

FUNDAÇÃO GETULIO VARGAS
ESCOLA DE ECONOMIA DE SÃO PAULO

RODRIGO NISHIDA

**COMPARAÇÃO DE PREVISÕES PARA A PRODUÇÃO INDUSTRIAL
BRASILEIRA CONSIDERANDO EFEITOS CALENDÁRIO E MODELOS
AGREGADOS E DESAGREGADOS**

SÃO PAULO

2016

RODRIGO NISHIDA

**COMPARAÇÃO DE PREVISÕES PARA A PRODUÇÃO INDUSTRIAL
BRASILEIRA CONSIDERANDO EFEITOS CALENDÁRIO E MODELOS
AGREGADOS E DESAGREGADOS**

Dissertação apresentada à Escola de Economia de São Paulo da Fundação Getúlio Vargas, como requisito para obtenção do título de Mestre em Economia

Campo de conhecimento: Macroeconometria

Orientador: Prof. Dr. Emerson Fernandes Marçal

SÃO PAULO

2016

Nishida, Rodrigo.

Comparação de previsões para a produção industrial brasileira considerando efeitos calendário e modelos agregados e desagregados / Rodrigo Nishida. - 2016. 50 f.

Orientador: Emerson Fernandes Marçal

Dissertação (mestrado) - Escola de Economia de São Paulo.

1. Produtividade industrial. 2. Previsão econômica. 3. Modelos econométricos. I. Marçal, Emerson Fernandes. II. Dissertação (mestrado) - Escola de Economia de São Paulo. III. Título.

CDU 658.5

RODRIGO NISHIDA

**COMPARAÇÃO DE PREVISÕES PARA A PRODUÇÃO INDUSTRIAL
BRASILEIRA CONSIDERANDO EFEITOS CALENDÁRIO E MODELOS
AGREGADOS E DESAGREGADOS**

Dissertação apresentada à Escola de Economia de São Paulo da Fundação Getúlio Vargas, como requisito para obtenção do título de Mestre em Economia

Campo de conhecimento: Macroeconometria

Data da aprovação:

__/__/__

Banca examinadora:

Prof. Dr. Emerson Fernandes Marçal (Orientador)
FGV-EESP

Prof. Dr. Diogo de Prince Mendonça
UNIFESP

Profª Dra. Marislei Nishijima
USP-IRI

AGRADECIMENTOS

A concretização deste trabalho não seria possível sem a contribuição de várias pessoas. Agradeço primeiramente aos meus pais por sempre proporcionarem as melhores condições possíveis em todos os sentidos. Agradeço também aos meus irmãos, por me fazerem entender melhor o mundo e aprender a dividir e compartilhar. À Tamires Duó agradeço pelo amor, carinho e compreensão em todos os momentos ao longo desta jornada, especialmente nos sábados em que não pudemos estar juntos.

Tenho enorme gratidão pelo auxílio da LCA Consultores, não somente pelo indispensável suporte financeiro, mas também pela flexibilidade de jornada em épocas de provas e outros momentos críticos, essenciais para uma boa evolução no curso. Devo agradecimentos especiais a alguns de seus economistas por inúmeras contribuições de diferentes tipos, principalmente para Francisco Pessoa, Bráulio Borges, Thovan Caetano e Bruno Campos. Deixo também meus agradecimentos a todos os colegas do mestrado que estiveram juntos nesta rica experiência.

Por fim, não poderia deixar de agradecer a todos os professores que transmitiram seus conhecimentos de forma inigualável e insubstituível desde o início do meu aprendizado, passando pela FEA-USP e finalmente na EESP-FGV. Deixo meus cumprimentos especiais ao Prof. Emerson Marçal, pela preciosa orientação desta dissertação.

RESUMO

O trabalho tem como objetivo verificar a existência e a relevância dos Efeitos Calendário em indicadores industriais. São explorados modelos univariados lineares para o indicador mensal da produção industrial brasileira e alguns de seus componentes. Inicialmente é realizada uma análise dentro da amostra valendo-se de modelos estruturais de espaço-estado e do algoritmo de seleção *Autometrics*, a qual aponta efeito significativo da maioria das variáveis relacionadas ao calendário. Em seguida, através do procedimento de Diebold-Mariano (1995) e do *Model Confidence Set*, proposto por Hansen, Lunde e Nason (2011), são realizadas comparações de previsões de modelos derivados do *Autometrics* com um dispositivo simples de Dupla Diferença para um horizonte de até 24 meses à frente. Em geral, os modelos *Autometrics* que consideram as variáveis de calendário se mostram superiores nas projeções de 1 a 2 meses adiante e superam o modelo simples em todos os horizontes. Quando se agrega os componentes de categoria de uso para formar o índice industrial total, há evidências de ganhos nas projeções de prazo mais curto.

Palavras-chave: produção industrial mensal, Efeitos Calendário, projeção, agregação, *Autometrics*, Diebold-Mariano, *Model Confidence Set*.

ABSTRACT

The work aims to verify the existence and the relevance of Calendar Effects in industrial indicators. The analysis covers linear univariate models for the Brazilian monthly industrial production index and some of its components. Initially an in-sample analysis is conducted using state space structural models and Autometrics selection algorithm, which indicates statistically significance effect of most variables related to calendar. Then, using Diebold-Mariano (1995) procedure and Model Confidence Set, developed by Hansen, Lunde e Nason (2011), out-of-sample comparisons are realized between Autometrics derived models and a simple double difference device for a forecast horizon up to 24 months ahead. In general, forecasts of the Autometrics models that consider calendar variables are superior for 1-2 steps ahead and surpass the naive model in all horizons. The aggregation of the category of use components to form the general industry indicator shows evidence of a better perform in shorter term forecasts.

Key words: monthly industrial production, Calendar Effects, forecasting, aggregation, Autometrics, Diebold-Mariano, Model Confidence Set.

LISTA DE FIGURAS

Figura 3.1 – Árvore de busca para um MGI com as variáveis ABCD	19
Figura 4.1 – Raiz do EQM: Indústria Geral	38

LISTA DE TABELAS

Tabela 3.1 – Model Confidence Set: p-valor	25
Tabela 3.2 – Pesos das categorias de uso (%)	28
Tabela 3.3 – Relação dos modelos utilizados	28
Tabela 4.1 – Modelo Estrutural: impacto das variáveis de Efeito Calendário (%)	30
Tabela 4.2 – Autometrics: impacto das variáveis de Efeito Calendário (%)	31
Tabela 4.3 – Raiz do EQM por indicador e modelo	32
Tabela 4.4 – Diebold-Mariano por indicador	33
Tabela 4.5 – Model Confidence Set com métrica de erro quadrático	35
Tabela 4.6 – Model Confidence Set com métrica de erro absoluto	36
Tabela 4.7 – Raiz do EQM: Indústria Geral	37
Tabela 4.8 – Diebold-Mariano: Indústria Geral	39
Tabela 4.9 – Model Confidence Set com métrica de erro quadrático: Indústria Geral	40
Tabela 4.10 – Model Confidence Set com métrica de erro absoluto: Indústria Geral	40

SUMÁRIO

1. INTRODUÇÃO	9
2. REVISÃO DA LITERATURA	11
2.1. EFEITOS CALENDÁRIO	11
2.2. COMPARAÇÃO DE PREVISÕES.....	13
2.3. MODELOS AGREGADOS E DESAGREGADOS	14
3. METODOLOGIA	16
3.1. MODELO DE DUPLA DIFERENÇA	16
3.2. MODELO ESTRUTURAL DE ESPAÇO-ESTADO.....	16
3.3. MODELO ARIMA	17
3.4. AUTOMETRICS	18
3.5. DIEBOLD-MARIANO	21
3.6. MODEL CONFIDENCE SET	22
3.7. DADOS.....	25
3.8. MODELOS ESTIMADOS	27
4. RESULTADOS	29
4.1. ANÁLISE DENTRO DA AMOSTRA.....	29
4.2. ANÁLISE FORA DA AMOSTRA	31
4.3. ANÁLISE FORA DA AMOSTRA COM MODELOS AGREGADOS	36
5. CONSIDERAÇÕES FINAIS	41
REFERÊNCIAS BIBLIOGRÁFICAS	43
APÊNDICES	46

1. INTRODUÇÃO

A atividade industrial há anos ocupa um papel central na discussão sobre o desenvolvimento brasileiro. Apesar da perda de peso no Produto Interno Bruto nas últimas décadas – somente desde 1996 houve recuo de 2 p.p. da participação da Indústria Total – o segmento continua relevante, uma vez que respondeu por aproximadamente 20% do PIB em 2014, de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE). Além disso, a indústria permanece como um dos setores mais dinâmicos da atividade econômica brasileira, ao reagir mais rapidamente a choques e políticas econômicas, e ter o indicador oficial mensal divulgado mais rapidamente.

Sendo assim, a análise de sua evolução é de primordial importância para o entendimento do ciclo econômico e a orientação de políticas públicas. Mas ao se observar as séries históricas mensais de produção industrial e suas aberturas surge a natural dificuldade em se distinguir a tendência e o ciclo do ruído. Um artifício sugerido pela literatura para tornar essa tarefa menos árdua é a construção de modelos econométricos que considerem os efeitos de curto prazo com sazonalidade e relacionados ao calendário, como a variação dos dias úteis entre os meses e os feriados móveis.

A argumentação é que em muitas situações não se deseja utilizar os mecanismos tradicionais de controle das distorções relacionadas ao calendário, como os ajustes sazonais ou o uso de *dummies* sazonais, ou mesmo quando eles são utilizados não explicam totalmente os distúrbios. A hipótese é que a diferença de dias úteis entre os períodos, a existência de feriados que acontecem em meses distintos dependendo do ano (no Brasil há o Carnaval, a Páscoa e Corpus Christi) e grandes eventos como a Copa do Mundo também afetam as séries temporais. O controle dos mesmos propiciaria ganhos de qualidade na estimação do passado, evitando regressões espúrias, bom como melhoraria as projeções, permitindo um melhor entendimento do ciclo econômico e instruindo mais adequadamente a formulação e o acompanhamento de políticas macroeconômicas e setoriais.

Portanto, o objetivo do presente trabalho é estimar e comparar diferentes modelos univariados para a Indústria Geral e sete de suas aberturas (Indústria Extrativa, Indústria de Transformação, Bens de Capital, Bens Intermediários, Bens de Consumo Total, Bens de Consumo Duráveis e Bens de Consumo Semi e Não Duráveis) controlando por *dummies* sazonais e testando essas outras variáveis, ora denominadas de Efeitos Calendário (EC). O uso das mesmas é feito de acordo com Harvey (1989), ou seja, são centradas na média anual.

Inicialmente, para avaliar a contribuição das variáveis relacionadas ao calendário na evolução das séries da indústria, estima-se, incorporando toda a amostra disponível, modelos a partir do mecanismo de seleção automática conhecido como *Autometrics* e modelos estruturais de espaço-estado. Como essa avaliação aponta para efeito relevante e estatisticamente significativo dos EC, posteriormente também é feita uma análise fora da amostra, valendo-se de modelos de Dupla Diferença e da modelagem via *Autometrics* com e sem os Efeitos Calendário.

Como o horizonte de projeção no qual o uso de EC traz ganhos também é objeto de discussão, busca-se fazer a comparação de modelos com projeções de um mês, dois meses, um trimestre, um semestre, nove meses, um ano e dois anos à frente. A comparação dos modelos segue as técnicas expostas por Diebold-Mariano (1995) e o *Model Confidence Set* de Hansen, Lunde e Nason (2011). De modo geral, os exercícios realizados indicam que os modelos que consideram os efeitos relacionados ao calendário se mostram superiores para projetar até dois meses à frente, não contribuindo significativamente em horizontes mais amplos.

Alguns trabalhos também discutem os ganhos de precisão em projeções de variáveis agregadas construídas a partir da ponderação das projeções de suas aberturas. Nesse sentido são feitos exercícios projetando a Indústria Geral a partir das suas aberturas de categoria de uso e também se compara os resultados com os modelos desagregados. A conclusão é que os modelos construídos a partir de suas desagregações mostram alguma superioridade em projeções de prazo mais curto.

A ordem do trabalho é apresentada adiante. Na sequência desta Introdução, na seção 2, é realizada uma discussão sobre a literatura produzida sobre os Efeitos de Calendário em séries temporais e alternativas de tratamento. Adicionalmente são revisitadas abordagens de mecanismos de comparação de previsões e trabalhos comparando projeções de séries agregadas e desagregadas. Na seção 3, apresenta-se a metodologia empregada no presente trabalho. A seguir, na seção 4, realiza-se a análise dos resultados obtidos, começando pelos modelos que utilizam toda a amostra e partindo para a comparação de previsões. Por fim, na seção 5, são apresentadas as considerações finais, limitações e possíveis extensões.

2. REVISÃO DA LITERATURA

2.1. EFEITOS CALENDÁRIO

Geralmente as séries temporais mensais sofrem oscilações abruptas provocadas pelos efeitos relacionados a variações do calendário, como a diferença entre a quantidade de finais de semana entre um mês e outro, a quantidade de determinado dia da semana no mês, a variação de dias úteis ou mesmo a existência de feriados móveis, que são celebrados em diferentes meses dependendo do ano. Isso deturba as séries e prejudica a diferenciação entre uma tendência mais duradoura e um simples ruído. Sendo assim, o controle dessas variáveis propiciaria ganhos de qualidade nas estimações.

Alguns dos primeiros trabalhos sobre o tema foram desenvolvidos por pesquisadores ligados ao U.S. Census Bureau. Um exemplo é o de Young (1965), que propõe técnicas para mensurar a importância dos ruídos relacionados à variação da quantidade de cada dia da semana em séries mensais fictícias e séries reais de vendas no varejo, produção e comércio exterior dos Estados Unidos, comparando-as com os componentes de tendência-ciclo, sazonal e irregular. O autor argumenta que o efeito do calendário é relevante para explicar as oscilações mensais em relação aos outros componentes e apresenta um método para ser incorporado ao ajuste sazonal X-11 para controlar esse efeito. Cleveland e Devlin (1982) também usam modelos estruturais e análise espectral para o tratamento dos EC com vistas a melhorar o ajustamento sazonal.

No início dos anos 1980 uma série de artigos passou a analisar os Efeitos Calendário em modelos autorregressivos integrados de média móvel (ARIMA). Liu (1980) avaliou o impacto dos efeitos de feriados móveis em modelos ARIMA, argumentando que o processo de identificação do modelo via função de autocorrelação pode ser afetado na presença desses efeitos. O autor utiliza o volume de tráfego registrado em Taiwan e o feriado móvel do Ano Novo chinês para sua demonstração e propõe uma intervenção no modelo para corrigir a série. Hillmer (1982), Cleveland e Grupe (1981) e Bell e Hillmer (1983) propõem correções exógenas ao modelo ARIMA sazonal para tratar os distúrbios relacionados à variação dos dias da semana e o feriado móvel da Páscoa, os quais afetam o correlograma. As intervenções propostas melhorariam não somente a identificação do modelo, mas também a capacidade preditiva.

Uma síntese sobre o assunto (e que inclusive é utilizada como referência metodológica neste trabalho) é realizada por Harvey (1989). O autor sugere a modelagem das variáveis de Efeito Calendário de modo que elas não afetem a tendência das séries. Assim, a construção de cada uma deve ser feita de modo a se cancelarem dentro do horizonte temporal, no caso, um ano. Dessa forma, as variáveis são construídas centradas na média anual, de forma a deixar a constante representando a tendência de longo prazo. São explicitadas alternativas de tratamento para dois tipos de deturpações relacionadas ao calendário: diferenças de ocorrência de determinado dia da semana entre os meses e os feriados móveis.

Uma abordagem mais recente utilizando dados industriais foi produzida por Thury e Zhou (2005). Os autores tratam os feriados como se fossem domingo e adicionam ao modelo ARIMA apenas um componente representado conjuntamente os efeitos de mudanças nos dias úteis e feriados móveis. Os exercícios realizados para a série de produção industrial da Áustria reforçam as distorções provocadas pela variação de dias úteis e feriados móveis na identificação dos modelos. É sugerido o tratamento destes para facilitar a identificação de modelos ARIMA, bem como a otimização de modelos estruturais. Outro trabalho utilizando dados de produção industrial foi conduzido por Flaig (2005). O autor vale-se de um Modelo de Componentes Não-Observáveis para analisar o indicador da indústria alemã e decompô-lo nos componentes de tendência, ciclo, sazonal, calendário e irregular, estimados via filtro de Kalman. São realizados oito exercícios distintos e a comparação deles via critérios de informação mostra superioridade dos modelos que consideram a variação de dias úteis, a quantidade de emendas de feriados e o efeito férias de verão. É válido ressaltar que o autor não faz distinção entre os dias úteis da semana, apenas os separa de sábados, domingos e feriados. Também há a preocupação de fazer as variáveis relacionadas ao calendário se anularem no ano. Esta abordagem é semelhante à utilizada neste trabalho.

Diversos artigos também se dedicaram a analisar os Efeitos Calendários em séries históricas de preços de ações. Um exemplo é Hansen, Lunde e Nason (2005), que buscam controlar uma ampla gama de ruídos de calendário sem comprometer o poder da estimação de detectar anomalias reais. As séries analisadas são índices da Dinamarca, França, Alemanha, Hong Kong, Itália, Japão, Noruega, Suécia, Reino Unido e Estados Unidos e os resultados confirmam a significância estatística dos EC na maioria das séries. A maioria dos trabalhos produzidos no Brasil sobre o assunto também se debruçam sobre indicadores financeiros.

2.2. COMPARAÇÃO DE PREVISÕES

Não é incomum um pesquisador estar mais interessado em entender se um modelo é eficiente em projetar o futuro do que compreender sua capacidade explicativa sobre o passado. É de conhecimento geral que a adição de variáveis em uma regressão incrementa a aderência de um modelo dentro da amostra (e.g. aumenta o R^2) ao custo de diminuir os graus de liberdade. No entanto, isso não necessariamente melhora o poder preditivo. De acordo com Enders (2010), em muitos casos até piora em função do aumento da incerteza na estimação dos parâmetros.

Como os valores futuros são desconhecidos, uma maneira de comparar a acurácia das projeções dos diversos modelos disponíveis é usar apenas uma parte da amostra para estimar os parâmetros e fazer a projeção. Isso pode ser feito recursivamente até o último ponto da amostra. Assim, é possível comparar uma série de valores projetados com os números efetivamente observados. Nesse sentido, diversas técnicas de comparação de projeções foram propostas. Provavelmente a mais simples seja a observação do erro quadrático médio (EQM) da estimativa em relação ao valor verdadeiro. Segundo Enders (2010), a razão do EQM de dois modelos segue uma distribuição F padrão desde que os erros de previsão respeitem três premissas: i) média zero e distribuição normal, ii) serialmente não correlacionados e iii) contemporaneamente não correlacionados entre si.

No entanto, dificilmente essas hipóteses são respeitadas. Granger e Newbold (1976) superam o problema da correlação contemporânea ao propor a criação de duas variáveis, uma com a soma e outra com a subtração dos erros de projeção de dois modelos. A partir disso, eles desenvolvem um teste cuja hipótese nula é a de igualdade de desempenho dos modelos e que segue uma distribuição t.

Provavelmente o trabalho mais conhecido produzido para relaxar as três premissas citadas acima seja o de Diebold e Mariano (1995). Os autores propõem outro teste para comparar dois modelos sob a hipótese nula de igualdade da acurácia, o qual também permite o uso de funções perda não quadráticas, como o erro absoluto. Harvey, Leybourne e Newbold (1997) promovem uma pequena alteração no teste para permitir um melhor tratamento em comparações com amostras pequenas, o que não configura um problema no presente estudo. Clark e West (2007) promovem um ajuste no procedimento de Diebold e Mariano para o caso em que os modelos sejam aninhados.

Os testes descritos exigem a escolha de um *benchmark* para realizar a comparação, que é realizada sempre dois a dois. Isso pode se tornar um problema quando há uma ampla gama de modelos em análise. Para contornar esse problema, Hansen, Lunde e Nason (2010) introduzem o *Model Confidence Set* (MCS), que é um mecanismo de ranqueamento do melhor modelo ou do conjunto de melhores modelos dentre toda a gama disponível, dado um determinado nível de significância. O MCS será apresentado com maior detalhamento na seção 3.6.

Thury e Witt (1998) comparam previsores para os indicadores industriais austríacos e alemães usando correções para os efeitos relacionados ao calendário. Quando se avalia o tamanho e a direção dos erros, os autores argumentam que modelos estruturais podem produzir resultados superiores aos modelos ARIMA.

Um trabalho desenvolvido recentemente comparando modelos para a produção industrial mensal brasileira é o de Rocha e Valls (2015). Usando o teste de Diebold e Mariano, os autores confrontam três tipos de modelos não lineares com um modelo autorregressivo comum e um modelo de Dupla Diferença. Em síntese, eles encontram evidências de superioridade do modelo autorregressivo sobre os demais e dos modelos não lineares sobre o de Dupla Diferença.

2.3. MODELOS AGREGADOS E DESAGREGADOS

Ao invés de simplesmente modelar e projetar o índice total, uma alternativa é estimar os diversos subcomponentes e agregá-los, por meio de determinada ponderação fixa ou estocástica, para se chegar ao indicador geral. Essa opção proporcionaria ganhos na medida em que a projeção das séries desagregadas seria capaz de capturar características intrínsecas às aberturas, as quais seriam perdidas quando se projeta apenas o indicador total. Essa opção também pode ser comparada com as demais através das técnicas expostas acima.

Tiao e Gutman (1980) desenvolvem uma medida de eficiência para modelos agregados de médias móveis estacionários, estabelecendo uma condição necessária e suficiente para que não existam ganhos na agregação. Posteriormente eles estendem os resultados para modelos autorregressivos e integrados. Lütkepohl (1984) argumenta que, se o processo gerador de todas as séries é conhecido, é preferível projetar as desagregações e

depois construir um índice total no âmbito dos modelos ARIMA. No entanto, como na prática isso não ocorre, em determinadas situações pode ser preferível projetar apenas a série agregada, dada a variabilidade de especificação dos modelos e das técnicas de estimação. As comparações realizadas com séries de consumo e investimento dos EUA sugerem superioridade do modelo construído através dos subcomponentes principalmente em horizontes mais curtos. Resultados semelhantes para essa relação inversa entre prazo e desagregação também foram encontrados por Hubrich (2005), Duarte e Rua (2007) e Carlos e Marçal (2013) em séries de inflação.

Marcellino, Stock e Watson (2003) analisaram diversos métodos de projeção de curto prazo para o PIB real, produção industrial, taxa de desemprego e inflação na Zona do Euro. Os autores concluem que em geral os modelos univariados construídos a partir das desagregações se mostram superiores, captando melhor as idiosincrasias de cada país do grupo. Hendry e Hubrich (2006), por sua vez, ponderam que nem sempre a superioridade teórica dos modelos desagregados se confirma empiricamente. Problemas na seleção dos modelos, incertezas na estimação, quebras estruturais, diferenças no horizonte de projeção, bem como erros de medida seriam os motivos. Os autores também propõem um modelo alternativo, que seria o uso dos subcomponentes como variáveis explicativas nos modelos que projetam as variáveis agregadas. Essa modelagem em geral diminuiria o erro quadrático médio em relação aos modelos agregados ou construídos a partir da soma ponderada dos componentes.

3. METODOLOGIA

3.1. MODELO DE DUPLA DIFERENÇA

Segundo Clements e Hendry (1999, 2003), dentre todos os motivos que provocam erros em projeções, as mudanças nos termos determinísticos (interceptos e tendências lineares) são a maior fonte. Dessa forma um dispositivo muito simples, o de Dupla Diferença, pode ter uma boa performance em projeções de realizações futuras (apesar do desempenho fraco em estimações dentro da amostra) na medida em que a dupla diferenciação no tempo elimina os interceptos e as tendências lineares. Por esse modelo não possuir parâmetros, é especialmente vantajoso usá-lo em séries com muitas quebras estruturais, uma vez que suas projeções não são indefinidamente afetadas por elas.

Sendo assim, este estudo vale-se do modelo de Dupla Diferença para projetar as séries industriais analisadas e comparar seus resultados com os outros modelos propostos. As projeções do modelo para séries com sazonalidade, como é caso aqui, é explicada a seguir. Seja ΔY_t a primeira diferença de uma série histórica mensal (em logaritmo). A projeção para o mês t um período à frente é $\widehat{\Delta y}_t = \Delta y_{t-12}$, ou seja, a estimativa é igual ao resultado observado doze meses antes do mês que se deseja projetar. No caso de 2 passos à frente, a projeção é $\widehat{\Delta y}_t + \widehat{\Delta y}_{t+1} = \Delta y_{t-12} + \Delta y_{t-11}$ e assim por diante para 3, 6, 9, 12 e 24 meses. Por exemplo, no caso de uma projeção para dezembro de 2014 feita 12 meses antes, o valor projetado é igual à soma dos valores da série em primeira diferença entre janeiro e dezembro de 2013.

3.2. MODELO ESTRUTURAL DE ESPAÇO-ESTADO

Uma alternativa de modelagem para o tratamento de uma série temporal é decompô-la em diversos fatores não observáveis, cada qual com características próprias e que juntos promovem a dinâmica da série observável. O objetivo do modelo estrutural de espaço-estado é exatamente esse e, em determinadas situações, esse modelo tem se mostrado superior aos

tradicionais modelos ARIMA. Outras informações e maiores detalhes podem ser encontrados em Harvey e Shephard (1993) e Commandeur e Koopman (2007).

O modelo ora utilizado decompõe as variáveis em nível nos seguintes componentes: tendência (nível e inclinação), sazonal e irregular, todos de forma estocástica. Também é utilizado um componente de ciclo na forma de um AR(2) e habilitada a detecção automática de *outliers*. O modelo inclui as cinco variáveis de calendário como regressores com o objetivo de avaliar se elas contribuem significativamente para a estimação dos componentes. Os exercícios são realizados no STAMP, disponível no pacote estatístico OxMetrics 7.

3.3. MODELO ARIMA

O modelo ARIMA, proposto por Box e Jenkins (1976), constitui um modelo univariado que tem sido amplamente utilizado no estudo de séries temporais.

Ele assume a seguinte forma básica:

$$\phi_p(B)(1 - B)^d Y_t = \theta_0 + \theta_q(B)a_t$$

em que $a_t \sim i.i.d. N(0, \sigma^2)$, $t = 1, 2, 3, \dots, n$.

Geralmente é aplicado o logaritmo neperiano na variável não estacionária Y_t para estabilizar a variância. O algarismo B denota o operador defasagem. Dessa forma, a série diferenciada $(1 - B)^d Y_t$ segue um processo estacionário autorregressivo de média móvel, no qual $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ é o operador AR estacionário e $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ é o operador MA invertível. Esse modelo é conhecido como ARIMA (p,d,q), em que os termos p , d e q representam as ordens dos componentes autorregressivo, integrado e de média móvel, respectivamente. A expansão deste modelo para captar flutuações sazonais (não é usada neste trabalho) é conhecida como SARIMA (p, d, q) (P, D, Q)_s, no qual o subscrito representa a periodicidade sazonal.

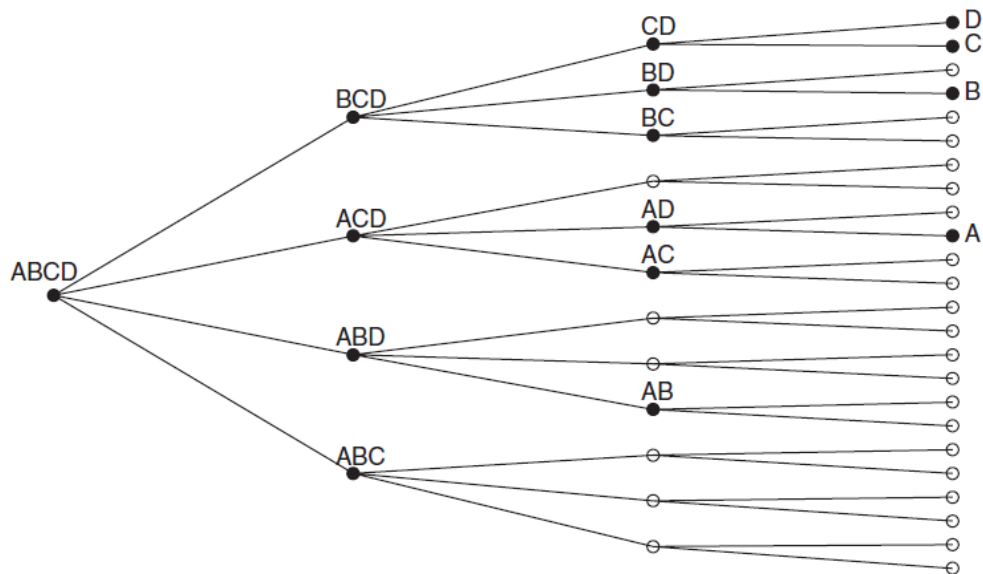
3.4. AUTOMETRICS

O algoritmo de seleção automática de modelos conhecido como *Autometrics* se insere na famosa abordagem metodológica LSE (*London School of Economics*), que preconiza o conceito de partir do geral para se chegar específico. Em se tratando da seleção de um modelo, a ideia é estipular todas as variáveis explicativas possíveis que possam ter alguma relação significativa com a variável dependente e, através de testes de especificação e diagnóstico, checar se alguns regressores podem ser excluídos sem perda de capacidade explicativa, chegando-se em um modelo ideal mais parcimonioso.

Refletindo sobre a discricionariedade de cada pesquisador ao selecionar um modelo dentro dessa abordagem e o custo envolvido, Lovell (1983) e Hoover e Perez (1999) foram pioneiros ao proporem mecanismos de seleção automática. Hendry e Krolzig (1999, 2005) desenvolveram diversas melhorias e essas evoluções serviram de base para a introdução do *Autometrics*, descrito em Doornik (2009).

Assim como os trabalhos anteriores, o *Autometrics* tem como ponto de partida a proposição, pelo pesquisador, de um Modelo Geral Irrestrito (MGI ou GUM, na sigla original), ou seja, um modelo que contemple todas as variáveis que podem ser relevantes para reproduzir o processo gerador dos dados. A partir do MGI é feita uma árvore de busca, na qual cada letra representa um regressor e cada ramo contém vários nós, cada um representando um modelo, dessa forma abrangendo toda a gama de modelos que podem ser gerados com as variáveis selecionadas. A Figura 3.1 representa um exemplo. Há vários círculos vazios em alguns nós porque a ordem das variáveis dependentes não importa e os modelos redundantes são retirados. A disposição das letras é feita em ordem crescente de significância estatística (A é a menos significativa e D a mais relevante) e o algoritmo percorre a árvore da esquerda para a direita e de cima para baixo.

Figura 3.1 – Árvore de busca para um MGI com as variáveis ABCD



Fonte: Doornik (2009).

A avaliação de todos os modelos possíveis seria muito custosa operacionalmente, por isso são utilizadas quatro regras principais de eliminação de opções. A primeira consiste em ignorar os modelos derivados de um modelo que falhou em testes de exclusão ou diagnóstico. Por exemplo, na Figura 3.1, se a variável B não puder ser removida do modelo BCD, então é possível ignorar as opções CD, D e C. Essa regra segue o p-valor principal do *Autometrics* (p_a), que consiste em um valor estipulado discricionariamente, abaixo do qual uma variável não pode ser eliminada considerando seu nível de significância.

O segundo procedimento propõe a remoção de um grupo de variáveis (usando um teste F) ao invés de somente uma variável por vez (através do teste t). O corte é feito ao mesmo nível do procedimento anterior (p_a) e o tamanho do grupo a que inicialmente se aplica a regra é definido como $p_b = \max(\frac{1}{2}p_a^{1/2}, p_a^{3/4})$. Se o grupo inicial não puder ser excluído, outro menor é testado e assim por diante. Como ilustração, no ramo BCD do exemplo anterior, se as variáveis BC foram conjuntamente insignificantes, é possível passar direto para o modelo D.

A terceira regra estipula a remoção permanente de uma variável ou de um grupo de variáveis que são altamente não significantes de toda uma linha de modelos. O p-valor desta regra (p_c) é igual a (p_b). Ainda no ramo BCD, se B for muito insignificante, apenas os modelos CD, D e C serão avaliados, ou seja, nenhum nó que contenha B.

Por fim, o quarto procedimento consiste em otimizar a varredura encurtando ou eliminando caminhos que levam a modelos terminais (i.e. que não puderam ser mais reduzidos de acordo com os critérios adotados) encontrados previamente. No exemplo, se D já foi designado como um modelo terminal e o nó ACD está em avaliação, é possível ignorar o modelo AD para avaliar diretamente A. Há duas definições desse procedimento dependendo se o MGI em análise é igual ao anterior ou não.

Ao contrário dos modelos de seleção automática citados anteriormente, no *Autometrics* os testes de diagnóstico¹ são aplicados apenas nos modelos terminais. Se determinado modelo falha em algum teste, o algoritmo percorre o caminho de volta na árvore de forma iterativa até encontrar um modelo válido. Ao final, quando possivelmente mais de um modelo terminal é encontrado, realiza-se um desempate usando algum critério de informação (SIC, AIC ou HQ, por exemplo) para avaliar qual o mais parcimonioso ou opta-se por trabalhar com uma união dos modelos finais.

Além das funções citadas anteriormente, também é possível acionar no algoritmo uma avaliação prévia de redução de defasagens das variáveis explicativas, além de um mecanismo de detecção automática de *outliers* e/ou quebras estruturais. A ideia desta última função é saturar o modelo de *dummies*, ou seja, propor uma para cada observação² e verificar quais são realmente necessárias. Mais detalhes sobre o procedimento, como o modo de fazer a regressão quando há mais variáveis do que observações, podem ser consultados em Santos, Hendry e Johansen (2008).

Do modelo ARIMA comentado acima, o *Autometrics* só foi implementado com o componente autorregressivo, embora a rigor em qualquer modelo para o qual pode ser formulada uma função de verossimilhança é possível aplicar a seleção. Portanto, todas as variáveis colocadas no mecanismo no âmbito deste trabalho foram diferenciadas, como descrito na seção 3.8. Estipulou-se um MGI com 13 defasagens para todas as aberturas da indústria. Além disso, usa-se uma constante fixa, as variáveis explicativas de Efeito Calendário e as *dummies* sazonais centradas na média (CSeasonal) para controlar a sazonalidade determinística. Também foi habilitada a redução prévia de defasagens e a

¹ Os testes realizados são: normalidade e autocorrelação dos resíduos, heteroscedasticidade (ARCH) e estabilidade (Chow).

² A *dummy* assume o valor 1 para a observação em questão e 0 para as demais.

detecção automática de *outliers*. O nível de significância escolhido foi de $p_a = 0,001$ e os modelos estimados no PcGive³, disponível no OxMetrics.

3.5. DIEBOLD-MARIANO

Uma descrição do teste de Diebold e Mariano (1995) é apresentada a seguir. Sejam dois modelos, 1 e 2, para os quais os erros da projeção para h períodos à frente são calculados subtraindo o valor projetado do valor observado, ou seja $\varepsilon_{t+h|t}^1 = y_{t+h} - y_{t+h|t}^1$ e $\varepsilon_{t+h|t}^2 = y_{t+h} - y_{t+h|t}^2$. Em seguida, escolhe-se uma função de perda (L). Neste trabalho foi selecionada uma função de perda quadrática para penalizar as projeções que ficam mais distantes dos valores observados. Duas séries são construídas com os valores das funções de perda dos erros para o período selecionado da amostra.

A hipótese nula proposta é a de que os modelos apresentam séries de desvios estatisticamente iguais contra a hipótese alternativa de que um modelo é melhor predictor do que o outro.

$$H_0: E[L(\varepsilon_{t+h|t}^1)] = E[L(\varepsilon_{t+h|t}^2)]$$

$$H_1: E[L(\varepsilon_{t+h|t}^1)] \neq E[L(\varepsilon_{t+h|t}^2)]$$

A estatística do teste de Diebold-Mariano é dada por:

$$S = \frac{\bar{d}}{(\widehat{avar}(\bar{d}))^{1/2}}$$

em que $d_t = L(\varepsilon_{t+h|t}^1) - L(\varepsilon_{t+h|t}^2)$, $\bar{d} = \frac{1}{T_0} \sum_{t=t_0}^T d_t$ e $\widehat{avar}(\bar{d})$ é uma estimativa consistente da variância assintótica de \bar{d} para a amostra selecionada. Dessa forma, a estatística segue uma distribuição t-Student.

Uma forma prática de realizar o procedimento é regredir d_t em uma constante e usar o teste t bicaudal com erro padrão robusto, como o de Newey e West (1987). Se o valor do parâmetro for estatisticamente diferente de zero, rejeitamos a hipótese nula. Neste caso, o sinal do coeficiente indicará o melhor modelo. Se for negativo, o modelo que menos erra é o

³ Ver Doornik e Hendry (2013).

primeiro e vice-versa. Além da referência original, mais detalhes sobre o procedimento podem ser consultados em Enders (2010).

3.6. MODEL CONFIDENCE SET

O *Model Confidence Set* (MCS), introduzido por Hansen, Lunde e Nason (2011), é um mecanismo de comparação de um conjunto de modelos usado principalmente (mas não somente) para avaliar a capacidade preditiva dos mesmos. O objetivo é selecionar o melhor modelo, ou conjunto de melhores modelos, dado um determinado nível de significância⁴ e sem a necessidade de se estabelecer um *benchmark*, como no teste de Diebold-Mariano, por exemplo.

Uma característica interessante do MCS é que ele considera a limitação dos dados. Uma base bastante informativa resultará na seleção de um único melhor modelo. Por outro lado, com uma amostra menos informativa, torna-se difícil distinguir os modelos, resultando na escolha de vários (ou até mesmo todos) os modelos disponíveis. Outra vantagem do MCS é que ele permite fazer reflexões sobre o nível de significância válido no sentido tradicional, qualidade não disponível no modo tradicional de reportar o p-valor em comparações dois a dois.

De forma resumida, o funcionamento do MCS consiste em aplicar um teste de equivalência e uma regra de eliminação a um conjunto de modelos competidores. Se o teste de equivalência for rejeitado, há evidências de que os modelos não são igualmente eficientes e a regra de eliminação entra em ação para eliminar o objeto com o pior desempenho. Este procedimento é repetido até o teste de equivalência não ser rejeitado e os modelos “sobreviventes” são classificados como os melhores. Há bastante semelhança entre este procedimento e aquele empregado no teste do traço para checar o número de relações de cointegração em um VAR (vetor autorregressivo). A seguir apresenta-se o funcionamento do MCS de maneira mais formal. Outros detalhes podem ser verificados na referência supracitada nesta seção.

⁴ O(s) melhor(es) modelo(s) são escolhidos com certa probabilidade no mesmo sentido que um intervalo de confiança delimitado para uma inferência qualquer contém um parâmetro populacional.

Seja um conjunto \mathcal{M}^0 que contenha um número finito de objetos $i = 1, 2, \dots, m_0$. Cada objeto é avaliado nos períodos da amostra $t = 1, 2, \dots, n$ através de uma função perda associada $L_{i,t}$. Como exemplo, para a projeção de $\hat{Y}_{i,t}$ de Y_t em termos da função de perda L , é definido $L_{i,t} = L(Y_t, \hat{Y}_{i,t})$. Com a definição da performance relativa das variáveis $d_{ij,t} = L_{i,t} - L_{j,t}$ para todo $i, j \in \mathcal{M}^0$, é possível estipular o conjunto dos objetos superiores: $\mathcal{M}^* \equiv \{i \in \mathcal{M}^0 : E(d_{ij,t}) \leq 0 \text{ para todo } j \in \mathcal{M}^0\}$.

O objetivo do MCS, que é determinar \mathcal{M}^* , é feito através de uma sequência de testes de significância, nos quais os objetos estatisticamente inferiores aos outros elementos de \mathcal{M}^0 são eliminados. As hipóteses nula e alternativa do teste são:

$$H_{0,\mathcal{M}}: E(d_{ij,t}) = 0 \text{ para todo } i, j \in \mathcal{M}$$

$$H_{A,\mathcal{M}}: E(d_{ij,t}) \neq 0 \text{ para todo } i, j \in \mathcal{M}$$

em que $\mathcal{M} \subset \mathcal{M}^0$.

Como mencionado anteriormente, o mecanismo é baseado em um teste de equivalência ($\delta_{\mathcal{M}}$) e uma regra de eliminação ($e_{\mathcal{M}}$). O primeiro testa as hipóteses acima e em caso de rejeição da hipótese nula, a regra de eliminação é acionada para descartar o objeto com desempenho inferior. O procedimento do MCS em etapas é:

Passo 0. Definir o conjunto $\mathcal{M} = \mathcal{M}^0$.

Passo 1. Testar $H_{0,\mathcal{M}}$ usando $\delta_{\mathcal{M}}$ e o nível de significância discricionário α .

Passo 2. Se $H_{0,\mathcal{M}}$ não for rejeitado, definir $\hat{\mathcal{M}}_{1-\alpha}^*$. Caso contrário, usar $e_{\mathcal{M}}$ para eliminar o objeto inferior de \mathcal{M} e repetir o procedimento desde o Passo 1.

O conjunto $\hat{\mathcal{M}}_{1-\alpha}^*$ relaciona os objetos sobreviventes ao teste e é denominado *Model Confidence Set*. Usando o mesmo α em todos os testes, é possível provar que $\lim_{n \rightarrow \infty} P(\mathcal{M}^* \subset \hat{\mathcal{M}}_{1-\alpha}^*) \geq 1 - \alpha$. No caso de apenas um modelo ser classificado como superior, $\lim_{n \rightarrow \infty} P(\mathcal{M}^* = \hat{\mathcal{M}}_{1-\alpha}^*) = 1$.

A implementação do MCS é feita através de uma técnica de *bootstrap*, baseada em White (2000). Essa abordagem é utilizada por sua praticidade e por ser conveniente quando há muitos modelos competidores. A aplicação é assegurada pela premissa de que $\{d_{ij,t}\}_{i,j \in \mathcal{M}^0}$ seja estritamente estacionário com $var(d_{ij,t}) > 0$, sendo permitido assim funções de perda $L_{i,t}$ não estacionárias e com quebras estruturais.

Especialmente quando o número de modelos disponíveis, m , é grande em relação ao tamanho da amostra, n , é conveniente usar testes estatísticos baseados em múltiplos testes t , que não seguem distribuições convencionais. Dois deles são apresentados abaixo.

Sejam $\bar{d}_{ij} \equiv n^{-1} \sum_{t=1}^n d_{ij,t}$ e $\bar{d}_i \equiv m^{-1} \sum_{j \in \mathcal{M}} \bar{d}_{ij}$ as funções de perda relativas da amostra. A primeira expressão mede o diferencial de perda entre os modelos i e j dentro da amostra. A segunda é a perda média do modelo i em relação à média dos modelos em \mathcal{M} . Dessa forma duas estatísticas t são propostas:

$$t_{ij} = \frac{\bar{d}_{ij}}{\sqrt{\widehat{\text{var}}(\bar{d}_{ij})}} \quad \text{e} \quad t_i = \frac{\bar{d}_i}{\sqrt{\widehat{\text{var}}(\bar{d}_i)}} \quad \text{para } i, j \in \mathcal{M}.$$

As hipóteses nulas são, respectivamente, $H_{ij}: E(\bar{d}_{ij}) = 0$ e $H_i: E(\bar{d}_i) = 0$. As estatísticas $T_{R,\mathcal{M}} \equiv \max_{i,j \in \mathcal{M}} |t_{ij}|$ e $T_{max,\mathcal{M}} \equiv \max_{i \in \mathcal{M}} t_i$ podem ser usadas para verificar as hipóteses nulas do teste de equivalência, $\delta_{\mathcal{M}}$. Pela ordem, elas se referem à amplitude e ao desvio máximo. É válido ressaltar que a distribuição assintótica dessas estatísticas não é convencional em decorrência das perturbações relacionadas às estimações dos parâmetros sob as hipóteses nula e alternativa. Essa questão é contornada com a aplicação dos métodos de *bootstrap*.

Se a estatística $T_{R,\mathcal{M}}$ for aplicada no teste de equivalência, a regra de eliminação será $e_{R,\mathcal{M}} = \arg \max_{i \in \mathcal{M}} \sup_{j \in \mathcal{M}} t_{ij}$. Caso a estatística seja $T_{max,\mathcal{M}}$, a regra de eliminação será $e_{R,\mathcal{M}} = \arg \max_{i \in \mathcal{M}} t_i$. Isso é esperado, pois a regra de eliminação retira o modelo que mais contribui para a estatística do teste. Dentre todos os modelos de \mathcal{M} , o eliminado é aquele que possui a maior perda padronizada relativa à média dos outros modelos.

A aplicação do MCS pode resultar em mais de um modelo no conjunto final e isso pode ser verificado através do p-valor do mecanismo atribuído a cada modelo. Sua interpretação é semelhante à de um p-valor tradicional, em que o intervalo de confiança $(1 - \alpha)$ contém o verdadeiro parâmetro com probabilidade não inferior a $1 - \alpha$. O p-valor do MCS não deve ser tomado como a probabilidade de um determinado modelo constituir o melhor modelo.

Seja m_0 o número de elementos em \mathcal{M}^0 e $\mathcal{M}_i = \{e_{\mathcal{M}_i}, \dots, e_{\mathcal{M}_{m_0}}\}$. Os elementos deste grupo são colocados em ordem de eliminação. Assim $e_{\mathcal{M}^0} = e_{\mathcal{M}_1}$ é o primeiro objeto eliminado se a hipótese nula H_{0,\mathcal{M}_1} for rejeitada, $e_{\mathcal{M}_2}$ é o segundo elemento e assim por diante.

Seja $P_{H_{0,\mathcal{M}_i}}$ o p-valor associado à hipótese nula H_{0,\mathcal{M}_i} , com a convenção de que $P_{H_{0,\mathcal{M}_{m_0}}} \equiv 1$. O p-valor do MCS é definido como $\hat{p}_{e_{\mathcal{M}_j}} \equiv \max_{i \leq j} P_{H_{0,\mathcal{M}_i}}$ para o modelo $e_{\mathcal{M}_j} \in \mathcal{M}^0$.

Com os elementos de \mathcal{M}^0 indexados por $i = 1, \dots, m_0$, o p-valor do MCS, \hat{p}_i , é tal que $i \in \hat{\mathcal{M}}_{1-\alpha}^*$ se, e somente se $\hat{p}_i \geq \alpha$ para qualquer $i \in \mathcal{M}^0$. A Tabela 3.1 abaixo ilustra o cálculo do p-valor da hipótese nula e do MCS para cada rodada de eliminação.

Tabela 3.1 – Model Confidence Set: p-valor

Regra de eliminação $e_{\mathcal{M}_i}$	P-valor da hipótese nula H_{0,\mathcal{M}_i}	P-valor do MCS $\hat{p}_{e_{\mathcal{M}_j}} \equiv \max_{i \leq j} P_{H_{0,\mathcal{M}_i}}$
1	0,01	0,01
2	0,04	0,04
3	0,02	0,04
4	0,03	0,04
5	0,07	0,07
6	0,04	0,07
7	0,11	0,11
8	0,25	0,25
⋮	⋮	⋮
$e_{\mathcal{M}(m_0)}$	1,00	1,00

Fonte: Hansen, Lunde e Nason (2011).

Nas comparações feitas via MCS neste trabalho foram utilizadas duas funções de perda (L) dos desvios. Como no teste de Diebold-Mariano, o erro quadrático $L(\varepsilon_{t+h|t}^i) = (y_{t+h} - \hat{y}_{t+h|t}^i)^2$ e também o erro absoluto $L(\varepsilon_{t+h|t}^i) = |y_{t+h} - \hat{y}_{t+h|t}^i|$, em que i representa o modelo em questão, y_{t+h} é a variável observada em h passos à frente e $\hat{y}_{t+h|t}^i$ é a projeção do modelo i para h passos à frente feita no período t . O *Model Confidence Set* foi empregado através do pacote MulCom (*Multiple Comparison*) disponível para o OxMetrics 7.

3.7. DADOS

O presente trabalho vale-se dos dados da Pesquisa Industrial Mensal – Produção Física (PIM-PF) do IBGE. São analisadas as séries do número-índice (média 2012=100) da Indústria

Geral e sete de suas aberturas: Indústria Extrativa, Indústria de Transformação, Bens de Capital, Bens Intermediários, Bens de Consumo Total, Bens de Consumo Duráveis e Bens de Consumo Semi e Não Duráveis. As cinco últimas aberturas são conhecidas como categorias de uso.

Após uma revisão metodológica em maio de 2014, feita com o intuito de atualizar a lista de produtos e informantes, além da estrutura setorial e sua ponderação, o IBGE disponibilizou as séries somente a partir de janeiro de 2002. Mas a pesquisa teve início em meados da década de 1970 e, com vistas a alongar as séries, foi feito um encadeamento das séries atuais com o histórico mais antigo a partir da variação marginal. Portanto, as séries analisadas vão de janeiro de 1975 a junho de 2015. Embora as séries disponibilizadas atualmente não sejam perfeitamente compatíveis com o histórico mais antigo, o encadeamento permite a obtenção de uma desejável longa série de observações (486 ao todo) para a Indústria Geral e todos os subcomponentes.

As variáveis de Efeito Calendário utilizadas são: a quantidade de dias úteis por mês, os feriados móveis brasileiros (Carnaval, Páscoa e Corpus Christi)⁵ e o campeonato mundial de futebol. Como mencionado anteriormente, todas essas variáveis são manipuladas de forma a estarem centradas na média anual, seguindo o sugerido por Harvey (1989).

A série mensal de dias úteis foi retirada do portal Ipeadata e modificada de forma a também excluir a segunda-feira de Carnaval da contagem. Isso porque geralmente uma grande quantidade de indústrias não funciona neste dia, emendando com a terça-feira seguinte, que é feriado nacional. Não há diferenciação entre a variação da quantidade dos dias da semana entre os meses, como muitos trabalhos citados acima fizeram. Avalia-se que em dados industriais essa separação é menos relevante, uma vez que não deve haver grande variação da produção entre segunda e sexta-feira, como possivelmente ocorre em séries de vendas no varejo ou de retorno de ações, por exemplo.

Os feriados móveis são chamados dessa forma porque ocorrem em meses distintos dependendo do ano. No Brasil, o Carnaval pode ser celebrado em fevereiro ou março, a Páscoa em março ou abril e Corpus Christi em maio ou junho. Essas mudanças provocam ruídos nas séries temporais nem sempre considerados em análises e projeções. A Copa do Mundo é outro evento com apelo entre os brasileiros e que geralmente é apontada como

⁵ A rigor o Carnaval e Corpus Christi não são feriados nacionais, mas sim pontos facultativos. Essas datas foram tratadas como feriados porque na prática boa parte das indústrias não funciona. O feriado de Páscoa se refere à sexta-feira imediatamente anterior, conhecida como Sexta-feira Santa ou Paixão de Cristo.

potencial foco de ruído em índices de atividade econômica. A competição é disputada quadrienalmente em junho e/ou julho.

3.8. MODELOS ESTIMADOS

Todas as variáveis dependentes utilizadas foram transformadas em logaritmos naturais (LOG). Nos modelos estimados via *Autometrics* utilizou-se as séries em primeira diferença (DLOG), uma vez que elas apresentavam coeficiente de integração. Os gráficos das séries industriais em nível, LOG e DLOG podem ser visualizados no Apêndice A. Os resultados do teste de raiz unitária ADF (Augmented Dickey-Fuller) mostram evidências de que todas as séries em primeira diferença são estacionárias. Os valores podem ser checados no apêndice B.

Inicialmente, para avaliar a contribuição das variáveis relacionadas ao calendário na evolução das séries da indústria, estima-se, incorporando toda a amostra disponível, dois tipos de modelos. O primeiro é um modelo estrutural e o segundo é estimado usando o *Autometrics*. Em ambos as variáveis de EC são colocadas como regressores para avaliar as respectivas significâncias estatísticas. Em seguida, é realizada a análise fora da amostra, ou seja, avaliando os modelos em relação à eficiência preditiva. São comparados os modelos de Dupla Diferença e *Autometrics* sem e com Efeitos Calendário no MGI. Os horizontes de projeção avaliados são 1, 3, 6, 9, 12 e 24 meses. Decidiu-se realizar as previsões a partir de jul/2000 até o final da amostra (jun/2015), para possibilitar a comparação com os valores observados com quantidade significativa de observações. É válido ressaltar que dependendo do horizonte de projeção, a quantidade de observações disponíveis varia. Para um mês à frente há 180 observações, para 2 meses há 179, e assim por diante até 24 períodos com 157 observações.

Como também há projeções para algumas aberturas da produção industrial, é possível agrupá-las, utilizando seus respectivos pesos, para formar uma nova projeção para a Indústria Geral. Isso é realizado a partir das aberturas de categoria de uso: Bens de Capital, Bens Intermediários, Bens de Consumo Duráveis e Bens de Consumo Semi e Não Duráveis. As duas últimas somadas resultam em Bens de Consumo Total, série que não é utilizada. O IBGE utiliza uma estrutura de ponderação fixa na PIM-PF. Entre as categorias de uso há uma abertura (com peso residual) denominada Bens Não Especificados Anteriormente, cuja série tem início apenas em janeiro de 2012. Portanto, essa abertura não é utilizada e seu peso foi

redistribuído entre as outras categorias de acordo com as representatividades. A Tabela 3.2 mostra uma relação dos pesos.

Tabela 3.2 – Pesos das categorias de uso (%)

Peso	Bens de Capital	Bens Intermediários	Bens de Consumo Total	Bens de Consumo Duráveis	Bens de Consumo Semi e Não Duráveis	Bens Não Especificados Anteriormente	Total
Original	8,32	59,72	30,61	7,35	23,26	1,36	100,00
Redistribuído	8,43	60,54	31,03	7,45	23,58	-	100,00

Fonte: IBGE.

A Tabela 3.3 relaciona os modelos utilizados, suas descrições e códigos correspondentes para facilitar a interpretação.

Tabela 3.3 – Relação dos modelos utilizados

Nome	Técnica	Descrição
DDF	Dupla Diferença	Projeção direta
EEE	Modelo Estrutural	Modelo com Efeito Calendário
AUT_SEC	Autometrics	Modelo sem Efeito Calendário
AUT_CEC	Autometrics	Modelo com Efeito Calendário
AUT_SEC_AG	Autometrics	Modelo construído a partir das desagregações sem Efeito Calendário
AUT_CEC_AG	Autometrics	Modelo construído a partir das desagregações com Efeito Calendário

Fonte: Elaboração própria.

4. RESULTADOS

Descritos o arcabouço metodológico, os dados e a ponderação utilizada, parte-se para a análise dos resultados. Inicialmente é realizada uma análise dentro da amostra e em seguida a comparação dos previsores. Ao final também são avaliados modelos para a Indústria Geral calculados a partir da soma ponderada das categorias de uso.

4.1. ANÁLISE DENTRO DA AMOSTRA

A Tabela 4.1 abaixo mostra o impacto e a relevância estatística das variáveis explicativas de Efeito Calendário nas estimações do modelo estrutural de espaço-estado usando toda a amostra disponível. A tabela indica claramente a elevada importância que este modelo atribui para as variáveis relacionadas ao calendário. A quantidade de dias úteis aparece com significância em todas as séries analisadas, com a menor relevância na Indústria Extrativa e a maior em Bens de Consumo Duráveis. Nesta última, a presença de um dia útil a mais no mês em relação à média anual em geral leva a uma produção 3,5% maior. Os feriados móveis de Carnaval e Páscoa estão presentes na maioria dos indicadores, ao passo que Corpus Christi é considerado relevante apenas em três séries. A variável de Copa do Mundo não aparece apenas no modelo da Indústria Extrativa e de Bens Intermediários. É notável como a presença do Carnaval e da Copa do Mundo reduz em 4,9% e 5,2%, respectivamente, a produção mensal da categoria de Bens de Consumo Duráveis.

Tabela 4.1 – Modelo Estrutural: impacto das variáveis de Efeito Calendário (%)

Indicador	Dias Úteis	Carnaval	Páscoa	Corpus Christi	Copa do Mundo
Indústria Geral	1,6 ***	-1,1 ***	-1,6 ***	0,3	-1,9 ***
Indústria Extrativa	0,3 **	-0,5	-0,6	0,0	-0,7
Indústria de Transformação	1,7 ***	-1,2 ***	-1,7 ***	0,3	-1,9 ***
Bens de Capital	2,7 ***	-2,6 ***	-2,4 ***	-1,6 **	-3,3 ***
Bens Intermediários	1,1 ***	-0,3	-1,4 ***	0,8 ***	-0,9
Bens de Consumo Total	2,2 ***	-1,4 ***	-2,1 ***	0,1	-2,2 ***
Bens de Consumo Duráveis	3,5 ***	-4,9 ***	-1,0	-1,9 **	-5,2 ***
Bens de Consumo Semi e Não Duráveis	1,9 ***	-0,7	-1,7 ***	0,4	-1,6 **

Fonte: Elaboração própria.

Nota: Três asteriscos (***) indicam significância a 1%, dois asteriscos (**) representam significância a 5% e um asterisco (*) aponta significância a 10%.

A Tabela 4.2 mostra em quais indicadores industriais as variáveis de calendário aparecem no modelo final selecionado pelo *Autometrics* com p-valor de 0,1% e os impactos sobre os indicadores de produção. Da mesma maneira que antes todos os 486 meses de amostra são utilizados. Neste caso, as séries de EC são consideradas relevantes para menos indicadores. Dias úteis e Carnaval continuam presentes nos modelos da maioria das séries e geralmente produzem maiores perturbações do que o verificado no modelo estrutural. O feriado de Páscoa aparece em quatro dos oito modelos finais. As variáveis de Corpus Christi e Copa do Mundo não são consideradas em nenhuma das aberturas.

É interessante notar, também, que nenhuma variável de Efeito Calendário aparece no modelo final da Indústria Extrativa. Este é um resultado de certa forma esperado, pois boa parte da produção deste segmento não é alterada em finais de semana ou feriados. A extração de petróleo e gás, por exemplo, é feita de forma contínua, sem relação com o calendário de dias úteis.

Tabela 4.2 – Autometrics: impacto das variáveis de Efeito Calendário (%)

Indicador	Dias Úteis	Carnaval	Páscoa	Corpus Christi	Copa do Mundo
Indústria Geral	1,8	-3,7	-3,4	–	–
Indústria Extrativa	–	–	–	–	–
Indústria de Transformação	1,9	-3,5	-3,3	–	–
Bens de Capital	3,5	-4,5	–	–	–
Bens Intermediários	1,6	–	–	–	–
Bens de Consumo Total	2,8	-5,0	-3,9	–	–
Bens de Consumo Duráveis	4,0	-10,7	–	–	–
Bens de Consumo Semi e Não Duráveis	2,2	-3,2	-4,6	–	–

Fonte: Elaboração própria.

Nota: Resultados apenas para as variáveis selecionadas para o modelo final com $p_\alpha = 0,001$. O travessão (–) indica as variáveis excluídas pelo mecanismo de seleção.

É válido ponderar que o p-valor usado no *Autometrics* é bastante rigoroso. Desta forma, as variáveis remanescentes são claramente importantes. Com algum relaxamento, provavelmente mais variáveis de calendário seriam incluídas no modelo, assim como na modelagem de espaço-estado. Também é importante ressaltar que em quase todas as simulações realizadas os regressores de EC estatisticamente significantes apresentam os sinais esperados: quantidade de dias úteis com sinal positivo e Carnaval, Páscoa, Corpus Christi e Copa do Mundo com o sinal negativo. A exceção ficou por conta do feriado de Corpus Christi no modelo estrutural para Bens Intermediários.

4.2. ANÁLISE FORA DA AMOSTRA

Em geral os exercícios realizados acima sugerem que as variáveis de Efeito Calendário desempenham papel relevante nas estimações dentro da amostra, melhorando a aderência dos modelos aos dados. Entretanto, isso não é garantia de que essas variáveis também contribuem para melhorar a capacidade preditiva dos modelos.

Para avaliar a validade de se fazer projeções controlando os modelos pelas variáveis de EC, inicialmente são comparadas as raízes dos Erros Quadráticos Médios das projeções de três tipos de modelos para todas as aberturas. A Tabela 4.3 apresenta esses dados.

Tabela 4.3 – Raiz do EQM por indicador e modelo

Raiz do Erro Quadrático Médio								
Indicador	Modelo	Horizonte de projeção (meses)						
		1	2	3	6	9	12	24
Indústria Geral	DDF	0,0405	0,0461	0,0519	0,0759	0,0919	0,1038	0,1051
	AUT_SEC	0,0303	0,0372	0,0422	0,0558	0,0634	0,0661	0,0750
	AUT_CEC	0,0252	0,0350	0,0430	0,0591	0,0665	0,0672	0,0722
Indústria Extrativa	DDF	0,0469	0,0616	0,0755	0,0988	0,1151	0,1323	0,1314
	AUT_SEC	0,0361	0,0501	0,0640	0,0831	0,0848	0,0851	0,1054
	AUT_CEC	0,0357	0,0496	0,0624	0,0813	0,0833	0,0827	0,0999
Indústria de Transformação	DDF	0,0430	0,0476	0,0530	0,0775	0,0938	0,1062	0,1073
	AUT_SEC	0,0323	0,0385	0,0437	0,0568	0,0646	0,0677	0,0759
	AUT_CEC	0,0260	0,0360	0,0447	0,0616	0,0712	0,0736	0,0816
Bens de Capital	DDF	0,0900	0,1012	0,1110	0,1663	0,2041	0,2313	0,2342
	AUT_SEC	0,0701	0,0807	0,0897	0,1195	0,1453	0,1549	0,1854
	AUT_CEC	0,0580	0,0752	0,0886	0,1221	0,1508	0,1570	0,1823
Bens Intermediários	DDF	0,0331	0,0415	0,0514	0,0766	0,0941	0,1061	0,1076
	AUT_SEC	0,0253	0,0330	0,0392	0,0524	0,0607	0,0636	0,0710
	AUT_CEC	0,0239	0,0340	0,0426	0,0603	0,0677	0,0692	0,0713
Bens de Consumo Total	DDF	0,0542	0,0563	0,0566	0,0719	0,0810	0,0923	0,0938
	AUT_SEC	0,0381	0,0452	0,0483	0,0536	0,0592	0,0622	0,0747
	AUT_CEC	0,0301	0,0403	0,0482	0,0561	0,0637	0,0658	0,0794
Bens de Consumo Duráveis	DDF	0,1103	0,1309	0,1448	0,1791	0,2013	0,2284	0,2238
	AUT_SEC	0,0859	0,1054	0,1164	0,1381	0,1456	0,1510	0,1965
	AUT_CEC	0,0766	0,1008	0,1175	0,1411	0,1496	0,1484	0,1875
Bens de Consumo Semi e Não Duráveis	DDF	0,0456	0,0457	0,0433	0,0533	0,0598	0,0685	0,0697
	AUT_SEC	0,0335	0,0391	0,0414	0,0397	0,0430	0,0451	0,0540
	AUT_CEC	0,0286	0,0366	0,0423	0,0450	0,0497	0,0480	0,0550

Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_CEC: Autometrics com Efeito Calendário.

Nota 2: Em negrito o modelo com o menor EQM por indicador e horizonte de projeção.

É notável como nos horizontes de 1 e 2 períodos em quase todas as aberturas o menor EQM é o do modelo *Autometrics* que considera as variáveis de calendário no Modelo Geral Irrestrito (AUT_CEC). A exceção fica por conta de Bens Intermediários. Para o horizonte de três meses há um certo equilíbrio entre os modelos *Autometrics* com e sem os Efeitos Calendário, entre 6 e 12 meses há domínio dos modelos sem EC e no horizonte de 24 meses volta a existir equilíbrio. Em todos os horizontes e aberturas, o modelo de Dupla Diferença apresenta os piores resultados.

Para verificar se os resultados observados acima são relevantes estatisticamente, é realizado o teste Diebold-Mariano com função de perda quadrática (Tabela 4.4). O modelo *Autometrics* com Efeitos Calendário foi escolhido como *benchmark*.

Tabela 4.4 – Diebold-Mariano por indicador

Diebold-Mariano - Benchmark Modelo Autometrics Com EC								
Indicador	Modelo	Horizonte de projeção (meses)						
		1	2	3	6	9	12	24
Indústria Geral	DDF	-1,01*** (0,216)	-0,90** (0,361)	-0,84 (0,594)	-2,26* (1,339)	-4,03** (1,876)	-6,26*** (2,304)	-5,83* (3,271)
	AUT_SEC	-0,28*** (0,071)	-0,16 (0,119)	0,07 (0,179)	0,38 (0,341)	0,41 (0,422)	0,14 (0,371)	-0,42 (0,708)
Indústria Extrativa	DDF	-0,93*** (0,265)	-1,33** (0,657)	-1,81 (1,115)	-3,16 (2,133)	-6,32** (2,676)	-10,66*** (3,304)	-7,287** (3,532)
	AUT_SEC	-0,03 (0,034)	-0,05 (0,066)	-0,20* (0,102)	-0,29* (0,174)	-0,25** (0,121)	-0,39*** (0,115)	-1,13*** (0,362)
Indústria de Transformação	DDF	-1,17*** (0,233)	-0,96*** (0,329)	-0,81 (0,519)	-2,20* (1,178)	-3,73** (1,684)	-5,86*** (2,063)	-4,85 (3,430)
	AUT_SEC	-0,37*** (0,074)	-0,18 (0,113)	0,09 (0,170)	0,57* (0,300)	0,90** (0,419)	0,84* (0,429)	0,90 (0,853)
Bens de Capital	DDF	-4,74*** (1,357)	-4,58*** (1,605)	-4,45** (1,967)	-12,76** (5,199)	-18,91** (7,723)	-28,83*** (8,833)	-21,60 (14,787)
	AUT_SEC	-1,55*** (0,307)	-0,86* (0,474)	-0,19 (0,637)	0,61 (1,249)	1,63 (1,809)	0,66 (2,070)	-1,13 (3,736)
Bens Intermediários	DDF	-0,53*** (0,157)	-0,56 (0,355)	-0,82 (0,636)	-2,24 (1,434)	-4,28* (2,257)	-6,46** (2,846)	-6,49* (3,6291)
	AUT_SEC	-0,07 (0,046)	0,07 (0,072)	0,28** (0,123)	0,89*** (0,268)	0,90*** (0,290)	0,74** (0,326)	0,04 (0,519)
Bens de Consumo Total	DDF	-2,03*** (0,342)	-1,55*** (0,347)	-0,88*** (0,320)	-2,03*** (0,606)	-2,50*** (0,838)	-4,19*** (1,150)	-2,50 (2,2128)
	AUT_SEC	-0,55*** (0,132)	-0,42** (0,165)	-0,01 (0,228)	0,27 (0,377)	0,55 (0,403)	0,47 (0,458)	0,72 (1,030)
Bens de Consumo Duráveis	DDF	-6,28*** (1,822)	-6,98** (3,025)	-7,17* (3,843)	-12,15** (5,769)	-18,14*** (6,867)	-30,14*** (10,208)	-14,90 (14,854)
	AUT_SEC	-1,51*** (0,468)	-0,95 (0,809)	0,27 (1,235)	0,85 (1,651)	1,20 (1,498)	-0,79 (1,444)	-3,44 (3,717)
Bens de Consumo Semi e Não Duráveis	DDF	-1,26*** (0,268)	-0,75*** (0,256)	-0,08 (0,205)	-0,82** (0,334)	-1,10*** (0,424)	-2,39*** (0,525)	-1,83** (0,818)
	AUT_SEC	-0,30*** (0,094)	-0,19 (0,123)	0,08 (0,146)	0,45** (0,210)	0,62*** (0,217)	0,26 (0,211)	0,11 (0,490)

Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário.

Nota 2: Três asteriscos (***) indicam significância a 1%, dois asteriscos (**) representam significância a 5% e um asterisco (*) aponta significância a 10%.

Nota 3: Todos os valores foram multiplicados por 10³ para facilitar a visualização.

De forma geral, os testes reiteram a superioridade do modelo *Autometrics* com EC sobre o modelo DDF (sinal negativo dos coeficientes) em todos os horizontes. No entanto, essa vantagem não é estatisticamente significativa no teste de Diebold-Mariano para alguns indicadores nos horizontes de 3 e 24 passos à frente. Nesse sentido a Indústria de Transformação é o maior exemplo. O teste também reforça o domínio do modelo *benchmark* sobre o modelo *Autometrics* sem EC para a projeção de 1 mês à frente, mas em geral não há vantagem nos demais horizontes. Em algumas aberturas, como na Indústria de Transformação, Bens Intermediários e Bens de Consumo Semi e Não Duráveis, há inclusive uma inversão relevante da vantagem (sinal positivo dos coeficientes).

Para avaliar como ficariam as comparações sem a necessidade de escolher um modelo como referência e também avaliar se a amostra utilizada é suficientemente informativa, parte-se para a verificação dos resultados do Model Confidence Set, inicialmente usando-se uma função de perda quadrática. Os resultados são apresentados na Tabela 4.5.

A observação da tabela realça a superioridade dos modelos formulados via *Autometrics* sobre o modelo trivial. Este último não é selecionado pelo mecanismo em quase nenhuma abertura considerando todos os horizontes de previsão. Ao contrário do teste de Diebold-Mariano, o MCS considera o modelo AUT_CEC como superior para projetar 2 passos à frente para a maioria dos indicadores industriais, além da previsão para o mês seguinte. Em consonância com o teste de *benchmark*, em geral para os demais horizontes ambos os modelos formulados via *Autometrics* compõem a seleção de melhores modelos.

É na categoria de Bens Intermediários que o modelo gerado automaticamente sem as variáveis de calendário se sai melhor. Esse resultado possivelmente ocorre porque parte importante da produção dessa abertura não é afetada por variações de dias úteis ou feriados, ocorrendo de forma contínua. Esse é o caso, por exemplo, dos produtos do refino de petróleo e da metalurgia.

Também é curioso constatar os resultados reportados para a Indústria Extrativa. Apesar do modelo *Autometrics* com EC para essa abertura ser o único a não considerar as variáveis de calendário no modelo final, como mencionado na seção 4.1, este modelo é considerado superior em todos os horizontes analisados. Avalia-se que isso ocorra porque a inclusão das variáveis independentes relacionadas ao calendário torna o Modelo Geral Irrestrito diferente daquele sem essas variáveis. Com isso, partindo de um MGI diferente, o mecanismo chega a um modelo final distinto, o qual se mostra superior aos demais.

Tabela 4.5 – Model Confidence Set com métrica de erro quadrático

Model Confidence Set e p-valor do modelos estimados								
Indicador	Modelo	Horizonte de projeção (meses)						
		1	2	3	6	9	12	24
Indústria Geral	DDF	0,00	0,02	0,10	0,01	0,00	0,00	0,03
	AUT_SEC	0,00	0,18*	1,00**	1,00**	1,00**	1,00**	0,42**
	AUT_CEC	1,00**	1,00**	0,70**	0,15*	0,20*	0,64**	1,00**
Indústria Extrativa	DDF	0,00	0,06	0,07	0,09	0,00	0,00	0,01
	AUT_SEC	0,37**	0,39**	0,07	0,09	0,03	0,00	0,00
	AUT_CEC	1,00**	1,00**	1,00**	1,00**	1,00**	1,00**	1,00**
Indústria de Transformação	DDF	0,00	0,01	0,09	0,01	0,00	0,00	0,03
	AUT_SEC	0,00	0,12*	1,00**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	1,00**	0,59**	0,02	0,01	0,01	0,15*
Bens de Capital	DDF	0,00	0,01	0,03	0,00	0,00	0,00	0,08
	AUT_SEC	0,00	0,05	0,74**	1,00**	1,00**	1,00**	0,67**
	AUT_CEC	1,00**	1,00**	1,00**	0,53**	0,22*	0,67**	1,00**
Bens Intermediários	DDF	0,00	0,07	0,06	0,01	0,00	0,00	0,02
	AUT_SEC	0,16*	1,00**	1,00**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	0,33**	0,06	0,00	0,00	0,01	0,93**
Bens de Consumo Total	DDF	0,00	0,00	0,03	0,00	0,00	0,00	0,09
	AUT_SEC	0,00	0,01	0,96**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	1,00**	1,00**	0,39**	0,10	0,18*	0,36**
Bens de Consumo Duráveis	DDF	0,00	0,02	0,07	0,02	0,00	0,00	0,39**
	AUT_SEC	0,01	0,23*	1,00**	1,00**	1,00**	0,53**	0,39**
	AUT_CEC	1,00**	1,00**	0,79**	0,54**	0,36**	1,00**	1,00**
Bens de Consumo Semi e Não Duráveis	DDF	0,00	0,01	0,72**	0,00	0,00	0,00	0,01
	AUT_SEC	0,00	0,16*	1,00**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	1,00**	0,72**	0,02	0,00	0,17*	0,78**

Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_CEC: Autometrics com Efeito Calendário.

Nota 2: Dois asteriscos (**) indicam que o modelo pertence ao MCS com 90% de probabilidade. Um asterisco (*) indica que o modelo pertence ao MCS com 75% de probabilidade.

As conclusões descritas acima não se alteram substancialmente se for considerado o erro absoluto no lugar do erro quadrático (Tabela 4.6).

Tabela 4.6 – Model Confidence Set com métrica de erro absoluto

Model Confidence Set e p-valor do modelos estimados								
Indicador	Modelo	Horizonte de projeção (meses)						
		1	2	3	6	9	12	24
Indústria Geral	DDF	0,00	0,01	0,22*	0,00	0,00	0,00	0,07
	AUT_SEC	0,00	0,30**	1,00**	1,00**	1,00**	1,00**	0,33**
	AUT_CEC	1,00**	1,00**	0,78**	0,12*	0,07	0,39**	1,00**
Indústria Extrativa	DDF	0,00	0,06	0,14*	0,18*	0,00	0,00	0,01
	AUT_SEC	0,43**	0,25*	0,04	0,26**	0,06	0,00	0,00
	AUT_CEC	1,00**	1,00**	1,00**	1,00**	1,00**	1,00**	1,00**
Indústria de Transformação	DDF	0,00	0,00	0,21*	0,00	0,00	0,00	0,07
	AUT_SEC	0,00	0,24*	1,00**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	1,00**	0,77**	0,02	0,00	0,02	0,54**
Bens de Capital	DDF	0,00	0,00	0,01	0,00	0,00	0,00	0,06
	AUT_SEC	0,00	0,07	0,45**	1,00**	1,00**	1,00**	0,12*
	AUT_CEC	1,00**	1,00**	1,00**	0,77**	0,24*	0,60**	1,00**
Bens Intermediários	DDF	0,00	0,07	0,09	0,00	0,00	0,00	0,09
	AUT_SEC	0,17*	1,00**	1,00**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	0,65**	0,12*	0,00	0,01	0,01	0,90**
Bens de Consumo Total	DDF	0,00	0,00	0,01	0,00	0,00	0,00	0,20*
	AUT_SEC	0,00	0,08	0,60**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	1,00**	1,00**	0,46**	0,04	0,09	0,78**
Bens de Consumo Duráveis	DDF	0,00	0,00	0,01	0,00	0,00	0,00	0,54**
	AUT_SEC	0,00	0,07	1,00**	1,00**	1,00**	1,00**	0,41**
	AUT_CEC	1,00**	1,00**	0,57**	0,49**	0,49**	0,96**	1,00**
Bens de Consumo Semi e Não Duráveis	DDF	0,00	0,13*	0,56**	0,00	0,00	0,00	0,01
	AUT_SEC	0,01	0,30**	1,00**	1,00**	1,00**	1,00**	1,00**
	AUT_CEC	1,00**	1,00**	0,56**	0,02	0,00	0,21*	0,57**

Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_CEC: Autometrics com Efeito Calendário.

Nota 2: Dois asteriscos (**) indicam que o modelo pertence ao MCS com 90% de probabilidade. Um asterisco (*) indica que o modelo pertence ao MCS com 75% de probabilidade.

4.3. ANÁLISE FORA DA AMOSTRA COM MODELOS AGREGADOS

De posse das estimativas para as aberturas de categoria de uso e dos pesos de cada uma, é possível construir estimativas para a Indústria Geral a partir das projeções dos componentes. Dessa maneira, outros dois modelos para o indicador industrial total são

calculados e comparados com os demais, um agregado a partir das projeções do *Autometrics* com MGI sem Efeitos Calendários (AUT_SEC_AG) e o outro considerando essas variáveis (AUT_CEC_AG). A Tabela 4.7 apresenta os valores da raiz do EQM para todos os modelos.

Tabela 4.7 – Raiz do EQM: Indústria Geral

Indicador	Horizonte de projeção (meses)						
	1	2	3	6	9	12	24
DDF	0,04055	0,04607	0,05191	0,07588	0,09194	0,10378	0,10507
AUT_SEC	0,03028	0,03715	0,04225	0,05578	0,06341	0,06611	0,07503
AUT_CEC	0,02515	0,03497	0,04301	0,05910	0,06653	0,06717	0,07215
AUT_SEC_AG	0,02869	0,03503	0,03957	0,05154	0,06101	0,06502	0,07476
AUT_CEC_AG	0,02462	0,03504	0,04302	0,05881	0,06743	0,06894	0,07395

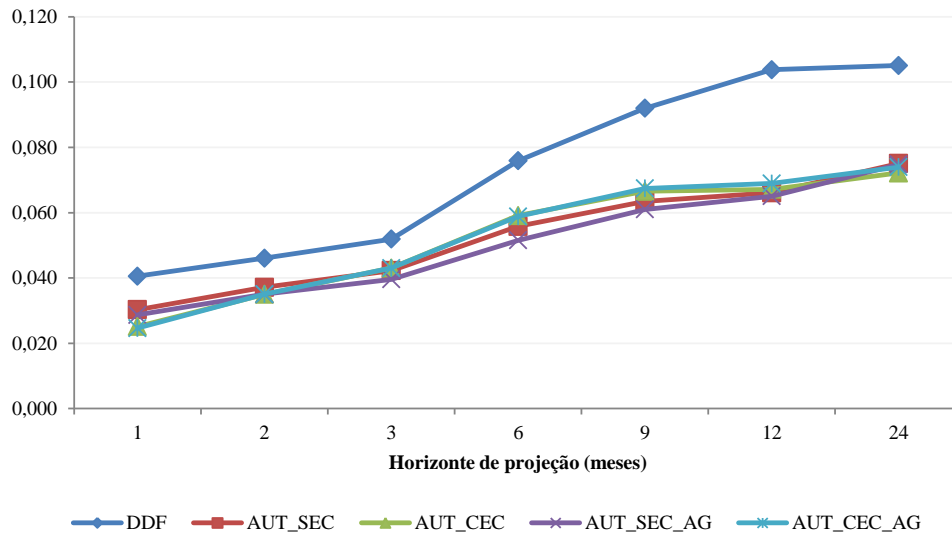
Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_CEC: Autometrics com Efeito Calendário; AUT_SEC_AG: Autometrics sem Efeito Calendário Agregado; AUT_CEC_AG: Autometrics com Efeito Calendário Agregado.

Nota 2: Em negrito o modelo com o menor EQM por horizonte de projeção.

O modelo *Autometrics* agregado considerando EC apresenta o menor EQM apenas para a projeção de 1 período à frente e praticamente empata com outros dois modelos para 2 passos adiante. Depois desse horizonte, o modelo *Autometrics* agregado sem EC apresenta os menores valores, perdendo a vantagem somente nas estimativas de 24 meses à frente. No entanto, há certo equilíbrio entre todos os modelos *Autometrics* e a clara vantagem deles sobre o modelo mais simples. Isso é mais facilmente observado na Figura 4.1.

Figura 4.1 – Raiz do EQM: Indústria Geral



Fonte: Elaboração própria.

Nota: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_CEC: Autometrics com Efeito Calendário; AUT_SEC_AG: Autometrics sem Efeito Calendário Agregado; AUT_CEC_AG: Autometrics com Efeito Calendário Agregado.

No teste de Diebold-Mariano, com função de perda quadrática, manteve-se o modelo *Autometrics* desagregado com Efeitos Calendário (AUT_CEC) como *benchmark*. Os resultados são reportados na Tabela 4.8. O único modelo não superior à referência para projeções 1 passo à frente é aquele construído a partir dos componentes da Indústria Geral dos modelos *Autometrics* com EC, aspecto denotado pelo coeficiente positivo, embora não estatisticamente significativo. O equilíbrio entre todos os modelos do mecanismo de seleção automática permanece nos demais horizontes, com alguma vantagem do modelo agregado sem EC para 3,6 e 9 meses de projeção.

Tabela 4.8 – Diebold-Mariano: Indústria Geral

Modelo	Horizonte de projeção (meses)						
	1	2	3	6	9	12	24
DDF	-1,01*** (0,216)	-0,90** (0,361)	-0,84 (0,594)	-2,26* (1,339)	-4,03** (1,876)	-6,26*** (2,304)	-5,83* (3,271)
AUT_SEC	-0,28*** (0,071)	-0,16 (0,119)	0,07 (0,179)	0,38 (0,341)	0,41 (0,422)	0,14 (0,371)	-0,42 (0,708)
AUT_SEC_AG	-0,19*** (0,061)	-0,00 (0,098)	0,28** (0,144)	0,84*** (0,259)	0,70** (0,294)	0,28 (0,358)	-0,38 (0,630)
AUT_CEC_AG	0,03 (0,022)	-0,01 (0,048)	-0,00 (0,082)	0,03 (0,177)	-0,12 (0,137)	-0,24* (0,138)	-0,26 (0,192)

Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_SEC_AG: Autometrics sem Efeito Calendário Agregado; AUT_CEC_AG: Autometrics com Efeito Calendário Agregado.

Nota 2: Três asteriscos (***) indicam significância a 1%, dois asteriscos (**) representam significância a 5% e um asterisco (*) aponta significância a 10%.

Nota 3: Todos os valores foram multiplicados por 10^3 para facilitar a visualização.

A Tabela 4.9 reporta os resultados das comparações feitas no *Model Confidence Set* com perda quadrática. As conclusões são parecidas com o teste DM ao mostrar que o pior modelo é o de Dupla Diferença. Os demais apresentam certa similaridade, pois aparecem com frequência no grupo final. O modelo agregado com EC é um pouco melhor para projeções de 1 mês adiante e o agregado sem os efeitos de calendário mostra melhor desempenho em 6 e 9 períodos à frente. Vale notar que a maior superioridade de modelos agregados em prazos curtos também foi verificada em outros trabalhos descritos anteriormente.

Tabela 4.9 – Model Confidence Set com métrica de erro quadrático: Indústria Geral

Modelo	Horizonte de projeção (meses)						
	1	2	3	6	9	12	24
DDF	0,00	0,03	0,11*	0,01	0,00	0,00	0,06
AUT_SEC	0,00	0,12*	0,13*	0,01	0,15*	0,62**	0,68**
AUT_CEC	0,24*	1,00**	0,14*	0,00	0,01	0,62**	1,00**
AUT_SEC_AG	0,00	0,99**	1,00**	1,00**	1,00**	1,00**	0,68**
AUT_CEC_AG	1,00**	0,99**	0,14*	0,01	0,01	0,17*	0,39**

Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_CEC: Autometrics com Efeito Calendário; AUT_SEC_AG: Autometrics sem Efeito Calendário Agregado; AUT_CEC_AG: Autometrics com Efeito Calendário Agregado.

Nota 2: Dois asteriscos (**) indicam que o modelo pertence ao MCS com 90% de probabilidade. Um asterisco (*) indica que o modelo pertence ao MCS com 75% de probabilidade.

Mais uma vez os resultados não se alteram substancialmente ao substituir a função de perda quadrática pela função de perda absoluta no MCS (Tabela 4.10).

Tabela 4.10 – Model Confidence Set com métrica de erro absoluto: Indústria Geral

Modelo	Horizonte de projeção (meses)						
	1	2	3	6	9	12	24
DDF	0,00	0,00	0,07	0,00	0,00	0,00	0,15*
AUT_SEC	0,00	0,14*	0,07	0,00	0,07	0,51**	0,45**
AUT_CEC	0,25*	0,91**	0,15*	0,00	0,01	0,45**	1,00**
AUT_SEC_AG	0,00	0,91**	1,00**	1,00**	1,00**	1,00**	0,45**
AUT_CEC_AG	1,00**	1,00**	0,15*	0,00	0,01	0,12*	0,45**

Fonte: Elaboração própria.

Nota 1: DDF: Dupla Diferença; AUT_SEC: Autometrics sem Efeito Calendário; AUT_CEC: Autometrics com Efeito Calendário; AUT_SEC_AG: Autometrics sem Efeito Calendário Agregado; AUT_CEC_AG: Autometrics com Efeito Calendário Agregado.

Nota 2: Dois asteriscos (**) indicam que o modelo pertence ao MCS com 90% de probabilidade. Um asterisco (*) indica que o modelo pertence ao MCS com 75% de probabilidade.

5. CONSIDERAÇÕES FINAIS

O trabalho buscou compreender os ruídos que os chamados Efeitos Calendário, como a variação de dias úteis entre os meses, os feriados móveis e a Copa do Mundo, provocam em análises econométricas de indicadores industriais brasileiros dentro e fora da amostra. As regressões de modelos estruturais usando toda a série de dados disponível mostraram grande relevância estatística de praticamente todos os EC como variáveis explicativas. Exercícios semelhantes usando o algoritmo de seleção automática *Autometrics* indicam que o controle principalmente da quantidade de dias úteis e dos feriados móveis de Carnaval e da Páscoa aproximam melhor as séries estimadas ao processo gerador dos dados.

Em relação à capacidade preditiva, os modelos formulados via *Autometrics* que consideram as variáveis explicativas relacionadas ao calendário apresentaram os melhores desempenhos primordialmente de 1 a 2 meses à frente para a maioria das séries pesquisadas, não demonstrando vantagem estatística em previsões para períodos mais extensos. As comparações foram realizadas através do teste de Diebold-Mariano e do mecanismo de seleção *Model Confidence Set*. Avalia-se que esses resultados podem contribuir para incrementar os previsores de séries industriais de curto prazo, principalmente sem ajuste sazonal ou quando o ajustamento não considerar perfeitamente os Efeitos Calendário.

Também foram realizadas simulações com a agregação ponderada das séries de categoria de uso para formular o indicador da Indústria Geral, ao invés de projetar diretamente esta série. Da mesma forma que o uso de EC, as comparações realizadas sugerem maior eficiência preditiva do modelo agregado em prazos curtos. Esse resultado é condizente com diversos outros trabalhos considerando modelos agregados e desagregados, como Duarte e Rua (2007) e Carlos e Marçal (2013) para dados de inflação.

Uma limitação imposta ao trabalho foi o histórico curto de séries industriais mais desagregadas disponibilizadas pelo IBGE atualmente. Em decorrência de mudanças metodológicas e reclassificações dos produtos e atividades, não foi possível encadear outras séries além das utilizadas para o período analisado. Isso impediu a formulação de modelos agregados a partir de mais subcomponentes, o que poderia produzir melhores modelos. A soma da Indústria de Transformação com a Indústria Extrativa para formular o indicador industrial total tampouco foi utilizada. Isso porque a primeira abertura tem peso de aproximadamente 90% e a sua dinâmica dominaria a série final.

O trabalho elencou cinco tipos de Efeitos Calendários que se acredita serem os mais significativos para explicar alguns ruídos das séries de produção industrial mensal brasileira. No entanto, poderia ser realizada uma análise mais extensiva do efeito dessas variáveis. Em especial, uma opção seria considerar as possíveis emendas de feriados que ocorrem na terça-feira ou quinta-feira. Outra alternativa seria diferenciar a quantidade de cada dia da semana para cada mês e testar se essa abordagem é mais eficiente do que simplesmente controlar a variação de dias úteis.

As extensões possíveis também incluem aumentar a variedade de modelos em análise. O modelo de espaço-estado, por exemplo, não foi considerado nas comparações fora da amostra. Como mencionado antes, Thury e Witt (1998) argumentam que modelos estruturais podem produzir resultados superiores aos modelos ARIMA para indicadores industriais.

A análise de previsões se limitou a modelos univariados lineares. Dessa maneira, seria válido testar modelos VAR ou VECM que incluam nas regressões outras variáveis relevantes, como o PIB, a taxa de desemprego, a inflação, a taxa de juros, o índice de confiança empresarial ou indicadores coincidentes (e.g. a expedição de papelão ondulado e o fluxo pedagiado de veículos pesados). Exercícios com modelos não lineares, como *Markov-switching*, também podem ser interessantes, uma vez que no período em análise a indústria nacional sofreu os efeitos de diversos planos econômicos e atravessou períodos de crises internacionais e domésticas, com a ocorrência de diversos eventos disruptivos que justificariam o uso de quebras estruturais. É válido ponderar que Rocha e Valls (2015) não encontram evidências de superioridade de modelos não lineares sobre um autorregressivo para a previsão da produção industrial do Brasil.

Apesar das limitações e extensões possíveis, avalia-se que este trabalho contribui para o entendimento dos ruídos provocados pelos Efeitos Calendário nas séries de produção industrial brasileira, auxiliando a construção de melhores previsores e o entendimento e a formulação de políticas macroeconômicas e setoriais.

REFERÊNCIAS BIBLIOGRÁFICAS

- BELL, W. R.; HILLMER S. C. Modeling Time Series With Calendar Variation. *Journal of the American Statistical Society*, v. 78, n. 383, p. 526-534, Sep. 1983.
- BOX, G. E. P.; JENKINS, G. M. *Time Series Analysis: Forecasting and Control*. 2nd ed. San Francisco, CA: Holden-Day, 1976.
- CARLOS, T. C.; MARÇAL, E. F. *Forecasting Brazilian inflation by its aggregate and disaggregated data: a test of predictive power by forecast horizon*. São Paulo: FGV-EESP, 2013. (Textos para Discussão, n. 346/2013).
- CLARK, T.; WEST, K. Approximately Normal Tests for Equal Predictive Accuracy in Nested Models. *Journal of Econometrics*, n. 138, p. 291-311, 2007.
- CLEMENTS, M. P.; HENDRY D. F. *Forecasting Non-stationary Economic Time Series*. Cambridge, MA: MIT Press, 1999.
- CLEVELAND, W. S.; DEVLIN, S.J. Calendar Effects in Monthly Time Series: Modeling and Adjustment. *Journal of the American Statistical Association*, v. 77, p. 520-528, 1982.
- CLEVELAND, W. P.; GRUPE, M. R. *Modeling Time Series when Calendar Effects Are Present*. In: ZELLNER A. Proceedings of the Conference on Applied Time Series Analysis of Economic Data, U.S. Department of Commerce, Bureau of the Census, Washington, 1981, p. 57-67.
- COMMANDEUR, J.; KOOPMAN, S. *An Introduction to State Space Time Series Analysis*. Oxford: Oxford University Press, 2007.
- DIEBOLD, F. X.; MARIANO, R. S. Comparing Predictive Accuracy. *Journal of Business and Economic Statistics*, v. 13, 253-263, 1995.
- DOORNIK, J. A. Autometrics. In: CASTLE J.; SHEPHARD N. *The Methodology and Practice of Econometrics: A Festschrift in Honour of David F. Hendry*. New York: Oxford University Press, 2009, p. 88-121.
- DOORNIK, J. A.; HENDRY, D. F. *Empirical Econometric Modelling Using PcGive 14: Volume I*. London: Timberlake Consultants Press, 2013.
- DUARTE, C.; RUA, A. Forecasting inflation through a bottom-up approach: how bottom is bottom? *Economic Modelling*, v. 24, p. 941-953, 2007.


- ENDERS, W. *Applied Econometric Time Series*. 3rd ed. New York: Wiley, 2010.
- FLAIG, G. Time Series Properties of the German Production Index. *Allgemeines Statistisches Archiv*, v. 89, p. 419-434, 2005.
- GRANGER, C.; NEWBOLD, P. Forecasting Transformed Series. *Journal of the Royal Statistical Society*, B 38, p. 189-203, 1976.
- HANSEN, P. R., LUNDE, A., NASON, J. M. *Testing the Significance of Calendar Effects*. Working Paper, Federal Reserve Bank of Atlanta, Jan. 2005.
- HANSEN, P. R., LUNDE, A., NASON, J. M. The Model Confidence Set. *Econometrica*, v. 79, p. 453-497, Mar. 2011.
- HARVEY, A. C. *Forecasting Structural Time Series and the Kalman Filter*. Cambridge: Cambridge University Press, 1989.
- HARVEY, A. C.; SHEPHARD, N. Structural Time Series Models. *Handbook of Statistics*, v. 11, n. 10, p. 261-302, Nov. 1993.
- HARVEY, D. I.; LEYBOURNE, S. J.; NEWBOLD, P. Testing the Equality of Prediction Mean Squared Errors. *International Journal of Forecasting*, 13, p. 281-291, 1997.
- HENDRY, D. F.; CLEMENTS, M. P. Economic forecasting: Some lessons from recent research. *Economic Modelling*, v. 20, p. 301-329, Mar. 2003.
- HENDRY, D. F.; HUBRICH, K. *Forecasting Economic Aggregates by Disaggregates*. CEPR Discussion Paper No. 5485, 2006.
- HENDRY, D. F.; KROLZIG, H.-M. Improving on `Data mining reconsidered by K.D. Hoover and S.J. Perez. *The Econometrics Journal*, v. 2(2), p. 202-219, Dec. 1999.
- HENDRY, D. F.; KROLZIG, H.-M. The properties of automatic *GETS* modelling. *The Economic Journal*, v. 115(502), p. C32-C61, Mar. 2005.
- HILLMER, S.C. Forecasting Time Series with Trading Day Variation. *Journal of Forecasting*, v. 1(4), p. 385-395, Oct./Dec. 1982.
- HOOVER, K. D.; PEREZ, S. J. Data mining reconsidered: encompassing and the general-to-specific approach to specification search. *The Econometrics Journal*, v.2(2), p.167-191, 1999.
- HUBRICH, K. Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy? *International Journal of Forecasting*, v. 21(1), p. 119-136, 2005.

- LIU, L. M. Analysis of Time Series with Calendar Effects. *Management Science*, v. 26(1), p. 106-112, 1980.
- LOVELL, M. C. Data mining. *The Review of Economics and Statistics*, v. 65(1), p. 1-12, 1983.
- LÜTKEPOHL, H. Forecasting contemporaneously aggregated vector ARMA processes. *Journal of Business and Economic Statistics*, v. 2(3), p. 201-214, 1984.
- MARCELLINO, M., STOCK, J. H., & WATSON, M. W. Macroeconomic forecasting in the Euro area: Country specific versus area-wide information. *European Economic Review*, v. 47(1), p. 1-18, 2003.
- NEWBY, W. K.; WEST, K. D. A Simple, Positive Semi-definite, Heteroskedasticity and Autocorrelation Consistent Covariance Matrix. *Econometrica*, v. 55(3), p. 703-708, 1987.
- ROCHA, J. V.; VALLS PEREIRA, P. L. (2015). *Forecast Comparison With Nonlinear Methods For Brazilian Industrial Production*. São Paulo: FGV-EESP, 2015. (Textos para Discussão, n. 397/2015).
- SANTOS, C.; HENDRY, D. F.; JOHANSEN, S. Automatic selection of indicators in a fully saturated regression. *Computational Statistics*, v. 23(2), p. 317-335, 2008.
- TIAO, G.; GUTTMAN, A. Forecasting contemporaneous aggregates of multiple time series. *Journal of Econometrics*, v. 12, p. 219-230, 1980.
- YOUNG, A. *Estimating Trading-Day Variation in Monthly Economic Time Series Technical*. Paper No.12, Bureau of the Census, Washington, D. C, 1965.
- THURY, G.; WITT, S. F. Forecasting Industrial Production Using Structural Time Series Models. *Omega Int. J. Mgmt Sci*, v. 26, n. 6, p. 751-767, 1998.
- THURY, G.; ZHOU, M. Calendar Effects in Monthly Time Series Models. *Journal of Systems Science and System Engineering*. v. 14, n. 2, p. 218-230, Jun. 2005.


APÊNDICES

7.1. APÊNDICE A – Gráficos das séries industriais utilizadas


Indústria Geral




Indústria Extrativa



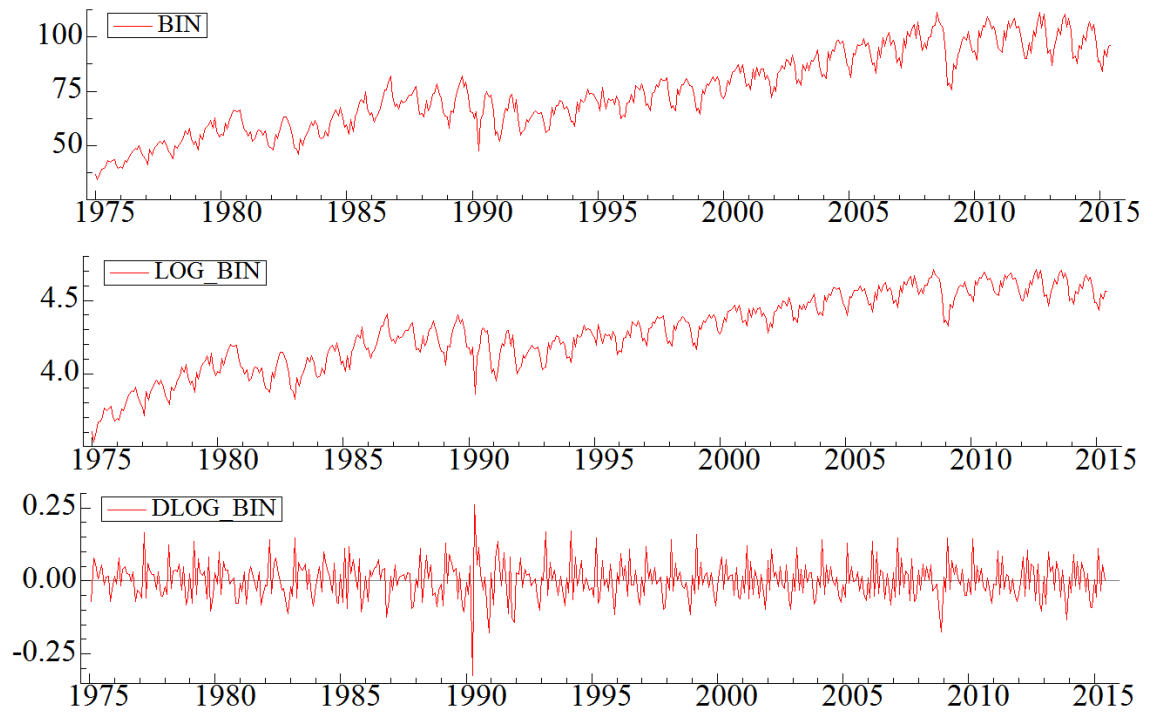
Indústria de Transformação



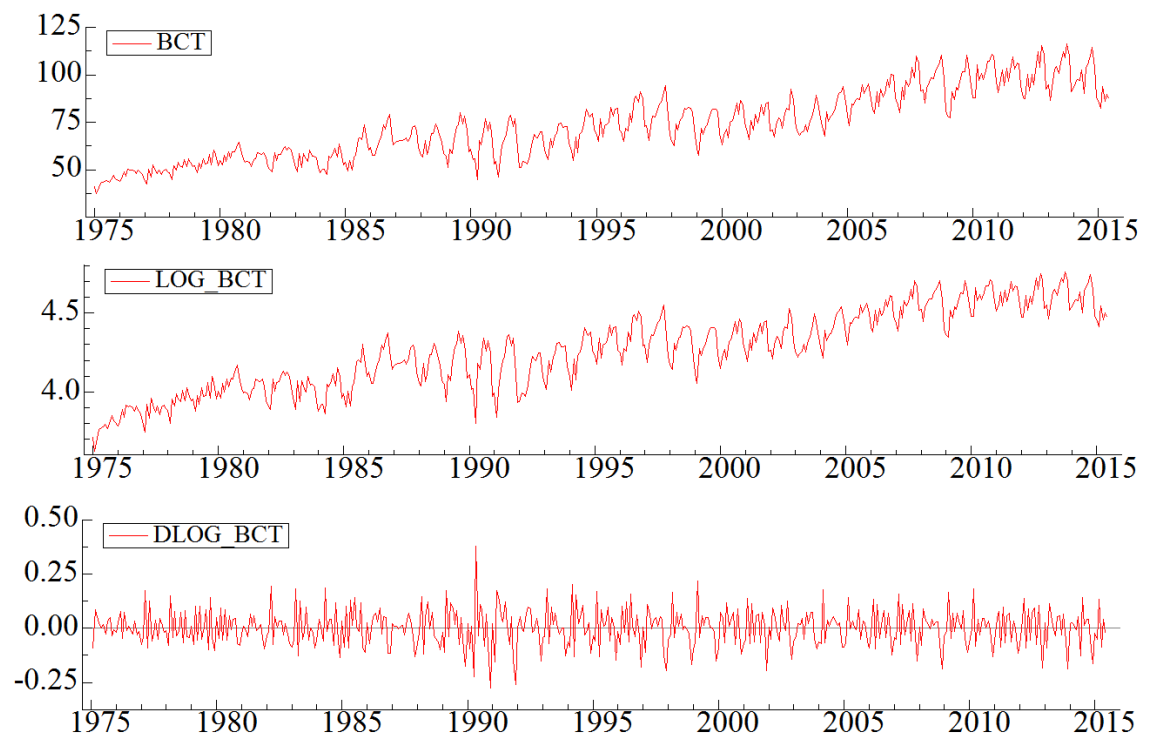
Bens de Capital




Bens Intermediários




Bens de Consumo Total



Bens de Consumo Duráveis



Bens de Consumo Semi e Não Duráveis



Fonte: IBGE. Elaboração no OxMetrics 7.

7.2. APÊNDICE B – Teste de raiz unitária

Resultados do Teste ADF (Augmented Dickey-Fuller)

Indicador	LOG		DLOG	
	Estatística t	P-valor	Estatística t	P-valor
Indústria Geral	-1,702	0,430	-7,480	0,000
Indústria Extrativa	-1,000	0,755	-7,896	0,000
Indústria de Transformação	-1,928	0,319	-7,637	0,000
Bens de Capital	-1,891	0,337	-5,135	0,000
Bens Intermediários	-2,266	0,184	-7,174	0,000
Bens de Consumo Total	-1,454	0,556	-6,085	0,000
Bens de Consumo Duráveis	-1,451	0,558	-6,675	0,000
Bens de Consumo Semi e Não Duráveis	-1,642	0,460	-6,421	0,000

Fonte: Elaboração própria.

Nota: Os testes foram realizados no EViews 9 para toda a amostra disponível com intercepto e até 17 defasagens.