, p. 569–583, 2002. Disponível em <<https://www.mitpressjournals.org/doi/abs/10.1162/003465302760556422>>. Acesso em 12/12/2018.

OWYANG, M. T.; PIGER, J.; WALL, H. J. **Business cycle phases in US states**. Re-view of Economics and Statistics, MIT Press, v. 87, n. 4, p. 604–616, 2005. Disponível em <<https://www.mitpressjournals.org/doi/abs/10.1162/003465305775098198?journalCode=rest>>. Acesso em 12/12/2018.

OWYANG, M. T. et al. **The economic performance of cities: A markov-switching approach**. Journal of Urban Economics, Elsevier, v. 64, n. 3, p. 538–550, 2008. Disponível em <<https://www.sciencedirect.com/science/article/pii/S0094119008000557>>. Acesso em 12/12/2018.

PALLAGE, S.; ROBE, M. A. **On the welfare cost of economic fluctuations in developing countries**. *International Economic Review*, Wiley Online Library, v. 44, n. 2, p. 677–698, 2003. Disponível em <<https://www.jstor.org/stable/3663483>>. Acesso em 12/12/2018.

PORTUGAL, M. S.; MORAIS, I. A. C. d. **Business cycle in the industrial production of brazilian states**. *Análise econômica*. Porto Alegre. vol. 26, n. 50 (set. 2008), p. 27-56, 2008. Disponível em <<https://www.lume.ufrgs.br/handle/10183/25329>>. Acesso em 12/12/2018.

TELES, V., SPRINGER, P., GOMES, M., PAES, N., CAVALCANTI, A. . **Ciclos econômicos e métodos de filtragem: fatos estilizados para o caso brasileiro**. *Revista EconomiA*, v. 6, p. 291–328, 2005. Disponível em <<http://www.anpec.org.br/novosite/br/volume-6>>. Acesso em 12/12/2018.