

FUNDAÇÃO GETULIO VARGAS
ESCOLA DE ECONOMIA DE SÃO PAULO

DANIEL YUZO SHIMADA KAJIYA

VOLATILIDADE NO MERCADO DE AÇÕES AJUDA A PREVER A
ATIVIDADE ECONÔMICA? UMA COMPARAÇÃO ENTRE PROCESSOS
LINEARES E NÃO LINEARES PARA BRASIL E ESTADOS UNIDOS

SÃO PAULO

2021

DANIEL YUZO SHIMADA KAJIYA

VOLATILIDADE NO MERCADO DE AÇÕES AJUDA A PREVER A
ATIVIDADE ECONÔMICA? UMA COMPARAÇÃO ENTRE PROCESSOS
LINEARES E NÃO LINEARES PARA BRASIL E ESTADOS UNIDOS

Dissertação apresentada à Escola de Economia de
São Paulo da Fundação Getulio Vargas, como requi-
sito para obtenção do título de Mestre em Economia.

Área de concentração: Economia

Orientador: Prof. Dr. Emerson Fernandes Marçal

SÃO PAULO

2021

Kajiya, Daniel.

Volatilidade no mercado de ações ajuda a prever a atividade econômica? Uma comparação entre processos lineares e não lineares para Brasil e Estados Unidos / Daniel Kajiya. - 2021.

115 f.

Orientador: Emerson Fernandes Marçal.

Dissertação (mestrado profissional MPFE) – Fundação Getulio Vargas, Escola de Economia de São Paulo.

1. Ações (Finanças) - Brasil. 2. Ações (Finanças) - Estados Unidos. 3. Avaliação de ativos. 4. Mercado financeiro. I. Marçal, Emerson Fernandes. II. Dissertação (mestrado profissional MPFE) – Escola de Economia de São Paulo. III. Fundação Getulio Vargas. IV. Título.

CDU 336.76(73=81)

DANIEL YUZO SHIMADA KAJIYA

VOLATILIDADE NO MERCADO DE AÇÕES AJUDA A PREVER A
ATIVIDADE ECONÔMICA? UMA COMPARAÇÃO ENTRE PROCESSOS
LINEARES E NÃO LINEARES PARA BRASIL E ESTADOS UNIDOS

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

Área de concentração: Economia

Aprovado em: 19 / 10 / 2021

Banca Examinadora

Prof. Dr. Emerson Fernandes Marçal
FGV - EESP

Prof. Dr. Pedro Luiz Valls Pereira
FGV - EESP

Prof. Dr. Diogo de Prince Mendonça
UNIFESP - EPPEC

Dedico este trabalho à minha filha, Emily. Embora ainda muito nova, frequentemente me observava enquanto eu estudava, por vezes me imitando ao pegar um de seus livros e sentando-se ao meu lado. Espero que esta experiência tenha ajudado a plantar a semente que a ensinará sobre a importância do estudo e da busca pelo conhecimento; e que isto sirva de alicerce para uma vida longa, repleta de alegria, realizações e conquistas.

AGRADECIMENTOS

Agradeço ao meu orientador, Prof. Dr. Emerson F. Marçal; cujo tempo, dedicação, disposição e auxílio foram fundamentais na execução desta dissertação. Agradeço à minha esposa pelo apoio, companheirismo e compreensão durante os últimos dois anos em que atividades ligadas ao estudo tomaram grande parte do meu tempo; e à minha filha, pelo amor e carinho a mim demonstrados mesmo nos momentos onde estive menos presente do que desejava. Gostaria também de registrar meu apreço ao Prof. Dr. João Ricardo C. Filho pelo incentivo ao aprendizado da Ciência Econômica. Por fim, gostaria de demonstrar minha gratidão a diversos docentes das instituições: EESP-FGV e PUC-RJ; os quais, mesmo na ausência de qualquer vínculo acadêmico formal, permitiram e até incentivaram que eu frequentasse e participasse de suas aulas.

RESUMO

Este trabalho tem como foco explorar a volatilidade da bolsa de valores como potencial fonte de ganho informacional, tanto na estimação quanto na previsão das séries de produção industrial do Brasil e dos Estados Unidos. A idéia principal é a de que movimentos abruptos na volatilidade realizada dos ativos financeiros acabam ecoando na economia real e o estudo de tais movimentos poderia ser capaz de ajudar a antecipar o que aconteceria com a atividade econômica em períodos subsequentes. Além disso, este texto também procura investigar se a introdução de métodos não lineares, através da aproximação de um modelo da classe STAR é capaz de produzir resultados melhores quando comparados aos processos lineares tradicionais do tipo AR para as séries de produção industrial. A análise é pautada em três eventos recentes para a economia brasileira em que observou-se um aumento repentino da volatilidade realizada na bolsa de valores, são eles: Crise financeira de 2008, Crise econômica de 2014-2015 e a recente crise causada pelo vírus COVID-19. Para o caso norte-americano deixaremos de lado os acontecimentos de 2014-15, pois os mesmos foram particulares à economia brasileira e sem impacto aparente na economia dos Estados Unidos.

Palavras-chave: Produção Industrial, Volatilidade realizada, STAR, Diebold-Mariano, *Autometrics*, *Impulse Indicator Saturation* .

ABSTRACT

The dissertation aims to explore the stock market volatility as a potential source of relevant information when modelling and forecasting the industrial production series for Brazil and the United States. Furthermore, the study also tries to investigate whether the introduction of an approximation of a non linear estimation processes (STAR) is able to generate more robust results compared to traditional linear models such as the AR. For the brazilian economy, the analysis is focused in 3 recent episodes where the stock market experienced an unexpected surge in realized volatility: Great Financial Crisis of 2008, Brazilian economical crisis of 2014-2015 and the most recent global crisis of 2020 caused by the COVID-19 pandemic. The US economy will be analyzed for the GFC and COVID-19 episodes only since the the remaining one was just a local event particular to the brazilian economy.

Keywords: Industrial Production, Realized Volatility, STAR, Diebold-Mariano, Autometrics, Impulse Indicator Saturation.

LISTA DE ILUSTRAÇÕES

Figura 1 – <i>Autometrics - Tree search 1</i>	33
Figura 2 – <i>Autometrics - Tree search 2</i>	34
Figura 3 – Algoritmo <i>IIS – Impulse Indicator Saturation</i>	35
Figura 4 – IIS em ação - 2 períodos	36
Figura 5 – Séries de Produção Industrial em nível, log e Δ log : Brasil (azul) e Estados Unidos (vermelho)	43
Figura 6 – ACF e PACF - Séries de Produção Industrial em nível: Brasil e EUA	44
Figura 7 – ACF e PACF - Séries de Produção Industrial em primeira diferença: Brasil e EUA	44

LISTA DE TABELAS

Tabela 1 – Confirmação de estacionariedade	45
Tabela 2 – <i>Index test</i> de não linearidade	45
Tabela 3 – Modelos e seus respectivos α (por evento)	46
Tabela 4 – Brasil: GFC - Modelos lineares	47
Tabela 5 – Brasil: GFC - GERAL	47
Tabela 6 – BRASIL - GFC Variáveis relevante por modelo	48
Tabela 7 – Brasil: GFC - Modelos não-lineares	48
Tabela 8 – Brasil: Crise Dilma - Modelos lineares	49
Tabela 9 – Brasil: Crise Dilma - Modelos não-lineares	49
Tabela 10 – Brasil: Crise Dilma - GERAL	49
Tabela 11 – BRASIL - Crise Gov. Dilma - Variáveis relevante por modelo	50
Tabela 12 – Brasil: Crise COVID-19 - Modelos lineares	51
Tabela 13 – Brasil: Crise COVID-19 - Modelos não-lineares	51
Tabela 14 – Brasil: Crise COVID-19 - GERAL	51
Tabela 15 – BRASIL - Crise COVID-19 - Variáveis relevante por modelo	52
Tabela 16 – EUA: GFC - Modelos lineares	53
Tabela 17 – EUA: GFC - Modelos não-lineares	53
Tabela 18 – EUA: GFC - GERAL	53
Tabela 19 – EUA - GFC Variáveis relevante por modelo	54
Tabela 20 – EUA: Crise COVID-19 - Modelos lineares	55
Tabela 21 – EUA: Crise COVID-19 - Modelos não-lineares	55
Tabela 22 – EUA: Crise COVID-19 - GERAL	55
Tabela 23 – EUA - COVID-19 Variáveis relevante por modelo	56
Tabela 24 – Erros de previsão Brasil - GFC: JUL/07-JUN/09	57
Tabela 25 – Erros de previsão Brasil - Dilma: AGO/13-JUL/15	57
Tabela 26 – Erros de previsão Brasil - Covid-19: FEV/19-JAN/21	58
Tabela 27 – Erros de previsão EUA - GFC: JUL/07-JUN/09	58
Tabela 28 – Erros de previsão EUA - Covid-19: FEV/19-JAN/21	58
Tabela 29 – Resumo do estudo	60
Tabela 30 – <i>Index-test</i> de não linearidade - Produção Industrial Geral: 04/1986-01/2021 .	68

Tabela 31 – <i>Index-test</i> de não linearidade - Industrial Production Manufacturing: 07/1955-01/2021	69
Tabela 32 – ESTIMAÇÃO: GFC - BRA - Modelo 1	70
Tabela 33 – ESTIMAÇÃO: GFC - BRA - Modelo 2	71
Tabela 34 – ESTIMAÇÃO: GFC - BRA - Modelo 3	72
Tabela 35 – ESTIMAÇÃO: GFC - BRA - Modelo 4	73
Tabela 36 – ESTIMAÇÃO: GFC - BRA - Modelo 5	74
Tabela 37 – ESTIMAÇÃO: GFC - BRA - Modelo 6	75
Tabela 38 – ESTIMAÇÃO: DILMA - BRA - Modelo 1	76
Tabela 39 – ESTIMAÇÃO: DILMA - BRA - Modelo 2	77
Tabela 40 – ESTIMAÇÃO: DILMA - BRA - Modelo 3	78
Tabela 41 – ESTIMAÇÃO: DILMA - BRA - Modelo 4	79
Tabela 42 – ESTIMAÇÃO: DILMA - BRA - Modelo 5	80
Tabela 43 – ESTIMAÇÃO: DILMA - BRA - Modelo 6	81
Tabela 44 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 1	82
Tabela 45 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 2	83
Tabela 46 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 3	84
Tabela 47 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 4	85
Tabela 48 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 5	86
Tabela 49 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 6	87
Tabela 50 – ESTIMAÇÃO: GFC - EUA - Modelo 1	88
Tabela 51 – ESTIMAÇÃO: GFC - EUA - Modelo 2	89
Tabela 52 – ESTIMAÇÃO: GFC - EUA - Modelo 3	90
Tabela 53 – ESTIMAÇÃO: GFC - USA - Modelo 4	91
Tabela 54 – ESTIMAÇÃO: GFC - USA - Modelo 5	92
Tabela 55 – ESTIMAÇÃO: GFC - USA - Modelo 6	93
Tabela 56 – ESTIMAÇÃO: COVID-19 - EUA - Modelo 1	94
Tabela 57 – ESTIMAÇÃO: COVID-19 - EUA - Modelo 2	95
Tabela 58 – ESTIMAÇÃO: COVID-19 - EUA - Modelo 3	96
Tabela 59 – ESTIMAÇÃO: COVID-19 - USA - Modelo 4	97
Tabela 60 – ESTIMAÇÃO: COVID-19 - USA - Modelo 5	98
Tabela 61 – ESTIMAÇÃO: COVID-19 - USA - Modelo 6	99
Tabela 62 – PREVISÃO BRASIL - GFC MODELO 1: 07/2007-06/2009	100

Tabela 63 – PREVISÃO BRASIL - GFC MODELO 2: 07/2007-06/2009	100
Tabela 64 – PREVISÃO BRASIL - GFC MODELO 3: 07/2007-06/2009	101
Tabela 65 – PREVISÃO BRASIL - GFC MODELO 4: 07/2007-06/2009	101
Tabela 66 – PREVISÃO BRASIL - GFC MODELO 5: 07/2007-06/2009	102
Tabela 67 – PREVISÃO BRASIL - GFC MODELO 6: 07/2007-06/2009	102
Tabela 68 – PREVISÃO BRASIL - DILMA MODELO 1: 08/2013-07/2015	103
Tabela 69 – PREVISÃO BRASIL - DILMA MODELO 2: 08/2013-07/2015	103
Tabela 70 – PREVISÃO BRASIL - DILMA MODELO 3: 08/2013-07/2015	104
Tabela 71 – PREVISÃO BRASIL - DILMA MODELO 4: 08/2013-07/2015	104
Tabela 72 – PREVISÃO BRASIL - DILMA MODELO 5: 08/2013-07/2015	105
Tabela 73 – PREVISÃO BRASIL - DILMA MODELO 6: 08/2013-07/2015	105
Tabela 74 – PREVISÃO BRASIL - COVID-19 MODELO 1: 02/2019-01/2021	106
Tabela 75 – PREVISÃO BRASIL - COVID-19 MODELO 2: 02/2019-01/2021	106
Tabela 76 – PREVISÃO BRASIL - COVID-19 MODELO 3: 02/2019-01/2021	107
Tabela 77 – PREVISÃO BRASIL - COVID-19 MODELO 4: 02/2019-01/2021	107
Tabela 78 – PREVISÃO BRASIL - COVID-19 MODELO 5: 02/2019-01/2021	108
Tabela 79 – PREVISÃO BRASIL - COVID-19 MODELO 6: 02/2019-01/2021	108
Tabela 80 – PREVISÃO EUA - GFC MODELO 1: 07/2007-06/2009	109
Tabela 81 – PREVISÃO EUA - GFC MODELO 2: 07/2007-06/2009	109
Tabela 82 – PREVISÃO EUA - GFC MODELO 3: 07/2007-06/2009	110
Tabela 83 – PREVISÃO EUA - GFC MODELO 4: 07/2007-06/2009	110
Tabela 84 – PREVISÃO EUA - GFC MODELO 5: 07/2007-06/2009	111
Tabela 85 – PREVISÃO EUA - GFC MODELO 6: 07/2007-06/2009	111
Tabela 86 – PREVISÃO EUA - COVID-19 MODELO 1: 02/2019-01/2021	112
Tabela 87 – PREVISÃO EUA - COVID-19 MODELO 2: 02/2019-01/2021	112
Tabela 88 – PREVISÃO EUA - COVID-19 MODELO 3: 02/2019-01/2021	113
Tabela 89 – PREVISÃO EUA - COVID-19 MODELO 4: 02/2019-01/2021	113
Tabela 90 – PREVISÃO EUA - COVID-19 MODELO 5: 02/2019-01/2021	114
Tabela 91 – PREVISÃO EUA - COVID-19 MODELO 6: 02/2019-01/2021	114

LISTA DE ABREVIATURAS E SIGLAS

ACF	<i>Auto Correlation Function</i>
AIC	<i>Akaike Information Criterion</i>
AR	<i>Autoregressive</i>
ARMA	<i>Autoregressive Moving Average</i>
ADF	<i>Augmented Dickey-Fuller</i>
CDI	Certificado de Depósito Interbancário
DF	<i>Dickey-Fuller</i>
DGP	<i>Data Generating Process</i>
DM	<i>Diebold-Mariano</i>
GFC	<i>Great Financial Crisis</i>
HQC	<i>Hannan-Quinn Criterion</i>
IBOVESPA	Índice da Bolsa de Valores de São Paulo
IIS	<i>Impulse-indicator Saturation</i>
IP	<i>Industrial Production</i>
IPI	Índice de Produção Industrial
KPSS	<i>Kwiatkowski–Phillips–Schmidt–Shin</i>
MCS	<i>Model Confidence Set</i>
PAC	<i>Partial Auto Correlation Function</i>
PIB	Produto Interno Bruto
SBC	<i>Schwarz Bayesian Criterion</i>
STAR	<i>Smooth Transition Autoregressive</i>
TAR	<i>Threshold Autoregressive</i>

SUMÁRIO

1	INTRODUÇÃO	13
2	REVISÃO DE LITERATURA	15
2.1	Considerações Iniciais	15
2.2	Modelos Não Lineares – STAR (<i>Smooth Transition Autoregressive</i>) . .	17
2.3	<i>AUTOMETRICS</i>	19
3	BASE DE DADOS	21
3.1	Economia Brasileira	21
3.2	Economia Americana	22
3.3	Tratamento dos Dados	23
3.3.1	Produção Industrial	23
3.3.2	Volatilidade Realizada	26
4	METODOLOGIA	28
4.1	Modelos Lineares	29
4.2	Modelos Não Lineares	30
4.3	<i>AUTOMETRICS</i>	32
4.3.1	Seleção automática de modelos	32
4.3.2	<i>IIS – Impulse Indicator Saturation</i>	34
4.3.3	Escolha do p-valor das regressões	36
4.4	Critérios de informação para escolha de modelos	37
4.5	<i>Index-test</i> de não linearidade	38
4.6	Previsões das séries	41
4.6.1	Teste de Diebold e Mariano (DM)	41
5	RESULTADOS	43
5.1	Estimação	45
5.1.1	Brasil	47
5.1.2	Estado Unidos	52
5.2	Previsão	57
5.3	Discussão	59
6	CONCLUSÃO	63
	REFERÊNCIAS	65
	APÊNDICE A	68

1 INTRODUÇÃO

É ponto pacífico que tanto o comportamento de variáveis macroeconômicas bem como a maneira com que a política econômica é conduzida repercutem diretamente nos preços dos ativos financeiros, muitas vezes até de forma imediata. Este trabalho faz a ponte entre o mercado financeiro e a macroeconomia ao analisar como momentos de *stress* e distúrbios na bolsa de valores reverberam na economia real; e se os mesmos são capazes de ajudar na previsão da atividade econômica.

Usualmente encontramos artigos detalhando o impacto de variáveis econômicas nos ativos financeiros, enquanto o que propomos é fazer exatamente o contrário. Embora em menor quantidade, este tipo de relação reversa vem sendo foco de diversos trabalhos relevantes ao longo das últimas décadas. Cochrane, Hansen (1992) argumentam que ativos financeiros podem ser fontes riquíssimas de informação na modelagem de variáveis macroeconômicas. Mais recentemente, Aghion et al. (2009) evidenciam de que forma a volatilidade cambial do país é capaz de impactar a taxa de crescimento da produtividade no longo prazo.

Saindo de um modelo de precificação de ativos baseados nos bens de produção, Cochrane (1991) estima a associação entre os retornos das ações com a atividade econômica dos períodos subsequentes. Já Cochrane (2005) prega que a macroeconomia dinâmica atual é baseada em três equações: a primeira liga poupança ao investimento, a segunda trata da alocação de consumo versus investimento ao longo do tempo e a terceira faz a conexão entre a taxa marginal de substituição e a taxa marginal de transformação. Comum a estas três equações é o fato dos ativos financeiros controlarem toda a dinâmica dessas igualdades. Desta forma, torna-se impreterível o completo entendimento sobre o funcionamento do mercado financeiro na construção dos modelos macroeconômicos modernos.

O presente estudo tenta entender se a adição de componentes ligados à volatilidade realizada da bolsa de valores e se o uso de modelos econométricos não lineares são capazes de trazer ganhos informacionais tanto na identificação do processo gerador dos dados como na previsão da série de produção industrial. A idéia fundamental por trás do trabalho é a de que pode existir uma relação onde a volatilidade da bolsa ajuda a antecipar o que acontecerá com a atividade econômica nos períodos seguintes e que esta relação pode se manifestar de maneira não linear.

A análise é dividida em duas etapas; a primeira parte começa com a montagem de um modelo linear do tipo AR^1 para a produção industrial contendo 12 defasagens e 11 variáveis *dummies* sazonais (representando os meses do ano) que receberá o nome de *benchmark*; recairá sobre ele um teste (*Index-test*) para avaliar a linearidade dos dados. A seguir, constrói-se uma família de modelos não lineares que são uma aproximação de um modelo STAR (*Smooth Transition Auto Regressive*) contendo não só termos relacionados à própria produção industrial e às *dummies* como também o componente da volatilidade realizada. Com os modelos teóricos já definidos, o algoritmo de seleção automática *Autometrics* se encarrega de fazer a escolha dos estimadores que geram os resultados mais congruentes e parcimoniosos. Por fim, utiliza-se os critérios de informação de Schwarz, Hannan-Quinn e Akaike a fim de verificar se estatisticamente existe realmente algum ganho informacional ao adicionarmos a volatilidade e modelos não lineares na estimação do índice de Produção Industrial.

A segunda parte da análise focará em gerar previsões para o índice de Produção Industrial em um horizonte de 24 meses. Previsões feitas para o *benchmark* linear serão comparadas com as dos demais modelos. Para verificar se os novos processos trazem algum ganho de previsão frente ao modelo base serão comparados as Raízes dos Erros Quadrados Médios (*RMSE*). Por fim, será utilizado o teste proposto por Diebold, Mariano (2002), e Diebold (2015) para checar se os possíveis ganhos são estatisticamente significativos.

A amostra conterà exemplo tanto da economia brasileira como da norte-americana. Para o caso brasileiro, focaremos em três períodos turbulentos recentes da economia que foram acompanhados por forte aumento da volatilidade no mercado financeiro, são eles: Crise Financeira de 2008 (*GFC – Great Financial Crisis*), a crise brasileira no biênio 2014-2015 que culminou no processo de *impeachment* presidencial e a Crise Global de 2020 resultante da pandemia causada pelo vírus Covid-19. Já no caso norte-americano, compartilhamos os resultados somente para a crise de 2008 e a de 2020 já que o outro evento foi particular à economia brasileira.

¹ auto-regressivo

2 REVISÃO DE LITERATURA

2.1 CONSIDERAÇÕES INICIAIS

Os pontos-chaves que formam a base do estudo já foram exploradas pela comunidade acadêmica em algumas oportunidades. Com a intenção de medir associação entre as séries e não de inferir causalidade, Schwert (1989) observa a forma como a volatilidade da bolsa de valores varia com o passar do tempo e tenta relacionar esta dinâmica com a volatilidade apresentada por diversas variáveis macroeconômicas como inflação, expansão monetária e produção industrial em um estudo que vai de 1857 a 1987. O autor observa que tanto o nível da volatilidade da bolsa de valores como da produção industrial costuma aumentar durante as recessões. Também vê pouco indício de que a volatilidade macroeconômica seja relevante para prever a volatilidade do índice de ações; porém, o autor considera que as evidências parecem ser mais fortes no sentido contrário, a favor de usar a volatilidade de ativos financeiros para medir a volatilidade de variáveis macroeconômicas sendo que esta relação é particularmente clara nos períodos de 1891-1987 e 1920-1952.

A conexão entre variáveis macroeconômicas e volatilidade da bolsa de valores também é explorada por Paye (2012) e Engle et al. (2013). O primeiro faz uso de modelos lineares e investiga a relação entre uma série de variáveis econômicas e financeiras (PIB corrente e esperado, alavancagem bancária, *spread* da taxa a termo, *spread* das taxas de *default*, entre outros) para checar se as condições dos ciclos de negócios são capazes de explicar movimentos na volatilidade do índice da bolsa americana S&P500. O autor conclui não só que a volatilidade é persistente e contracíclica, como também que algumas das variáveis estudadas causam no sentido de Granger a volatilidade do índice. No quesito previsão, a adição das mesmas variáveis acaba melhorando as estimativas, mas os ganhos tendem a ser bem modestos.

Já Engle et al. (2013) argumentam que a volatilidade observada na bolsa pode ser particionada em diferentes componentes, sendo um deles relacionado diretamente à atividade econômica. Os autores combinam modelos GARCH com a técnica conhecida como MIDAS (*mixed data sampling*), que permite a agregação de dados de diferentes periodicidades, e procuram verificar o quanto da volatilidade pode ser explicada pelas variáveis econômicas. Os resultados mais promissores vêm da previsão dos componentes de longo prazo onde a adição das variáveis macroeconômicas faz com que os modelos GARCH-MIDAS consigam superar os GARCH

simples.

Os impactos econômicos causados pela crise do COVID-19 são mensurados a partir de um modelo TAR aplicado ao GVAR em Chudik et al. (2020). O GVAR¹ (*Global Vector Autoregressive*), consiste em um modelo macroeconômico de larga escala que consegue analisar de forma coerente um sistema altamente complexo como o da economia mundial a partir de equações bem mais simples com a ajuda de métodos de redução da dimensionalidade. Dada a escala global da pandemia e a não linearidade do processo, os autores criam um indicador de volatilidade global e o modelam como um TAR – *Threshold Autoregressive* a fim de criar diferentes regimes de volatilidade. A idéia é a de que choques exógenos independentes tendem a levar a volatilidade para diferentes níveis, que reverberam na economia de forma distinta e com isso poderiam ajudar a prever ciclos econômicos de curto prazo. Os autores analisam o comportamento da volatilidade realizada nos últimos quarenta anos e a forma como um aumento abrupto da mesma se propaga em um total de 33 países/regiões. Os resultados obtidos mostram que choques exógenos na volatilidade geram um impacto contrário no crescimento econômico e também que as economias mais desenvolvidas tendem a sentir mais este impacto do que economias emergentes e este fato talvez esteja ligado ao menor nível de desenvolvimento dos mercados financeiros em economias emergentes.

Em um estudo publicado no início da década de 1990, Teräsvirta, Anderson (1992) se propõem a analisar a possível dinâmica não linear dos Ciclos de Negócios (*Business Cycles*) através da aplicação de modelos da classe STAR (*Smooth Transition Autoregressive*) na modelagem de índices de produção industrial de 13 países, além da região da zona do Euro. O ponto fundamental é verificar se a dinâmica do ciclo econômico é diferente durante momentos recessivos em relação a expansionários. Em 10 das 14 séries, eles encontram evidências de que modelos não lineares podem ser particularmente interessantes para tratar períodos recessivos, onde existe grande chance de políticas econômicas não convencionais serem implementadas. A ausência de não linearidade em 4 das séries faz com que o modelo STAR não seja apropriado para modelá-las. Contudo, ainda assim sugerem que tais modelos podem ser úteis, pois mesmo para séries onde a hipótese nula de linearidade é aceita, modelos não lineares acabam por melhorar os resultados da previsão para eventos pontuais específicos, como os choques exógenos causados pela crise do petróleo na década de 1970.

¹ Pesaran et al. (2004)

Refletindo sobre os textos citados até aqui, acredito que o presente trabalho tenta levar em consideração vários dos pontos mencionados; Schwert (1989) nos passa a noção de que a volatilidade dos ativos financeiros pode ter valor na previsão de variáveis econômicas, Chudik et al (2020) faz uso da volatilidade realizada para tentar explicar o desempenho econômico após choques exógenos enquanto Terasvirta e Anderson (1992) analisam os ciclos de negócios usando o índice da produção industrial como *proxy* da atividade econômica e o modelam a partir de modelos STAR.

2.2 MODELOS NÃO LINEARES – STAR (*SMOOTH TRANSITION AUTOREGRESSIVE*)

Existe uma literatura crescente que tenta apurar se a adoção de modelos não lineares traz benefícios na estimação de variáveis macroeconômicas quando comparados com modelos lineares tradicionais como um AR. Em um extenso trabalho divulgado em 1998, Stock e Watson² coletam dados de 215 séries macroeconômicas para os anos de 1959 à 1996 e adotam nada menos que 49 métodos de previsão para analisá-las, tentando responder se existe ganho de previsão ao sairmos de um processo auto-regressivo linear para um não linear. Olhando para um horizonte de previsão de 1, 6 e 12 meses adiante, os autores concluem que no geral, técnicas que consigam misturar elementos dos diversos métodos através de algum tipo de ponderação baseada nos erros de previsão obtidos tendem a registrar os melhores resultados. Porém, ao analisar cada método individualmente, os ARs foram superiores aos demais, obtendo menores erros de previsão. Dentre os não lineares, a classe STAR foi consistentemente superior a ANN (*Artificial Neural Network*). Os autores vão além e argumentam que mesmo em casos onde previsões baseadas em STAR foram superiores ao AR, existe a possibilidade de isso ter acontecido por *overfitting*. Não obstante, concedem que o exercício proposto era somente o de previsão sem levar em conta testes de linearidade das séries e sugerem que processos não lineares podem efetivamente trazer ganho informacional e de previsão para algumas delas.

Desde o artigo seminal publicado em 1983³ sobre a aleatoriedade do comportamento da taxa de câmbio, muito esforço vem sendo exibido por acadêmicos e também profissionais do mercado financeiro para se modelar a dinâmica dos movimentos cambiais de forma satisfatória. Kilian, Taylor (2003) valem-se dos resultados encontrados nos trabalhos mais recentes sobre o tema (não linearidade tanto das séries cambiais em relação aos fundamentos econômicos como

² Stock, Watson (1998)

³ Meese, Rogoff (1983)

também da reversão do *spot* à taxa de equilíbrio de longo prazo) para testar a previsibilidade da taxa de câmbio usando modelos ESTAR (*Exponential Smooth Transition Autoregressive*). Para horizontes de curto prazo, os autores argumentam que a hipótese de *random walk* prevalece, mas olhando para horizontes longos de tempo, como por exemplo 3 anos, o uso de processos ESTAR trazem ganhos significativos de previsão. Estes ganhos nas previsões de longo prazo são o suficientes para eles refutarem a idéia de *random walk* no longo prazo a 10% de significância para 4 ou 5 dos 7 pares de moedas da amostra.

Usando modelos com especificações dinâmicas, Teräsvirta et al. (2005) examinam a precisão das previsões feitas por 3 tipos de processos (um linear e dois não lineares): AR, STAR e NN (*neural network*) na previsão de 47 variáveis macroeconômicas dos países que fazem parte do G7. Os autores encontram evidências de que uma vez constatada a não linearidade das séries, o uso de modelos como STAR e NN traz ganho informacional de previsão. Contudo, para séries onde estes mesmos testes apontam para uma DGP linear, o processo AR costuma ter uma *performance* preditiva superior aos demais. Assim sendo, os autores reiteram a importância da execução de testes de não linearidade das séries antes da adoção de qualquer modelo não linear.

Fontes valiosas de informação a respeito da modelagem de série temporais usando STAR e suas variantes pode ser encontrado em Teräsvirta (1994); Lundbergh, Teräsvirta (2002); e Dijk van et al. (2002). Estes trabalhos abordam aspectos como identificação, especificação e aplicações reais destes modelos não lineares em séries econômicas, incluindo formas de usá-los para previsão. Desta forma, fornecem uma metodologia de uso similar à aquela construída por Box e Jenkins para tratar de processos lineares.

Após leitura das referências mencionadas acima e outras mais, a impressão que fica é a de que a adesão de modelos não lineares para ganhos informacionais de previsão está longe de ser uma unanimidade entre os acadêmicos. Enquanto para algumas séries os modelos lineares da família ARIMA continuam imbatíveis, para outras parece existir ganhos reais e estaticamente significativos com a utilização da modelagem STAR, ESTAR, LSTAR, Markov-Switch, etc. O ponto fundamental ressaltado em diversas oportunidades é a necessidade de se aplicar testes de linearidade para entender o comportamento da série antes de usar qualquer instrumento não linear.

2.3 AUTOMETRICS

Autometrics é um poderoso algoritmo de seleção de modelos e que será de suma importância no desenvolvimento deste trabalho. Faz parte do pacote *PcGive* e está disponível no *software* Oxmetrics. Todo o seu desenvolvimento precisa ser contextualizado de acordo com a linha de pesquisa econométrica produzida pelo departamento de econometria da *LSE - London School of Economics*, principalmente no período que vai do começo da década de 1960 até meados da década de 1980. Esta abordagem própria e inovadora desenvolvida no departamento rompeu com o que era a norma vigente em relação ao uso da econometria na modelagem econômica; ganhando inclusive um nome próprio, conhecido como *LSE Approach* ou abordagem LSE. Esta abordagem também foi responsável por cunhar o termo *GETS – General to Specific* onde não se deve partir do pressuposto de tentar adequar ou forçar os dados da amostra a um modelo macroeconômico pré-definido, mas sim deixar que os dados falem por si e nos digam como o processo (DGP) é formado.

Um bom ponto de partida para o entendimento completo da dinâmica envolvida na criação dessa abordagem inovadora é oferecido em Spanos (2014). Através do olhar de alguém que vivenciou intimamente o que era produzido no departamento de econometria da *LSE*, o autor nos leva a uma jornada que começa com Denis Sargan, ‘fundador’ da abordagem LSE, e sua cruzada contra a abordagem extremamente teórica dos livros texto de econometria da época em prol de métodos que enfatizassem a importância dos dados propriamente ditos. Em seguida, comenta sobre as inovações nos campos de aprendizado através dos dados e procedimentos alternativos de inferência que fizeram de David Hendry o verdadeiro protagonista da *LSE Tradition*. Por fim, conclui que o legado completo desta abordagem que ‘constrói modelos a partir do que é observado’ ainda levará um tempo para ser totalmente assimilado pelos econometristas.

Doornik (2009) explica que o algoritmo *Autometrics*, partindo da ideia do *general to specific*, recebe os dados sem tratamento algum e vale-se de uma rotina sequencial de procedimentos onde sucessivas iterações otimizadoras e de redução de dimensão do sistema, tem como objetivo final a estruturação de um modelo que seja congruente, abrangente (*encompassing*) e parcimonioso. As etapas a seguir dão uma idéia do que o algoritmo faz:

- 1 GUM (*general unrestricted model*): a partir de uma amostra grande de dados é criado um modelo representativo e estatisticamente bem comportado do que acreditamos ser o

processo gerador de dados.

- 2 Presearch: a fim de reduzir o trabalho computacional, testa-se a matriz de correlação dos coeficientes para começar o processo de eliminação daqueles claramente considerados redundantes ou de pouca significância estatística.

- 3 Multiple-path search: são criadas múltiplas simulações através de árvores de decisão onde a grande maioria das ramificações vai sendo apagada permanentemente de acordo com o processo de eliminação de variáveis.

- 4 Encompassing test: esta etapa compara os modelos que sobreviveram com o modelo geral irrestrito obtido no passo 1 de modo a aferir o quanto de informação se perdeu durante o processo de eliminação de variáveis dos passos anteriores. A partir disto uma nova o algoritmo volta às etapas iniciais e uma nova triagem é feita.

- 5 Tie breaker: em geral chega-se a última rodada com mais de um modelo ainda sendo considerado. Para o desempate o algoritmo usa critérios de informação na escolha do modelo final.

No capítulo 4 será apresentada uma explicação mais completa sobre o algoritmo e seu mecanismo de seleção, mas para uma referencia mais detalhada sobre o assunto, Hendry, Doornik (2014) dedicam um livro inteiro para relatar os processos e as técnicas envolvidas na seleção automática de modelos que serviram de base para o desenvolvimento do *Autometrics*.

Refletindo sobre a maneira como este trabalho tenta contribuir para o desenvolvimento da ciência econômica; parto do pressuposto de que o exercício de previsão se torna particularmente importante em momentos de maior turbulência e incerteza, momentos que tendem a ser mais danosos à economia. É exatamente sob esta ótica que, ao integrar um componente que mede o nervosismo dos mercados financeiros (volatilidade realizada) a um modelo econométrico mais sofisticado através de um poderoso algoritmo de seleção, tento melhorar a acurácia nas previsões das séries de produção industrial.

3 BASE DE DADOS

3.1 ECONOMIA BRASILEIRA

O principal indicador para acompanhar o ritmo da atividade econômica nacional é o PIB. Porém, a trimestralidade de sua divulgação traz certas limitações para a construção e análise da série; acontece que o PIB exibe alta correlação com o Índice de Produção Industrial Geral, que por sua vez possui periodicidade mensal e também é um indicador bastante relevante para medir a atividade econômica. Sendo assim, decidiu-se pelo uso da última como *proxy* para o comportamento da economia brasileira.

Além de sua divulgação mensal, outra vantagem em usarmos o Índice de Produção Industrial ao invés do PIB está ligada à identificação da não linearidade do processo. Ao comparar os erros de previsão feitos por um modelo linear com os erros do modelo não linear, Teräsvirta, Anderson (1992) sugerem que quanto maior for a variação cíclica do indicador, mais eficiente será o teste de não linearidade do processo; no nosso caso a série mensal da produção industrial tende a ser mais cíclica que a trimestral correspondente ao PIB.

A série histórica do Índice de Produção Industrial Geral sem ajuste sazonal para a economia brasileira passa a ser calculada pelo IBGE em janeiro de 1975, mas este estudo analisa os dados a partir de 1986 devido a limitação na base de dados da taxa de juros brasileira. Os dados referentes ao Índice Bovespa (IBOVESPA) correspondem aos preços de fechamento diário do índice sem qualquer tipo de ajuste; esta série foi extraída diretamente do provedor de dados Economatica. Também é nesta base onde o CDI é coletado diariamente.

Temos ao todo um total de 418 observações mensais nesta amostra, que vão de abril de 1986 à janeiro de 2021. Conforme mencionado no capítulo introdutório, o trabalho foca em três momentos principais:

- para a crise financeira de 2008 (*GFC – Great Financial Crisis*) olharemos os dados que vão do começo da amostra até junho de 2007 (255 observações) para formular a estimação dos modelos e a partir deles faremos uma previsão mês a mês por 24 períodos terminando em junho de 2009.

- para a crise econômica e política que afligiu o Brasil no biênio 2014-2015 e que culminou no processo de *impeachment* presidencial, faremos de julho de 2013 a base para estimação

dos modelos (328 observações), enquanto o exercício de previsão vai de agosto-2013 a julho-2015; ressaltando que este tipo de previsão, *one step ahead*, faz com que o tamanho da amostra cresça com o passar dos meses, pois o valor previsto é comparado ao valor observado para o cálculo do erro previsão e simultaneamente o valor observado é incorporado ao final da amostra¹ para o cálculo da previsão do período seguinte.

- para a crise sanitária, política, econômica e social de proporções globais causadas pela pandemia do vírus COVID-19 no ano de 2020, teremos janeiro de 2019 como último mês a ser incluído na estimação dos modelos, totalizando 394 observações. Assim, o exercício de previsão de 24 meses começará em fevereiro de 2019 e o seu término coincidirá com o final da amostra em janeiro de 2021

3.2 ECONOMIA AMERICANA

De maneira análoga ao que foi feito para o caso brasileiro, usaremos o *Industrial Production: Manufacturing (SIC)* – série mensal sem ajuste sazonal como variável representativa da atividade econômica dos EUA. O início dela acontece em janeiro de 1921 e está disponível no sítio de base de dados econômicas e financeiras do *Federal Reserve Bank of St. Louis (FRED)*. Para representar a bolsa de valores americana foi escolhido o Índice *Dow Jones Industrial Average*. Embora tenha perdido importância nas últimas duas décadas para o *S&P500* e *NASDAQ*; durante a maior parte do período estudado ele foi o índice de referência para o mercado de bolsa de valores americana. Além do mais, a correlação entre os três índices é altíssima e a volatilidades apresentadas pelo *Dow Jones* e *S&P500* estão em patamares similares.

Por mais extensos que sejam os dados referentes a produção industrial e *Dow Jones*, o início da amostra está limitado pela série de taxa de juros, cujos dados começam em 1955. A série escolhida é a *Effective Federal Funds Rate* – série diária da taxa overnight americana. Tanto os dados referentes ao fechamento diário do Índice *Dow Jones* como da taxa de juros também foram importados da base do *Federal Reserve Bank of St. Louis (FRED)*. Sendo assim, a amostra contém dados que começam em julho de 1955 e terminam em janeiro de 2021, contabilizando um total de 787 observações mensais.

Como a crise que atingiu o Brasil em 2014-2015 não passou de um evento local, a economia americana será analisada apenas nas outras duas ocasiões que envolveram choques de

¹ *expanding window*

magnitude global. Tomando como base janelas de dados similares às utilizadas para a economia brasileira, temos que para a *GFC – Great Financial Crisis* de 2008 os dados vão do começo da amostra até junho de 2007 (624 meses). Estas observações serão usadas para formular a estimação dos modelos e a partir deles faremos a previsão mês a mês por 24 períodos que termina em junho de 2009. Para a recente pandemia de 2020 os dados da série estimada vão de jul/1955 a jan/2019 (763 observações), enquanto as previsões começam em fev/2019 e terminam em jan/2021.

3.3 TRATAMENTO DOS DADOS

Ao longo da primeira parte do trabalho o foco é a estimação do modelo. Com isso, seguiremos a estratégia difundida por Box e Jenkins (1976), que prega a implementação de um método de três estágios. De acordo com Enders (2010), no primeiro estágio ou de identificação ocorre a análise gráfica das séries em busca de tendências de longo prazo, sazonalidade e *outliers* aparentes. Também são analisados os gráficos das funções de Auto Correlação (*ACF*) e Auto Correlação Parcial (*PAC*) para se ter uma idéia mais clara do tipo de processo que os dados parecem seguir dentre os diversos modelos de categoria ARIMA; é também nesta fase em que são feitas transformações nos dados a fim de garantir que as séries sejam estacionárias. No segundo estágio ou de estimação ocorre a análise dos coeficientes dos diferentes modelos a fim de encontrar aqueles que sejam abrangentes e parcimoniosos. O terceiro estágio ou de checagem diagnóstica (*diagnostic checking*) serve para garantir que os resíduos das regressões finais se comportam como um processo com características de um ruído branco.

As próximas subseções focam no primeiro estágio, enquanto os próximos dois capítulos aprofundam os estágios correspondentes a estimação e checagem.

3.3.1 Produção Industrial

A análise gráfica das séries em nível indicou a presença de tendência de longo prazo e sazonalidade tanto para a série brasileira como para a norte-americana. Uma vez que as séries parecem ser estacionárias em primeira diferença², optamos por uma transformação logarítmica dos dados e em seguida manipulamos a série para primeira diferença a fim de induzir

² difference stationary

estacionaridade.

Transformações logarítmicas são úteis quando os dados exibem forte tendência de crescimento, pois frequentemente valores mais elevados estão associados a uma maior dispersão em termos absolutos, ou seja, o desvio padrão se torna proporcional ao nível da série. Por outro lado, ao passarmos os dados para o seu logaritmo natural garantimos que o desvio padrão se torne praticamente constante por toda a amostra, conforme Cryer, Chan (2008). Como consequência desta etapa tem-se também a linearização da tendência exibida, garantindo que provavelmente a primeira diferença dos dados seja estacionária.

Sobre os dados transformados, propomos dois testes tradicionais de análise de raiz unitária para identificar se os mesmos são realmente estacionários: ADF (*Augmented Dickey-Fuller*) e KPSS³ (*Kwiatkowski-Phillips-Schmidt-Shin*).

O teste de *Dickey-Fuller* (1979,1981) é usado para validar a estacionaridade de um processo auto-regressivo AR(1) padrão dado por

$$y_t = \phi y_{t-1} + e_t \quad (3.1)$$

em que e_t é um ruído branco. Assumimos a hipótese nula de raiz unitária e hipótese alternativa de estacionariedade baseados no valor de ϕ .

$$H_0 : \phi = 1$$

$$H_1 : \phi < 1$$

Os valores de ϕ são calculados usando MQO, mas sob a hipótese nula de raiz unitária em que $\phi = 1$, a série não é estacionária e a estimação do coeficiente ϕ torna-se viesada para baixo. Desta maneira, embora a leitura do teste seja através da estatística- t , esta deverá ser feita observando valores críticos próprios para o teste DF ao invés procurarmos pelos valores na tabela da distribuição t padrão. Os valores críticos para o teste são menores que os da distribuição padrão.

Subtraindo y_{t-1} de ambos os lados da equação (3.1) chegamos a

$$\Delta y_t = \gamma y_{t-1} + e_t, \quad \gamma = \phi - 1 \quad (3.2)$$

³ D Kwiatkowski, D., Phillips, P.C.B., Schmidt, P., Shin Y. (1992) - *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?*

Podemos então reescrever as hipóteses do teste como

$$H_0 : \gamma = 0$$

$$H_1 : \gamma < 0$$

E o teste *Dickey-Fuller* será dado por

$$t_{DF} = \frac{\hat{\gamma}}{Se(\hat{\gamma})} \quad (3.3)$$

onde $\hat{\gamma}$ é o estimador de γ e $Se(\hat{\gamma})$ é o erro padrão de γ

O teste ADF é uma generalização do DF e possibilita testar qualquer processo das classes AR(p) e ARMA(p, q). Sua concepção segue os mesmos moldes do teste DF, e a equação do ADF também é a mesma. Nelson e Plosser (1982)⁴ mostram que em algumas situações o ADF apresenta baixo poder por ser incapaz de distinguir raiz unitária de valores que estejam próximos a raiz unitária. Com isso, o teste tende a não rejeitar a hipótese nula de raiz unitária mesmo quando ela é falsa para valores próximos a 1, ou seja, tem maiores chances de apresentar erros do Tipo 2.

Para o teste KPSS a hipótese nula é invertida e indicam que os dados são estacionários, enquanto a hipótese alternativa é de não estacionaridade. Segundo Pesaran (2015), este teste parte do princípio de que a variância da soma parcial: $s_t = \sum_{j=1}^t \hat{e}_j$, onde $\hat{e}_j = y_i - \hat{\alpha} - \hat{\beta}_j$ é relativamente pequena sob estacionaridade quando comparada com a hipótese alternativa de presença de raiz unitária. Consequentemente, temos

$$H_0 : \sigma_e^2 = 0 \text{ (série estacionária)}$$

$$H_1 : \sigma_e^2 \neq 0 \text{ (série não estacionária ou raiz unitária)}$$

A interpretação do teste é feita através da estatística LM o seu cálculo via MQO. O KPSS é definida por:

$$\hat{\zeta}_T = \left[\frac{1}{T s_T(l)} \right]^2 \sum_{t=1}^T s_t^2 \quad (3.4)$$

Onde $s_T^2(l)$ é a estimativa da variância de longo prazo de s_t , dado por:

$$s_T^2(l) = \frac{1}{T} \sum_{t=1}^T \hat{e}_t^2 + \frac{2}{T} \left[\sum_{j=1}^l w_j \left(\sum_{t=j+1}^T \hat{e}_t \hat{e}_{t-j} \right) \right] \quad (3.5)$$

⁴ Nelson, C.R., Plosser, C.R. (1982) - *Trends and random walks in macroeconomic time series: some evidence and implications*

e $w_j = 1 - \frac{j}{l+1}$, $j = 1, 2, 3, \dots, l$

3.3.2 Volatilidade Realizada

O cálculo da volatilidade realizada seguirá a definição clássica do desvio padrão dos retornos dos ativos. Neste caso, o procedimento consiste em primeiramente transformar a série inteira da bolsa aplicando o logaritmo natural a cada observação. Em seguida o cálculo do retorno de um dia é dado pela simples subtração do log de um dia contra o log do dia anterior:

$$r_{t_{bolsa}} = \ln X_t - \ln X_{t-1} \quad (3.6)$$

Os índices de bolsa geralmente exibem clara tendência altista de longo prazo, o que faz sentido, pois o investidor precisa receber um prêmio pelo risco adicional inerente ao mercado acionário quando investe em ações comparativamente à opção de alocar seus recursos no ativo livre de risco. Uma forma de tentar mitigar esta forte tendência é ‘deflacionando’ os retornos obtidos na bolsa de valores pela taxa do ativo livre de risco, ou seja, olhando apenas para o excesso de retorno pelo risco incorrido. Este excesso de retorno é calculado subtraindo os juros de 1 dia do ativo livre de risco da variação da bolsa de valores para o mesmo dia. Sejam os fatores diários para a capitalização do ativo livre de risco para o Brasil e Estados Unidos dados respectivamente por

$$r_{t_{BR}}^* = (1 + R_t^*)^{\frac{1}{252}} - 1 \quad (3.7)$$

$$r_{t_{US}}^* = \frac{R_t^*}{360} \quad (3.8)$$

onde r_t^* denota o retorno diário do ativo livre de risco e R_t^* é a taxa anual do ativo livre de risco.

O excesso de retorno r_t sobre o ativo livre de risco será dado por

$$r_t = r_{t_{bolsa}} - r_t^* \quad (3.9)$$

O próximo passo é a separação dos dados mês a mês e o cálculo do desvio padrão levando em consideração somente as observações pertinentes a cada mês. O resultado equivale à volatilidade diária mês a mês. Seguindo convenção de mercado, o valor encontrado deve ser anualizado assumindo um total de 252 dias úteis. Esta série anualizada da volatilidade é a que

será utilizada em nossas regressões.

$$vol_{dia_y} = \sqrt{\frac{\sum_{i=1}^j (r_i - \bar{r})^2}{j}} \quad (3.10)$$

$$Vol_{ano_y} = vol_{dia_y} \sqrt{252} \quad (3.11)$$

em que vol_{dia_y} representa a volatilidade diária do mês Y, j é o número de observações dentro do mês Y e Vol_{ano_y} é a volatilidade diária do mês Y anualizada.

4 METODOLOGIA

O presente trabalho abordará tanto modelos lineares como não lineares de séries temporais. Por mais completos e sofisticados que os modelos lineares tenham se tornado, estudos empíricos sugerem que uma porção de variáveis econômicas exibem comportamento não linear, Enders (2010). Um modelo linear simples é aquele que, depois das devidas transformações dos dados, possui média condicional dependente apenas do valor da variável ao longo do tempo. Este será considerado normalmente distribuído caso os erros da regressão sigam uma distribuição normal.

Uma série estacionária e inversível que esteja sendo modelada temporalmente como um processo linear exibirá uma propriedade chamada de *time reversability*¹. Esta propriedade está ligada ao fato de tais processos poderem ser completamente descritos olhando somente para sua média e função de auto covariância; o que implica em dizer que do ponto de vista temporal, ao analisarmos os dados no sentido natural indo de $D_t \rightarrow D_{t+s}$ (*forecasting*²) ou no sentido reverso $D_{t+s} \rightarrow D_t$ (*backcasting*³) chegamos exatamente na mesma distribuição. Acontece que grande parte dos processos observados empiricamente nos contradiz e não possuem tal característica, sendo assim classificados como *time-irreversible*⁴, Cryer, Chan (2008). Por exemplo: preços dos ativos financeiros tendem a subir gradativamente por período extenso de tempo, enquanto as correções de preço ou *crashes* tendem a ser violentas e repentinas; outras variáveis que exibem dinâmica comparável são nível de emprego e produto já que ambas tendem a cair mais rapidamente do que sobem. É exatamente esta dinâmica que cria a não linearidade que buscamos testar.

Neste contexto, temos dois objetivos principais: o primeiro é investigar se a adição de componentes ligados à volatilidade realizada do índice de ações contribui para a estimação de um modelo mais parcimonioso, congruente e abrangente que traga ganho informacional na identificação e na previsão da série de produção industrial quando comparado com o nosso modelo linear base (*benchmark*). O segundo objetivo é testar se métodos não lineares da classe STAR são capazes de obter o mesmo tipo de ganho informacional.

¹ Tradução livre: reversíveis temporalmente

² previsão

³ previsão de dados passados

⁴ Tradução livre: irreversíveis temporalmente

4.1 MODELOS LINEARES

Partiremos de um modelo linear do tipo auto regressivo – AR(p) que segue a seguinte forma:

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi_3 Y_{t-3} + \dots + \varphi_p Y_{t-p} + e_t \quad (4.1)$$

Ou

$$Y_t = \varphi_0 + \sum_{i=1}^p \varphi_i Y_{t-i} + e_t \quad (4.2)$$

onde e_t é um processo ruído branco normalmente distribuído. Sabe-se que este processo não é explosivo, ou seja, é convergente caso as raízes características da equação (4.1) estiverem dentro do círculo unitário, $|\varphi| < 1$

Para investigarmos o Índice da Produção Industrial, nosso *benchmark* terá um total de 12 defasagens e mais 11 variáveis *dummies* sazonais representando os meses do ano. Assim sendo, o modelo básico a ser utilizado é:

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi_3 Y_{t-3} + \dots + \varphi_{12} Y_{t-12} + \beta_1 D_1 + \beta_2 D_2 + \beta_3 D_3 + \dots + \beta_{11} D_{11} + e_t \quad (4.3)$$

Ou

$$Y_t = \varphi_0 + \sum_{i=1}^{12} \varphi_i Y_{t-i} + \sum_{j=1}^{11} \beta_j D_j + e_t \quad (4.4)$$

onde Y_t é a observação de número t da série já diferenciada do ln da produção industrial, D_j representa a *dummy* sazonal do mês j e e_t é um ruído branco de média e variância constantes

Uma primeira maneira de testarmos a relevância ou não da volatilidade realizada é acrescentando-a ao próprio modelo linear. Para tanto, adicionamos ao modelo anterior a volatilidade realizada contemporânea e suas duas primeiras defasagens, gerando o novo processo:

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi_3 Y_{t-3} + \dots + \varphi_{11} Y_{t-11} + \varphi_{12} Y_{t-12} + \beta_1 D_1 + \beta_2 D_2 + \beta_3 D_3 + \dots + \beta_{11} D_{11} + \alpha_0 Vol_t + \alpha_1 Vol_{t-1} + \alpha_2 Vol_{t-2} + e_t \quad (4.5)$$

ou

$$Y_t = \varphi_0 + \sum_{i=1}^{12} \varphi_i Y_{t-i} + \sum_{j=1}^{11} \beta_j D_j + \sum_{k=0}^2 \alpha_k Vol_{t-k} + e_t \quad (4.6)$$

e Vol_t é a observação de número t da volatilidade realizada do índice de ações. Este será o primeiro modelo a ser comparado ao *benchmark*.

4.2 MODELOS NÃO LINEARES

Por Enders (2010), o modelo auto regressivo não linear mais simples tem a forma:

$$Y_t = f(Y_{t-1}) + \varepsilon_t \quad (4.7)$$

e recebe o nome de NLAR(1) - *First Order Non Linear Autoregressive*. Um caso especial deste modelo assume a forma:

$$Y_t = \alpha_0 + \alpha_1(Y_{t-1}) + \beta_1(Y_{t-1})f(Y_{t-1}) + \varepsilon_t \quad (4.8)$$

Caso $f()$ seja uma função contínua e suave⁵, ambos os coeficientes da regressão (α e β) transitarão suavemente ao longo de Y_{t-1} , formando a base dos modelos STAR. Para mudanças de regime bem delineadas, poderíamos adotar modelos da classe TAR, mas no nosso caso estamos mais interessados em casos onde a mudança entre regimes acontece de forma suave e sem movimentos abruptos, desta forma manteremos o foco na classe de métodos STAR. O trabalho usará uma aproximação do processo não linear da classe STAR, conforme proposto em Luukkonen et al. (1988), cuja forma básica pode ser escrita como:

$$\begin{aligned} Y_t = & \varphi_0 + \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \gamma_{1,1} Y_{t-1}^2 + \gamma_{1,2} Y_{t-1} Y_{t-2} + \dots + \gamma_{1,p} Y_{t-1} Y_{t-p} \\ & + \gamma_{2,2} Y_{t-2}^2 + \gamma_{2,3} Y_{t-2} Y_{t-3} + \dots + \gamma_{2,p} Y_{t-2} Y_{t-p} + \dots + \gamma_{p,p-1} Y_{t-p} Y_{t-p+1} + \gamma_{p,p} Y_{t-p}^2 + e_t \end{aligned} \quad (4.9)$$

Ou

$$Y_t = \varphi_0 + \sum_{i=1}^p \varphi_i Y_{t-i} + \sum_{i=1}^p \sum_{j=i}^p \gamma_{i,j} Y_{t-i} Y_{t-j} + e_t \quad (4.10)$$

Observa-se que os primeiros dois termos do lado direito da equação (4.8) são idênticos aos da equação linear (4.2), enquanto o terceiro termo é novo. É justamente ele o responsável por carregar o componente não linear. Ao multiplicar uma defasagem por outra, ele tenta captar a dependência existente entre as relações cruzadas das próprias defasagens da série.

Construiremos 4 versões distintas para o modelo de Luukkonen et al (1988). A primeira será a mais próxima do modelo original proposto pelos autores e levará em conta somente a interação entre as próprias defasagens da série em conjunto com as mesmas variáveis *dummies* sazonais já usadas anteriormente. Além do acréscimo das *dummies*, a grande diferença para a

⁵ smooth and continuous

equação (4.10) está no fato de focarmos somente na interação das duas primeiras defasagens (Y_{t-1} e Y_{t-2}) da produção industrial com as demais ao invés de olhar para o conjunto todo dos termos cruzados. Nosso primeiro modelo não linear será dado por:

$$Y_t = \varphi_0 + \sum_{i=1}^{12} \varphi_i Y_{t-i} + \sum_{i=1}^{12} \delta_i Y_{t-i}^2 + \sum_{k=1}^2 \sum_{i=k+1}^{12} \lambda_{ki} Y_{t-k} Y_{t-i} + \sum_{j=1}^{11} \beta_j D_j + e_t \quad (4.11)$$

onde Y_t é a observação t da série já diferenciada do ln da produção industrial, D_j representa a *dummy* sazonal do mês j e e_t é um ruído branco de média e variância constantes

Partindo de (4.11), adicionamos os componentes correspondentes à volatilidade realizada contemporânea e suas duas primeiras defasagens. Note que, embora a equação continue sendo não linear, neste caso a volatilidade só impactará o processo de forma linear:

$$Y_t = \varphi_0 + \sum_{i=1}^{12} \varphi_i Y_{t-i} + \sum_{k=0}^2 \alpha_k Vol_{t-k} + \sum_{i=1}^{12} \delta_i Y_{t-i}^2 + \sum_{k=1}^2 \sum_{i=k+1}^{12} \lambda_{ki} Y_{t-k} Y_{t-i} + \sum_{j=1}^{11} \beta_j D_j + e_t \quad (4.12)$$

e Vol_t é a observação t da volatilidade realizada do índice de ações

Na terceira equação, excluiremos os termos cruzados correspondentes a interação entre as próprias defasagens da produção industrial, mas acrescentaremos os elementos da volatilidade em sua forma linear, em sua forma quadrática e ainda os termos cruzados entre as defasagens da volatilidade e as defasagens do índice de produção industrial que também são não lineares.

$$Y_t = \varphi_0 + \sum_{i=1}^{12} \varphi_i Y_{t-i} + \sum_{k=0}^2 \alpha_k Vol_{t-k} + \sum_{i=1}^{12} \delta_i Y_{t-i}^2 + \sum_{k=1}^2 \rho_k Vol_{t-k}^2 + \sum_{k=1}^2 \sum_{i=1}^{12} \gamma_{ki} Vol_{t-k} Y_{t-i} + \sum_{j=1}^{11} \beta_j D_j + e_t \quad (4.13)$$

O último modelo conterá todos os componentes discutidos até aqui, ou seja, incorporará tantos os termos cruzados provenientes da multiplicação entre as defasagens da volatilidade e as defasagens da produção industrial quanto aqueles que são frutos do cruzamento entre os próprios *lags* do índice de produção industrial. Segue:

$$Y_t = \varphi_0 + \sum_{i=1}^{12} \varphi_i Y_{t-i} + \sum_{k=0}^2 \alpha_k Vol_{t-k} + \sum_{i=1}^{12} \delta_i Y_{t-i}^2 + \sum_{k=1}^2 \rho_k Vol_{t-k}^2 + \sum_{k=1}^2 \sum_{i=1}^{12} \gamma_{ki} Vol_{t-k} Y_{t-i} + \sum_{k=1}^2 \sum_{i=k+1}^{12} \lambda_{ki} Y_{t-k} Y_{t-i} + \sum_{j=1}^{11} \beta_j D_j + e_t \quad (4.14)$$

Recapitulando, as regressões lineares testadas serão 2 (modelo base e base com volatilidade), enquanto as não lineares serão 4, totalizando 6 modelos diferentes que serão submetidos à otimização do *Autometrics* com a intenção de encontrar aquele que seja o mais congruente, abrangente e parcimonioso, conseguindo assim dominar os demais.

4.3 AUTOMETRICS

Tendo sido desenvolvido nos moldes da *LSE Tradition*, era de se esperar que o *Autometrics* tivesse como alicerce a abordagem *GETS – General to Specific*. Uma vez que raramente o processo gerador dos dados *DGP* é verdadeiramente observado ou conhecido; o algoritmo usa a premissa do *GETS* para partir de uma condição inicial onde existe um excesso de parâmetros e de modelos possíveis (*general*) e através do uso de técnicas de redução de dimensionalidade e otimização produz um *GUM – General Unrestricted Model* que seja uma boa aproximação da *LDGP – Local Data Generating Process*. Toda a estimação ocorre via Mínimos Quadrados Ordinários - MQO e ao final do procedimento chega-se a um ou poucos modelos finais (*specific*) que tendem a ser congruentes, parcimoniosos e capazes de abranger todos os demais que foram sendo descartados durante o processo.

4.3.1 Seleção automática de modelos

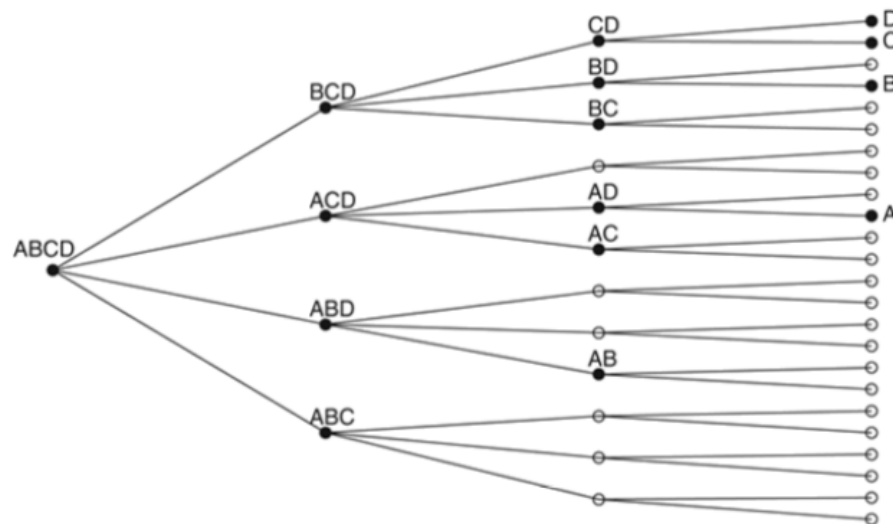
Em um mundo onde a quantidade de dados disponíveis cresce em velocidade assustadora e onde o poder computacional também vem aumentando de forma significativa, parece fazer bastante sentido a missão de tentar otimizar ao máximo a escolha dos parâmetros relevantes da regressão através de métodos de seleção automática, já que para um conjunto total de z variáveis, o número de modelos totais que podem ser estimados é igual a 2^z , Doornik (2009).

É então de suma importância o uso de um procedimento capaz de reduzir significativamente a dimensão, mantendo a solução do problema computacionalmente viável e sem descartar um número comprometedor de variáveis relevantes. Este é exatamente o primeiro passo dado pelo algoritmo *Autometrics* e envolve as seguintes etapas: agregação, transformação dos dados, partição dos dados, marginalização, fatoração sequencial e descoberta dos parâmetros de interesse. Finalizando todas estas etapas encontramos uma GUM que seja congruente à LDGP.


Embora esta GUM já contenha a LGDP, ela ainda é um modelo super-parametrizado

e com excesso de defasagens. Assim sendo, faz-se necessária a aplicação do procedimento de *pre-search* onde a matriz de correlação dos coeficientes é testada para que se comece um novo o processo de eliminação dos parâmetros redundantes ou de pouca significância estatística. A etapa seguinte tem o nome de *Multiple-path search* e engloba a simulação de um número altíssimo de modelos e a subsequente triagem dos mesmos através da técnica de *tree search* como ilustrado nas figuras 1 e 2. Para fazer a checagem dos galhos e ramificações, o *Autometrics* arma-se de 3 estratégias distintas chamadas de *Pruning*, *Bunching* e *Chopping*. Elas terão o papel de ditar a forma e o ritmo de como a eliminação de variáveis vai ocorrendo: por vezes as variáveis podem ser deletadas uma a uma, enquanto em outros momentos um ramo da árvore pode ser descartado e existem ainda situações onde blocos inteiros de regressores são deixados de lado. A rotina é então repetida novamente para conferência.

Figura 1 – *Autometrics - Tree search 1*



Fonte: Doornik, 2009

Figura 2 – *Autometrics - Tree search 2*

Fonte: Doornik, 2009

Com os regressores e as defasagens insignificantes já descartadas é hora do *Encompassing test*; os modelos que sobreviveram são postos frente ao modelo geral irrestrito obtido no passo 1 de modo a aferir o quanto de informação se perdeu durante a eliminação de variáveis. Volta-se ao estágio inicial de todo o processo onde é feita uma nova triagem para que novos modelos sejam descobertos.

Na última rodada de testes, chamada de *Tie breaker*, os modelos finalistas são comparados por critérios de informação (Schwarz como default, mas AIC ou Hannan-Quinn também podem ser escolhidos) para que um modelo final que abranja os demais emergja. Podem existir casos onde um modelo não consiga dominar os demais e consequentemente o algoritmo relatará mais de um modelo. Caso realmente não haja um que se sobressaia, existe ainda a possibilidade de se aglutinar todos os modelos finalistas e fazer disto um ponto de partida para uma nova rodada de triagem.

Junto ao modelo final, o algoritmo também fornece os resultados de testes mostrando as estatísticas referentes a autocorrelação, normalidade dos resíduos e heterocedasticidade.

4.3.2 IIS – *Impulse Indicator Saturation*

Um módulo bastante importante do *Autometrics* e que também é parte integrante do trabalho recebe o nome de *Impulse Indicator Saturation (IIS)*; desenvolvido inicialmente em Santos et al. (2008), este algoritmo é responsável por detectar *outliers* e quebras estruturais na série e tem a capacidade de identificar corretamente até 20 *outliers* para cada 100 observações amostrais, independentemente deles estarem localizados no começo, meio ou final da amostra.

Castle et al. (2012) evidenciam que o *IIS* mostra-se muito efetivo na identificação de mudanças locais (*local shifts*), funciona bem para distribuições com cauda pesada e como já mencionado acima, é muito eficiente na identificação de *outliers*.

Seguindo a *LSE tradition* e caminhando do geral para o específico, esta rotina computacional parte do pressuposto que toda e qualquer observação da amostra é passível de ser uma variável *dummy*. Consequentemente, o número de estimadores potenciais torna-se maior que o número de observações e este fato pode acarretar diversos empecilhos à regressão. Para resolver este problema de identificação, a implementação do *IIS* acontece da seguinte forma:

1 - A amostra é particionada em blocos, como por exemplo em duas metades ou em três terços, onde as todas as observações são ao mesmo tempo ortogonais entre si e candidatas a *dummy*; assim, para uma amostra de tamanho t dividida em 3 subconjuntos A, B e C. Sejam $A = \{I_1, I_2, \dots, I_{t/3}\}$, $B = \{I_{(t/3+1)}, I_{(t/3+2)}, \dots, I_{2t/3}\}$ e $C = \{I_{(2t/3+1)}, I_{(2t/3+2)}, \dots, I_t\}$

2 - Estima-se os parâmetros usando o algoritmo de identificação para cada uma das metades de forma independente;

3 - Os estimadores \hat{A} , \hat{B} e \hat{C} provenientes de cada subconjunto são obtidos a partir do algoritmo de seleção de modelos (*Autometrics*)

4 - Analisando todos os possíveis arranjos existentes entre as partições, cria-se o vetor de parâmetros contendo aqueles que estão presentes em todos os arranjos como mostra o exemplo abaixo

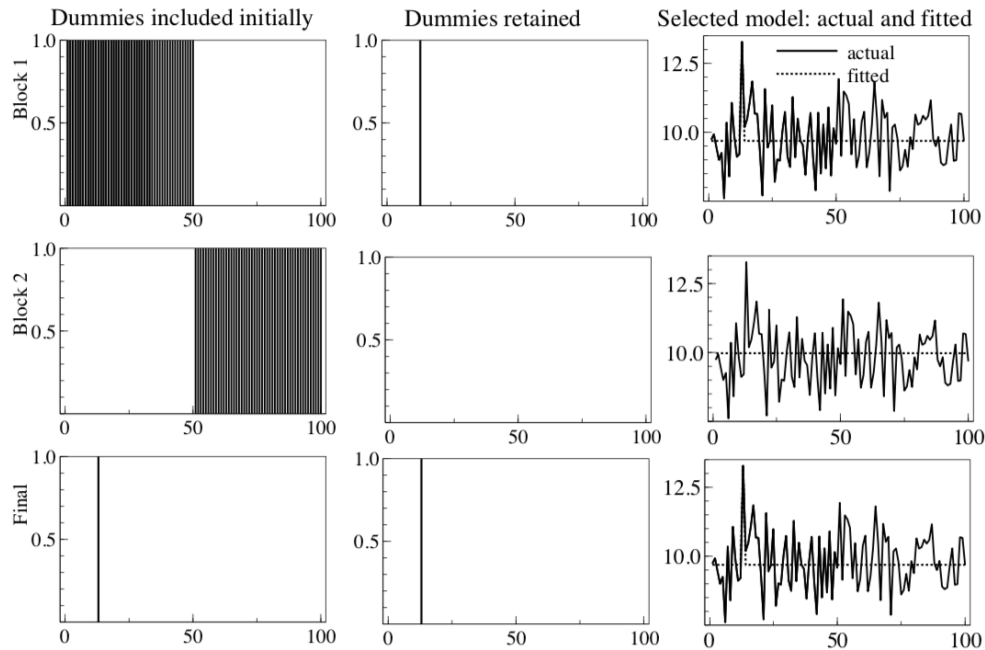
Figura 3 – Algoritmo *IIS* – *Impulse Indicator Saturation*

$$\begin{array}{lll}
 A \cup B & \text{model selection} \rightarrow & G_1 \\
 A \cup C & \text{model selection} \rightarrow & G_2 \\
 B \cup C & \text{model selection} \rightarrow & G_3 \\
 \hline
 & & G_1 \cup G_2 \cup G_3 \text{ model selection} \rightarrow S
 \end{array}$$

Fonte: Hendry e Doornik, (2014)

No entanto, a divisão da amostra em em três terços, figura 3 ou duas metades como na figura 4 não passa de um mero exemplo didático. Na prática o algoritmo testa e compara uma enorme combinação de partições.

Figura 4 – IIS em ação - 2 períodos



Fonte: Hendry e Doornik, (2014)

Para ilustrar o poder deste algoritmo, Hendry e Doornik (2014) usam uma amostra com apenas 139 observações e 504 possíveis estimadores. Ao escolherem um $\alpha = 0,001$; os autores concluem que estatisticamente o modelo final não reterá nenhuma variável não significativa em 60% dos casos, reterá uma variável não significativa em 30% dos casos, ele reterá duas em 8% dos casos e em um percentual negligenciável ele reterá mais que duas.

Johansen, Nielsen (2009) mostram que uma vez rodado o procedimento, os estimadores retidos no modelo final são estatisticamente robustos e possuem um nível de eficiência igual a $(1 - \alpha)\%$. Além disso, como para amostras grandes o custo de se reter uma variável *dummy* não significativa é baixo (equivalente a remover uma observação da amostra), é possível usar um p-valor bem mais baixo do que em regressões lineares tradicionais.

4.3.3 Escolha do p-valor das regressões

Dentre as características importantes de um algoritmo de seleção de modelos está a sua capacidade de reter variáveis que são efetivamente significativas e descartar aquelas que não são. Porém, por melhor que seja, o algoritmo também está fadado a falhas, ou seja, a cometer estes erros chamados de Erro Tipo 1 (reter um regressor não significativo) e Erro Tipo 2 (descartar um regressor significativo). Uma forma usual de se tentar balancear a ocorrência desses erros é através da definição do p-valor ou nível de significância; acontece que geralmente ao tentarmos

diminuir a ocorrência de um deles, estamos automaticamente aumentando a chance do outro acontecer.

Nymoen (2020), mostra que o algoritmo de seleção *Autometrics* consegue mitigar este problema; segundo o autor é possível escolher valores para o p-valor de forma a manejar a quantidade média de Erros Tipo 1 que aceitaremos sem que haja perda de eficiência.

Faz-se então a escolha do número de falsos regressores que em média serão aceitos no modelo e utiliza-se a seguinte equação para encontrarmos o p-valor desejado:

$$k^{irr} = k_{total}\alpha$$

$$\alpha = \frac{k^{irr}}{k_{total}} \quad (4.15)$$

onde k^{irr} representa o número de regressores irrelevantes aceitáveis, k_{total} representa o número máximo de regressores que o modelo pode ter e α denota o p-valor da regressão

Com isso, cada modelo potencial terá um p-valor próprio que leva em consideração o número de regressores potenciais máximo de cada um dos modelos, de forma a deixar a comparação mais justa, pois no final, independentemente do modelo observado, saberemos que todos terão retidos em média o mesmo número de previsores não significativos, no nosso caso apenas um único falso estimador.

4.4 CRITÉRIOS DE INFORMAÇÃO PARA ESCOLHA DE MODELOS

Dentre as diferentes classes de modelos otimizadas pelo *Autometrics*, ainda nos resta a tarefa de criar algum tipo de *ranking* que permita escolher qual ou quais modelos se sobressaem perante os outros, dominando assim os demais. Esta classificação acontecerá de acordo com o resultado que cada modelo obtiver nos seguintes testes: AIC, SBC e HQC.

Para todos os três testes, os modelos que obtiverem a menor estatística devem ser os escolhidos. Segundo Pesaran (2015), dentre os testes de critérios de informação ilustrados, o SBC tende a ser o mais parcimonioso quando o tamanho da amostra $T \geq 8$, enquanto o AIC tende a ser o menos parcimonioso; HQC por sua vez estaria entre os dois.

Akaike Information Criterion (AIC)⁶

Nos casos de modelos regressão de uma única equação, como no nosso caso, a estatística AIC pode ser escrita como:

$$AIC_{\sigma} = \log(\tilde{\sigma}^2) + \frac{2p}{T} \quad (4.16)$$

Onde T = tamanho da amostra, $p \equiv \text{dimensao}$, $\tilde{\sigma}^2$ é o estimador de Máxima-Verossimilhança da variância dos distúrbios da regressão, representado por: $\tilde{\sigma}^2 = \mathbf{e}'\mathbf{e}/T$

Schwarz Bayesian Criterion (SBC)⁷

A estatística do teste SBC é dada por:

$$SBC_{\sigma} = \log(\tilde{\sigma}^2) + \left(\frac{\log T}{T}\right)p \quad (4.17)$$

Hannan-Quinn Criterion (HQC)⁸

Este critério é definido da seguinte forma:

$$HQC_{\sigma} = \log \tilde{\sigma} + \left(\frac{2 \log \log T}{T}\right)p \quad (4.18)$$

Onde $l_T(\tilde{\theta})$ é o valor máximo da função de *log-likelihood* e $\tilde{\theta}$ é o estimador de máximo verossimilhança de θ .

4.5 INDEX-TEST DE NÃO LINEARIDADE

Como descrito anteriormente, o modelo que serve como base é um AR composto de doze defasagens e onze variáveis dummies sazonais, sendo assim um modelo linear. Neste trabalho estamos testando se ganhos informacionais acontecem quando acrescentamos uma variável representando a volatilidade dos mercados financeiros e quando passamos de um modelo linear para um não-linear. Faz-se assim necessário constatar se a especificação de um modelo linear parece descrever bem ou não a DGP.

⁶ Akaike, H. (1974) - *A new look at the statistical model identification*

⁷ Schwarz, G.E. (1978) - *Estimating the dimension of a model*

⁸ Hannan, E.J. e Quinn, B.G. (1979) - *The Determination of the order of an autoregression*

Caso a DGP seja um processo linear, parte dos parâmetros do modelo não linear STAR acaba não sendo identificados corretamente, tornando-os inconsistentes. Quando isto acontece, os modelos da classe STAR tenderão a fornecer previsões muito mais pobres que modelos AR bem especificados. Faz-se então, necessária, antes da aplicação de qualquer modelo não linear, a execução de procedimentos que testem a linearidade da série, Teräsvirta et al. (2005).

Muitos são os testes de não linearidade propostos pela literatura acadêmica: McLeod-Li (1983)⁹, Keenan (1985)¹⁰, Tsay (1986)¹¹ e Luukkonen et al (1988) entre outros. Optamos por fazer uso daquele proposto por Castle, Hendry (2010). Os autores propõem um teste *port-manteau* baseado em um polinômio de terceira ordem com funções exponenciais adicionais, chamado de *Index test*. Este teste é capaz de lidar com algumas das limitações mais comumente encontradas nos testes de linearidade, como por exemplo a alta dimensão, a colinearidade dos dados e não se saber *a priori* qual a forma funcional do processo não linear. O procedimento analisa conjuntamente os componentes principais dos possíveis regressores lineares com suas funções não-lineares e identifica se o modelo linear está bem especificado ou se haveria ganho informacional ao adicionarmos componentes não lineares ao sistema.

Seja \mathbf{x}_t o vetor de regressores lineares e \mathbf{z}_t o vetor de seus componentes principais onde

$$\mathbf{x}_t \sim D_n [\mu, \Omega] \quad (4.19)$$

e Ω é a matriz simétrica e positiva definida da variância-covariância. Pode-se fatorar $\Omega = \mathbf{H}\mathbf{\Lambda}\mathbf{H}'$ em que \mathbf{H} é a matriz dos autovetores de Ω e $\mathbf{\Lambda}$ seus respectivos autovalores, de forma que $\mathbf{H}\mathbf{H}' = \mathbf{I}_n$. Como $\mathbf{\Lambda}^{-\frac{1}{2}}\mathbf{H}'\Omega\mathbf{H}\mathbf{\Lambda}^{-\frac{1}{2}} = \mathbf{I}_n$. Então seja:

$$\mathbf{z}_t^* = \mathbf{\Lambda}^{-\frac{1}{2}}\mathbf{H}' (\mathbf{x}_t - \mu) \sim D_n [\mathbf{0}, \mathbf{I}] \quad (4.20)$$

Como Ω é desconhecida, sua estimativa $\hat{\Omega}$ é usada para o cálculo de \mathbf{z}_t .

$$\mathbf{z}_t = \hat{\mathbf{\Lambda}}^{-\frac{1}{2}}\hat{\mathbf{H}}' (\mathbf{x}_t - \hat{\mu}) \sim D_n [\mathbf{0}, \mathbf{I}] \quad (4.21)$$

⁹ Mcleod, A.I., Li, W.K. (1983) - *Diagnostic checking ARMA time series models using squared-residual autocorrelations*

¹⁰ Keenan, D.M. (1985) - *A Tukey nonadditivity-type test for time series nonlinearity*

¹¹ Tsay, R.S. (1986) - *Nonlinearity tests for time series*

Observa-se que $\mathbf{z}_{i,t}$ é uma combinação normalizada e ortogonal de $\mathbf{x}_{i,t}$. Para o componente quadrático do *Index-test*, utiliza-se $u_{1,i,t} = z_{i,t}^2$. Como a não linearidade pode se apresentar de diferentes maneiras e o polinômio do teste é de ordem 3, faz-se necessária a adição do termo $u_{2,i,t} = z_{i,t}^3$ para captar parte da assimetria da distribuição. Por fim, $u_{3,i,t} = e^{-|z_{i,t}|} z_{i,t}$ é o componente exponencial do teste.

Sob a hipótese nula, a estatística deste teste *portmanteau* será dada por um teste F de baixa dimensão com regressores fixos $\mathbf{k}_1 = \mathbf{k}_2 = \mathbf{k}_3 = 0$ e $e_t = \varepsilon_t$:

$$y_t = \beta_0 + \beta' \mathbf{x}_t + \mathbf{k}'_1 \mathbf{u}_{1,t} + \mathbf{k}'_2 \mathbf{u}_{2,t} + \mathbf{k}'_3 \mathbf{u}_{3,t} + e_t \quad (4.22)$$

e sob a alternativa¹²:

$$y_t = \beta_0 + \sum_{i=1}^n \left(\beta_i z_{i,t} + \kappa_{1,i} z_{i,t}^2 + \kappa_{2,i} z_{i,t}^3 + \kappa_{3,i} z_{i,t} e^{-|z_{i,t}|} \right) + e_t$$

$$y_t \approx \beta_0 + \sum_{i=1}^n \left(\beta_i z_{i,t} + \gamma_i z_{i,t} (1 - |z_{i,t}|) + \kappa_{1,i} z_{i,t}^2 + \kappa_{2,i} z_{i,t}^3 + \theta_i z_{i,t}^3 (1 - \frac{1}{3} |z_{i,t}|) \right) + e_t \quad (4.23)$$

Como resultado do teste, o modelo será constante para $\beta = \mathbf{k}_1 = \mathbf{k}_2 = \mathbf{k}_3 = 0$; ele linear se $\mathbf{k}_1 = \mathbf{k}_2 = \mathbf{k}_3 = 0$; terá a forma quadrática caso $\mathbf{k}_2 = \mathbf{k}_3 = 0$; será um modelo cúbico se $\mathbf{k}_3 = 0$ e finalmente terá forma bi-linear e bi-quadrático quando $\beta = \mathbf{k}_2 = 0$

Comparativamente, testes de linearidade baseados na expansão de Volterra de segunda ordem funcionam muito bem para um processo quadrático e com amostras grandes, mas tem pouca potência para detectar não linearidades cúbicas ou exponenciais. Caso o teste seja baseado na expansão de Volterra de terceira ordem, ele conseguirá detectar a não linearidade em mais direções, mas não conseguirá lidar com um número muito grande de regressores. Já o *Index test* apresentado tende a gerar um resultado igual ou melhor em todas estas situações a ainda por cima trabalha a redução da dimensionalidade, que por sua vez torna o procedimento computacionalmente mais simples, Castle, Hendry (2010).

¹² Mudança de notação na hipótese alternativa seguindo Castle, J. e Hendry, D. (2010) - *A low-dimension portmanteau test for non-linearity*

4.6 PREVISÕES DAS SÉRIES

Com os modelos já selecionados através do *Autometrics* e dos critérios de informação, o exercício de previsão percorre um horizonte de 24 meses sem que haja qualquer alteração nas especificações dos modelos. Utiliza-se o procedimento conhecido como *One step ahead* onde as estimativas das observações são previstas uma a uma. Assim que o *forecast* de uma observação é calculado, mede-se o erro de previsão da mesma e este valor previsto é substituído pelo valor real da variável antes que a previsão da observação seguinte seja computada.

Tradicionalmente, compara-se diferentes previsões olhando-se para o valor dos seus erros quadráticos médios ou erros absolutos médios. Ocorre que esta abordagem não leva em consideração dois pontos importantes. O primeiro é o de que notoriamente erros de previsão podem ter caráter assimétrico, isto implica em dizer que dependendo da série estudada os erros positivos e negativos são vistos com pesos diferentes.

O caso clássico é o do banqueiro central que toma decisões de política monetária levando em consideração o comportamento os erros de previsão da inflação. Dependendo de seu mandato e de sua função de perda, ele poderá ser mais sensível a erros de previsão positivos ou negativos.

No segundo ponto, temos que embora seja possível ver qual dos modelos obtém a previsão mais precisa numericamente comparando os valores do erro quadrático ou absoluto; esta comparação nada nos diz a respeito da significância estatística destas diferenças. Tentando mitigar esta deficiência, incluiremos também o teste Diebold-Mariano para checar se as diferenças de previsão encontradas entre os modelos são estatisticamente significantes.

4.6.1 Teste de Diebold e Mariano (DM)

Conforme definido em Diebold, Mariano (2002) e Diebold (2015), considere a série de t observações dada por $X = x_1, x_2, x_3, \dots, x_{t-1}, x_t$ cujas previsões são calculadas por dois modelos distintos gerando

$$\hat{X}_1 = \hat{x}_{(1,1)}, \hat{x}_{(1,2)}, \hat{x}_{(1,3)}, \dots, \hat{x}_{(1,t-1)}, \hat{x}_{(1,t)} \text{ e } \hat{X}_2 = \hat{x}_{(2,1)}, \hat{x}_{(2,2)}, \hat{x}_{(2,3)}, \dots, \hat{x}_{(2,t-1)}, \hat{x}_{(2,t)}$$

Sejam os erros das respectivas previsões dados pelos vetores E_1 e E_2 , tais que

$$E_i = e_{(i,1)}, e_{(i,2)}, e_{(i,3)}, \dots, e_{(i,t-1)}, e_{(i,t)} \text{ com } e_{(i,t)} = x_t - \hat{x}_{(i,t)}$$

A partir dos erros de previsão, calcula-se uma função de perda *loss function* para levar em conta a importância da assimetria dos erros, pois costumeiramente encontramos situações onde o peso de $e_t > 0$ é diferente do peso de $e_t < 0$. Para facilitar a notação, vamos assumir que a função de perda $g(x_t, \hat{x}_{(i,t)})$ possa ser interpretada com uma função relacionada diretamente aos erros de previsão; neste caso a *loss function* poderá ser reescrita como $g(e_{(i,t)})$

A hipótese nula do teste assume que estatisticamente as funções perdas das duas previsões são iguais, ou seja, $E[g(e_{(1,t)})] = E[g(e_{(2,t)})]$. Definindo $d_t = [g(e_{(1,t)})] - E[g(e_{(2,t)})]$, temos que sob a nula $E[d_t] = 0$.

Caso d_t seja estacionária em covariância e tenha memória curta, pode-se deduzir que assintoticamente para grandes amostras, sua média $\bar{d} = \frac{1}{T} \sum_{t=1}^T d_t$ será normalmente distribuída. Neste caso, o teste DM será dado por:

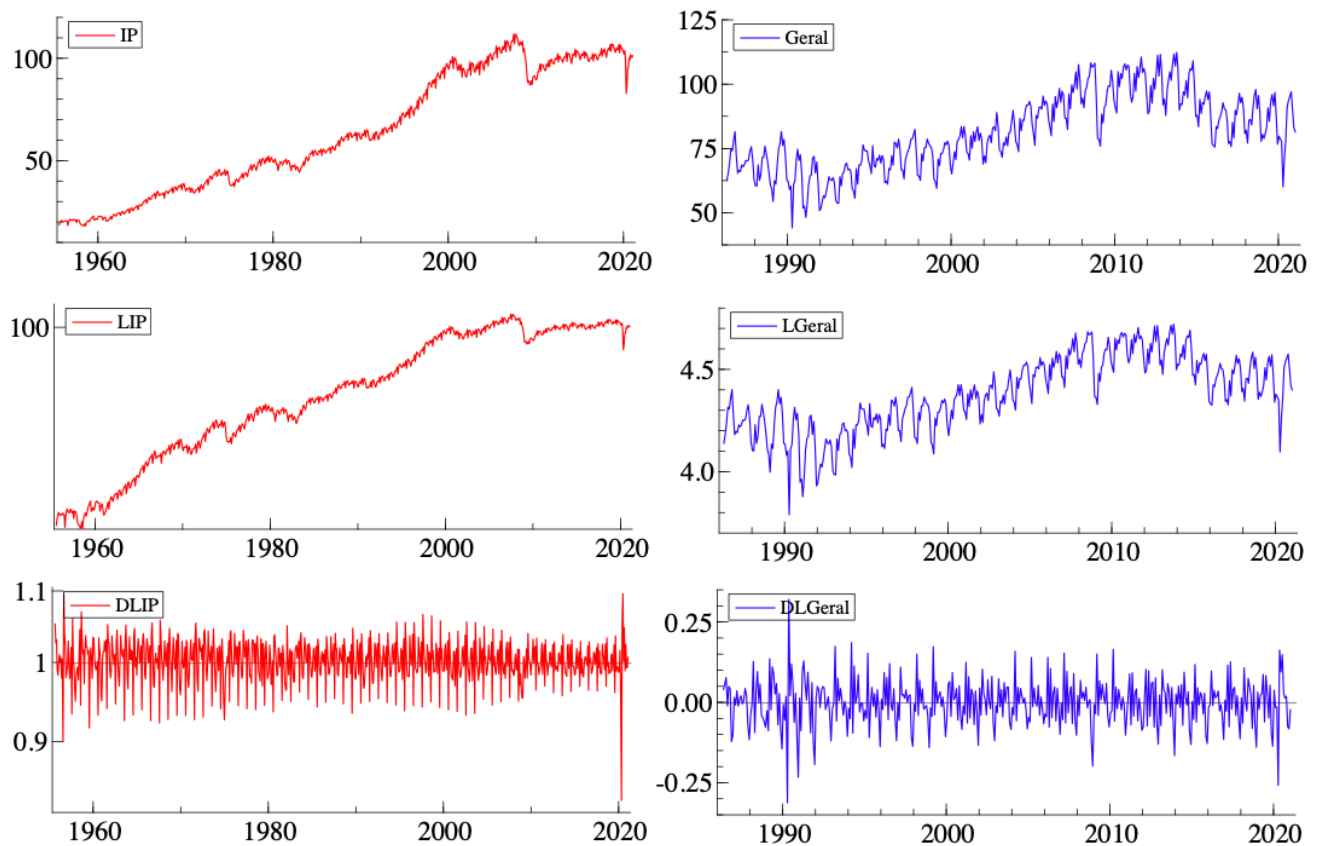
$$DM = \frac{\bar{d}}{\hat{\sigma}_d} \rightarrow N(0, 1) \quad (4.24)$$

5 RESULTADOS

Todos o resultados das regressões bem como os testes estatísticos com exceção do teste KPSS de raiz unitária foram realizados no *software Oxmetrics*® 8.0. O teste KPSS foi calculado no *software R* com o auxílio da biblioteca *tseries*. Antes de passarmos para as estimações dos modelos, serão mostrados os detalhes de alguns gráficos para a série de produção industrial brasileira e norte-americana bem como os resultados dos testes estatísticos confirmando a estacionariedade das mesmas.


Na parte superior da figura 5 temos os gráficos da produção industrial em nível, pode-se ver que aparentemente ambas (principalmente a americana) apresentam tendência de crescimento ao longo do tempo. Na parte central estão plotadas as mesmas séries, mas depois da transformação logarítmica. Por fim, na parte inferior, ambas são exibidas já diferenciadas e dando indícios de processos estacionários.

Figura 5 – Séries de Produção Industrial em nível, log e $\Delta \log$: Brasil (azul) e Estados Unidos (vermelho)




Olhando para os gráficos de auto-correlação e auto correlação da figura 6 podemos ver que as séries em níveis parecem ter memória infinita, sem decaimento da auto-correlação, indicando que provavelmente se tratam de séries não estacionárias. Já a figura 7 mostra que as a transformação logarítmica e diferenciação faz com que ambas fiquem mais bem comportadas, mas ainda apresentando sazonalidade que será tratada com a inclusão de variáveis *dummies*.

Figura 6 – ACF e PACF - Séries de Produção Industrial em nível: Brasil e EUA



Fonte: Elaboração própria

Figura 7 – ACF e PACF - Séries de Produção Industrial em primeira diferença: Brasil e EUA



Fonte: Elaboração própria

Os resultados dos testes ADF e KPSS estão relatados na tabela 1. Pode-se observar que para o ADF a hipótese nula de não estacionariedade foi rejeitada tanto para a série brasileira como para a americana a um nível de significância de 1% respectivamente. Já no caso do KPSS onde a hipótese nula e alternativa são invertidas, o teste não rejeita a nula de nenhuma das duas a 10% tanto para o KPSS em nível como KPSS em tendência.

Tabela 1 – Confirmação de estacionariedade

Índice	ADF	KPSS-nível	KPSS-trend
$\Delta Prod. Ind. - BRA$	-14,246* * *	0,019626*	0,010802*
$\Delta Ind. Prod. - EUA$	-10,13* * *	0,30706*	0,0026122*

Fonte: Elaboração própria

Já enfatizado algumas vezes nos capítulos anteriores é o fato de só fazer sentido a introdução de métodos não lineares depois da realização de testes que confirmem ser realmente o caso. Sendo assim, foi montado um modelo AR tradicional de 12 defasagens contendo a amostra inteira dos dados. Para a índice brasileiro foram um total de 418 observações cobrindo de abril de 1986 a janeiro de 2021, enquanto para o índice americano corresponde a 787 observações começando em julho de 1955 e terminando na mesma data. Uma vez otimizado usando-se o algoritmo *Autometrics*, o modelo foi submetido ao *Index-test* para que fosse averiguada a não linearidade dos dados. A tabela 2 mostra que a hipótese nula do *Index-test* de linearidade foi rejeitada em ambos os casos para um nível de significância de 5%.

Tabela 2 – *Index test* de não linearidade

Índice	Teste-F	Qui-Quadrado	RSS
$\Delta Prod. Ind. - BRA$	F(51,308) 1,8133 [0,0012]**	Chi ² (51) 93,525[0,0003] * *	0,1991
$\Delta Ind. Prod. - EUA$	F(48,614) 2,1746 [0,0000]**	Chi ² (48) 112,46[0,0000] * *	0,0382

Fonte: Elaboração própria

5.1 ESTIMAÇÃO

Esta seção apresenta os resultados dos modelos estimados e está separada por país e por evento. Para cada um dos eventos foram estimados 6 modelos diferentes já descritos no capítulo metodológico e como elemento facilitador usaremos a seguinte nomenclatura para identificar cada um deles:

Modelo 1: AR linear base de 12 defasagens e 11 variáveis *dummies* sazonais que serve como *benchmark* do estudo. (24 variáveis)

Modelo 2: AR linear como o *benchmark* + volatilidade realizada. (27 variáveis)

Modelo 3: STAR contendo até 12 defasagens, *dummies* sazonais e termos cruzados da primeira e segunda defasagem da série com as demais. (57 variáveis)

Modelo 4: STAR de 12 defasagens + *dummies* sazonais + volatilidade realizada + termos cruzados entre a primeira e segunda defasagem da volatilidade com os termos defasados da produção industrial. (65 variáveis)

Modelo 5: igual ao Modelo 3 acrescido da volatilidade realizada (60 variáveis)

Modelo 6: STAR de 12 defasagens + *dummies* sazonais + volatilidade realizada + termos cruzados entre a primeira e segunda defasagem da volatilidade com os termos defasados da produção industrial + termos cruzados da primeira e segunda defasagem da série com as demais (86 variáveis)

O número de regressores indica a quantidade máxima de variáveis de cada um dos modelos sem levar em conta as próprias observações da série. Sendo assim, todos eles serão apresentados já com redução de defasagens, de dimensão e com inclusão de variáveis *dummies* pontuais selecionadas após otimização feita pelo *Autometrics*.

O valor do α usado em cada uma das regressões está reportado na tabela a seguir:

Tabela 3 – Modelos e seus respectivos α (por evento)

Evento	Num. Obs.	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
BRA - GFC	255	0,00360	0,00356	0,00322	0,00313	0,00318	0,00294
BRA - Dilma	328	0,00285	0,00282	0,00260	0,00255	0,00258	0,00242
BRA - Covid	394	0,00240	0,00238	0,00224	0,00220	0,00222	0,00210
USA - GFC	624	0,00155	0,00154	0,00147	0,00145	0,00146	0,00141
USA - Covid	763	0,00127	0,00127	0,00122	0,00121	0,00122	0,00118

Fonte: Elaboração própria

As tabelas contendo os resultados completos de todas as regressões, bem como das previsões podem ser encontradas no Apêndice A. Conjuntamente às regressões, estão discriminados os seguintes testes de má especificação¹ dos modelos/resíduos gerados pelo *Autometrics*: teste de auto correlação serial, teste de normalidade (Jarque-Bera), teste de heterocedasticidade condicional autorregressiva, teste de White e teste da forma funcional de Ramsey (Reset).

¹ Misspecification test

5.1.1 Brasil

Great Financial Crisis - GFC:

Foram analisadas 255 observações indo de abr/1986 à jun/2007. Nesta primeira estimação, o Modelo 1, que serve como base de comparação, saiu-se relativamente bem ao ser o escolhido pelo critério de informação AIC. Este fato evidencia a dificuldade que é superar um modelo AR bem especificado, como bem evidenciado, por exemplo, em Stock e Watson (1998) e Rech (2002).

Olhando apenas para os processos lineares 1 e 2, vemos que pelo critério de informação, o Modelo 1 domina completamente o Modelo 2, possuindo a estatística de menor valor por SBC, HQC e AIC. Neste caso, vemos que a adição do componente da volatilidade realizada, embora seja uma variável relevante no Modelo 2, não parece trazer um conjunto de informações que seja estatisticamente significativa.

Tabela 4 – Brasil: GFC - Modelos lineares

Modelo	Schwarz	HQC	AIC
Modelo 1	-3,8145<	-4,0728<	-4,2470<
Modelo 2	-3,7755	-4,0338	-4,2080

Fonte: Elaboração própria

Olhando agora para todos os modelos de forma simultânea, temos que o Modelo 1 e o Modelo 4 tem um desempenho bastante similar. Cada um leva vantagem em um dos critérios e possui a segunda melhor colocação em outro. Já o Modelo 6 domina os demais segundo o HQC.

Tabela 5 – Brasil: GFC - GERAL

Modelo	Schwarz	HQC	AIC
Modelo 1	-3,8145	-4,0728	-4,2470<
Modelo 4	-3,8359<	-4,0770	-4,2396
Modelo 6	-3,8063	-4,0818<	-4,2377

Fonte: Elaboração própria

Na tabela 6 estão discriminados os regressores relevantes de cada um dos modelos já otimizados, incluindo todas as *dummies* pontuais selecionada pelo algoritmo *IIS*. Ao compararmos os 4 métodos da classe STAR (tabela 7) pelos mesmos critérios de informação, temos que o Modelo 6 leva vantagem segundo HQC e AIC enquanto o 4 é o escolhido pelo SBC.

Tabela 6 – BRASIL - GFC Variáveis relevante por modelo

MODELO 1	MODELO 2	MODELO 3	MODELO 4	MODELO 5	MODELO 6
DLIP_1	DLIP_1	DLIP_1	DLIP_1	DLIP_1	DLIP_1
DLIP_4	DLIP_7	DLIP_7	DLIP_7	DLIP_7	DLIP_4
DLIP_7	DLIP_12	DLIP_8	CSeasonal	DLIP_12	DLIP_7
CSeasonal	Constant	DLIP_12	CSeasonal_1	CSeasonal	DLIP_8
CSeasonal_1	CSeasonal	CSeasonal	CSeasonal_2	CSeasonal_1	DLIP_12
CSeasonal_2	CSeasonal_1	CSeasonal_1	CSeasonal_3	CSeasonal_2	CSeasonal_2
CSeasonal_3	CSeasonal_2	CSeasonal_2	CSeasonal_4	CSeasonal_3	CSeasonal_4
CSeasonal_4	CSeasonal_3	CSeasonal_3	CSeasonal_5	CSeasonal_4	CSeasonal_5
CSeasonal_5	CSeasonal_4	CSeasonal_4	CSeasonal_6	CSeasonal_5	CSeasonal_6
CSeasonal_6	CSeasonal_5	CSeasonal_5	CSeasonal_7	CSeasonal_6	CSeasonal_7
CSeasonal_7	CSeasonal_6	CSeasonal_6	CSeasonal_8	CSeasonal_7	CSeasonal_8
CSeasonal_8	CSeasonal_7	CSeasonal_7	CSeasonal_9	CSeasonal_8	CSeasonal_9
CSeasonal_9	CSeasonal_8	CSeasonal_8	CSeasonal_10	CSeasonal_9	CSeasonal_10
CSeasonal_10	CSeasonal_9	CSeasonal_9	VOL_1*DLIP_1	CSeasonal_10	DLIP_2 ²
I:1988(6)	CSeasonal_10	CSeasonal_10	VOL_2*DLIP_2	Vol_Ibov_1	DLIP_6 ²
I:1989(2)	Vol_Ibov_1	DLIP_3 ²	VOL_2*DLIP_3	DLIP_3 ²	DLIP_11 ²
I:1989(6)	I:1988(6)	I:1988(6)	I:1988(6)	I:1988(6)	VOL_1 ²
I:1990(3)	I:1989(6)	I:1990(3)	I:1989(6)	I:1989(6)	VOL_1*DLIP_6
I:1990(4)	I:1990(3)	I:1990(4)	I:1990(3)	I:1990(3)	VOL_2*DLIP_2
I:1990(5)	I:1990(4)	I:1990(5)	I:1990(4)	I:1990(4)	DLIP_1*DLIP_9
I:1990(6)	I:1990(5)	I:1990(6)	I:1990(5)	I:1990(5)	DLIP_1*DLIP_12
I:1990(7)	I:1990(6)	I:1990(11)	I:1990(7)	I:1990(6)	I:1989(6)
I:1990(11)	I:1990(7)	I:1990(12)	I:1990(11)	I:1990(11)	I:1990(3)
I:1991(4)	I:1990(11)	I:1991(4)	I:1991(4)	I:1990(12)	I:1990(4)
I:1991(9)	I:1990(12)	I:1991(9)	I:1991(9)	I:1991(4)	I:1990(5)
I:1991(12)	I:1991(4)	I:1992(2)	I:1991(12)	I:1991(12)	I:1990(12)
I:1992(2)	I:1991(12)	I:1995(5)	I:1992(2)	I:1992(2)	I:1991(1)
I:1992(3)	I:1992(2)		I:1995(5)	I:1992(3)	I:1992(2)
I:1994(12)	I:1994(12)			I:1995(5)	I:1993(3)
I:1995(5)	I:1995(5)				

Fonte: Elaboração própria

Tabela 7 – Brasil: GFC - Modelos não-lineares

Modelo	Schwarz	HQC	AIC
Modelo 3	-3,7739	-4,0063	-4,1631
Modelo 4	-3,8359<	-4,0770	-4,2396<
Modelo 5	-3,7814	-4,0311	-4,1995
Modelo 6	-3,8063	-4,0818<	-4,2377

Fonte: Elaboração própria

Focando nos três modelos finais, o único a não apresentar nenhuma anomalia nos resíduos foi o Modelo 4. O Modelo 1 apontou presença de auto correlação serial a 10% de significância enquanto no Modelo 6 o teste de ausência de heterocedasticidade condicional autorregressiva rejeitou H_0 também a 10%.

Crise Econômica do governo Dilma 2014-2015:

Embora em 2013 o país já estivesse patinando economicamente e a crise política instaurada, a economia só entrou "oficialmente" em recessão no segundo trimestre de 2014. Desta forma, ao escolhemos julho de 2013 como base de estimação dos modelos, garantimos que a

previsão contenha um período de aproximadamente 12 meses que antecede o início da recessão e mais 12 meses já dentro do período recessivo. O total de observações começando em abril de 1986 é igual a 328 e diferentemente do que aconteceu na estimação dos modelos para a crise financeira de 2008, desta vez o *benchmark* foi amplamente dominado, vide tabelas 8 e 9 tanto pelo Modelo 2 como por todos os processos STAR. Além do mais, os resíduos do Modelo 1 indicaram que o modelo sofre tanto de auto correlação serial como resíduos heterocedásticos a 10% de significância; e de não normalidade dos resíduos a 5%.

Tabela 8 – Brasil: Crise Dilma - Modelos lineares

Modelo	Schwarz	HQC	AIC
Modelo 1	-3,8210	-3,9998	-4,1188
Modelo 2	-3,8736<	-4,1311<	-4,3024<

Fonte: Elaboração própria

Tabela 9 – Brasil: Crise Dilma - Modelos não-lineares

Modelo	Schwarz	HQC	AIC
Modelo 3	-3,9018	-4,1021	-4,2354
Modelo 4	-3,9638	-4,2142	-4,3808
Modelo 5	-3,9790<	-4,2222<	-4,3840<
Modelo 6	-3,9233	-4,1737	-4,3403

Fonte: Elaboração própria

Pela tabela 10 fica claro não só que o Modelo 5 domina completamente todos os demais (por SBC, HQC e AIC), como também que os processos não lineares no geral apresentam uma especificação melhor para este período. Dos três postulantes apresentados nesta tabela, o Modelo 4 é o único a apresentar resíduos com algum problema de especificação, já que o teste de auto correlação serial rejeitou a hipótese nula de ausência de auto correlação a um nível de 10%.

Outro ponto a se notar é a significância estatística das variáveis representando a volatilidade realizada, fazendo-se presente em todos os três modelos mais bem especificados conforme pode ser visto na tabela 11 .

Tabela 10 – Brasil: Crise Dilma - GERAL

Modelo	Schwarz	HQC	AIC
Modelo 4	-3,9638	-4,2142	-4,3808
Modelo 5	-3,9790<	-4,2222<	-4,3840<
Modelo 6	-3,9233	-4,1737	-4,3403

Fonte: Elaboração própria

Tabela 11 – BRASIL - Crise Gov. Dilma - Variáveis relevante por modelo

MODELO 1	MODELO 2	MODELO 3	MODELO 4	MODELO 5	MODELO 6
DLIP_1	DLIP_1	DLIP_1	DLIP_1	DLIP_1	DLIP_1
DLIP_4	DLIP_2	DLIP_2	DLIP_3	DLIP_3	DLIP_4
DLIP_5	DLIP_4	DLIP_3	DLIP_4	DLIP_7	DLIP_7
DLIP_7	DLIP_7	DLIP_4	DLIP_9	Vol_Ibov_1	DLIP_8
CSeasonal	DLIP_8	DLIP_7	CSeasonal	CSeasonal_1	DLIP_9
CSeasonal_1	Constant	DLIP_12	CSeasonal_1	CSeasonal_2	Vol_Ibov_1
CSeasonal_2	CSeasonal	CSeasonal_2	CSeasonal_2	CSeasonal_3	CSeasonal
CSeasonal_3	CSeasonal_1	CSeasonal_4	CSeasonal_3	CSeasonal_4	CSeasonal_1
CSeasonal_4	CSeasonal_2	CSeasonal_5	CSeasonal_4	CSeasonal_5	CSeasonal_2
CSeasonal_5	CSeasonal_3	CSeasonal_6	CSeasonal_5	CSeasonal_6	CSeasonal_3
CSeasonal_6	CSeasonal_4	CSeasonal_7	CSeasonal_6	CSeasonal_7	CSeasonal_4
CSeasonal_7	CSeasonal_5	CSeasonal_8	CSeasonal_7	CSeasonal_8	CSeasonal_5
CSeasonal_8	CSeasonal_6	CSeasonal_9	CSeasonal_8	CSeasonal_9	CSeasonal_6
CSeasonal_9	CSeasonal_7	DLIP_1 ²	CSeasonal_9	CSeasonal_10	CSeasonal_7
CSeasonal_10	CSeasonal_8	DLIP_2 ²	CSeasonal_10	DLIP_2 ²	CSeasonal_8
I:1988(6)	CSeasonal_9	DLIP_6 ²	Vol_Ibov_1	DLIP_5 ²	CSeasonal_9
I:1989(6)	CSeasonal_10	DLIP_11 ²	DLIP_2 ²	DLIP_9 ²	CSeasonal_10
I:1990(3)	Vol_Ibov_1	DLIP_1*DLIP_9	DLIP_6 ²	DLIP_1*DLIP_6	DLIP_1 ²
I:1990(4)	I:1988(6)	DLIP_1*DLIP_12	VOL_1*DLIP_7	DLIP_1*DLIP_9	DLIP_2 ²
I:1990(5)	I:1988(11)	DLIP_2*DLIP_10	VOL_1*DLIP_9	DLIP_1*DLIP_10	DLIP_5 ²
I:1990(6)	I:1989(6)	I:1989(6)	VOL_1*DLIP_12	DLIP_1*DLIP_12	DLIP_7 ²
I:1990(11)	I:1989(7)	I:1990(3)	I:1988(6)	DLIP_2*DLIP_10	DLIP_11 ²
I:1991(4)	I:1990(3)	I:1990(4)	I:1988(12)	I:1988(6)	VOL_1 ²
I:1991(12)	I:1990(4)	I:1990(5)	I:1989(6)	I:1988(10)	VOL_1*DLIP_5
I:1992(2)	I:1990(5)	I:1991(1)	I:1990(3)	I:1989(6)	VOL_1*DLIP_12
	I:1990(6)	I:1991(9)	I:1990(4)	I:1990(3)	VOL_2*DLIP_2
	I:1990(7)	I:1992(6)	I:1990(5)	I:1990(4)	VOL_2*DLIP_3
	I:1990(11)	I:1995(5)	I:1991(4)	I:1990(5)	VOL_2*DLIP_6
	I:1990(12)		I:1991(9)	I:1990(11)	DLIP_1*DLIP_9
	I:1991(4)		I:1991(12)	I:1991(1)	DLIP_2*DLIP_10
	I:1991(12)		I:1992(2)	I:1991(4)	I:1988(10)
	I:1992(2)		I:1992(3)	I:1991(5)	I:1989(6)
	I:1993(3)		I:1992(6)	I:1991(9)	I:1990(3)
	I:1994(3)		I:1994(12)	I:1995(5)	I:1990(4)
	I:1994(12)		I:1995(5)		I:1990(5)
	I:1995(5)				

Fonte: Elaboração própria

Crise Econômica e Sanitária COVID-19:

O número de observações totaliza 394, cobrindo o período de abr/1986 à jan/2019. A análise dos processos lineares novamente mostra que para o caso brasileiro a adição da volatilidade realizada parece trazer benefícios estatisticamente significantes para a estimação do modelo, pois o Modelo 2 mostra-se superior ao Modelo 1 pelos três critérios de informação investigados. Além disso, a variável representando a primeira defasagem da volatilidade acabou se mostrando significativa em todos os modelos para os quais ela estava especificada como um possível regressor. A análise dos resíduos aponta ausência de normalidade tanto para o Modelo 1 quanto para o Modelo 2 (10%) enquanto o Modelo 1 sofre ainda de heterocedasticidade dos erros, também a 10% de significância.

Tabela 12 – Brasil: Crise COVID-19 - Modelos lineares

Modelo	Schwarz	HQC	AIC
Modelo 1	-3,9131	-4,0817	-4,1925
Modelo 2	-3,9399<	-4,1522<	-4,2918<

Fonte: Elaboração própria

A tabela 13 mostra que dentro da categoria dos não lineares, o Modelo 4 tem a melhor estatística de Schwarz enquanto o Modelo 6 lidera segundo os critérios HQC e AIC. Esta acaba sendo a classificação geral, ilustrada na tabela 14, onde além do Modelo 4 e 6, também está presente o Modelo 2. A hipótese nula de resíduos homocedásticos é rejeitada a 10% no Modelo 4, enquanto o Modelo 6 parece mais bem especificado, não apresentando nenhuma alteração nos resíduos.

Tabela 13 – Brasil: Crise COVID-19 - Modelos não-lineares

Modelo	Schwarz	HQC	AIC
Modelo 3	-3,9087	-4,0897	-4,2088
Modelo 4	-3,9737<	-4,1610	-4,2842
Modelo 5	-3,9533	-4,1406	-4,2638
Modelo 6	-3,9544	-4,1792<	-4,3270<

Fonte: Elaboração própria

Tabela 14 – Brasil: Crise COVID-19 - GERAL

Modelo	Schwarz	HQC	AIC
Modelo 2	-3,9399	-4,1522	-4,2918
Modelo 4	-3,9737<	-4,1610	-4,2842
Modelo 6	-3,9544	-4,1792<	-4,3270<

Fonte: Elaboração própria

Como anteriormente a tabela a seguir ilustra todos os regressores incluídos em cada um dos modelos após otimização. Chama a atenção o fato de que, para este período, praticamente todas as variáveis dummies sazonais representando os meses do ano estão presentes em todos os modelos, o que não havia acontecido nas duas primeiras análises.

Tabela 15 – BRASIL - Crise COVID-19 - Variáveis relevante por modelo

MODELO 1	MODELO 2	MODELO 3	MODELO 4	MODELO 5	MODELO 6
DLIP_1	DLIP_1	DLIP_1	DLIP_1	DLIP_1	DLIP_1
DLIP_3	DLIP_3	DLIP_2	DLIP_2	DLIP_2	DLIP_4
DLIP_7	DLIP_7	DLIP_3	DLIP_3	DLIP_4	DLIP_7
DLIP_8	Constant	DLIP_5	CSeasonal	DLIP_5	DLIP_8
CSeasonal	CSeasonal	DLIP_6	CSeasonal_1	DLIP_7	CSeasonal
CSeasonal_1	CSeasonal_1	DLIP_7	CSeasonal_2	DLIP_8	CSeasonal_1
CSeasonal_2	CSeasonal_2	DLIP_9	CSeasonal_3	Vol_Ibov_1	CSeasonal_2
CSeasonal_3	CSeasonal_3	CSeasonal	CSeasonal_4	CSeasonal_1	CSeasonal_3
CSeasonal_4	CSeasonal_4	CSeasonal_1	CSeasonal_5	CSeasonal_2	CSeasonal_4
CSeasonal_5	CSeasonal_5	CSeasonal_2	CSeasonal_6	CSeasonal_3	CSeasonal_5
CSeasonal_6	CSeasonal_6	CSeasonal_3	CSeasonal_7	CSeasonal_4	CSeasonal_6
CSeasonal_7	CSeasonal_7	CSeasonal_4	CSeasonal_8	CSeasonal_5	CSeasonal_7
CSeasonal_8	CSeasonal_8	CSeasonal_5	CSeasonal_9	CSeasonal_6	CSeasonal_8
CSeasonal_9	CSeasonal_9	CSeasonal_6	CSeasonal_10	CSeasonal_7	CSeasonal_9
CSeasonal_10	CSeasonal_10	CSeasonal_7	DLIP_1 ²	CSeasonal_8	CSeasonal_10
I:1988(6)	Vol_Ibov_1	CSeasonal_8	DLIP_2 ²	CSeasonal_9	Vol_Ibov_1
I:1989(6)	I:1987(9)	CSeasonal_9	DLIP_11 ²	CSeasonal_10	DLIP_3 ²
I:1990(3)	I:1988(6)	CSeasonal_10	VOL_1 ²	DLIP_2 ²	VOL_1*DLIP_5
I:1990(4)	I:1988(10)	DLIP_1 ²	VOL_1*DLIP_7	DLIP_1*DLIP_9	VOL_1*DLIP_12
I:1990(5)	I:1989(5)	DLIP_2 ²	VOL_1*DLIP_12	DLIP_1*DLIP_12	VOL_2*DLIP_2
I:1990(6)	I:1989(6)	DLIP_5 ²	VOL_2*DLIP_4	DLIP_2*DLIP_10	DLIP_1*DLIP_2
I:1990(7)	I:1990(3)	DLIP_1*DLIP_9	VOL_2*DLIP_5	I:1989(6)	DLIP_1*DLIP_9
I:1990(11)	I:1990(4)	DLIP_2*DLIP_10	I:1989(6)	I:1990(3)	DLIP_1*DLIP_12
I:1990(12)	I:1990(5)	I:1988(10)	I:1990(3)	I:1990(4)	DLIP_2*DLIP_10
I:1991(4)	I:1990(6)	I:1989(6)	I:1990(4)	I:1990(5)	I:1988(6)
I:1991(9)	I:1990(7)	I:1990(3)	I:1990(5)	I:1990(11)	I:1988(10)
I:1992(2)	I:1990(11)	I:1990(4)	I:1990(11)	I:1990(12)	I:1989(6)
	I:1990(12)	I:1990(5)	I:1992(2)	I:1991(1)	I:1990(3)
	I:1991(4)	I:1991(5)	I:1994(12)	I:1991(5)	I:1990(4)
	I:1991(5)		I:1995(5)	I:1995(5)	I:1990(11)
	I:1991(9)				I:1990(12)
	I:1991(12)				I:1991(4)
	I:1992(2)				I:1991(5)
	I:2008(12)				I:1992(6)
					I:1994(12)
					I:1995(5)

Fonte: Elaboração própria

5.1.2 Estado Unidos

Great Financial Crisis - GFC:

No geral, nosso *benchmark* saiu-se bem nas duas estimações realizadas para a economia norte americana. Com o início da série em jul/1955, foram analisadas um total de 624 observações até jun/2007. Neste episódio, o modelo base acabou dominando todos os demais segundo os critérios HQC e AIC.

A tabela 16 mostra os resultados para os dois processos lineares enquanto a 17 faz o mesmo para os quatro não lineares. Nota-se que dentro da classe STAR o Modelo 4 foi o que apresentou melhor estimação.

Tabela 16 – EUA: GFC - Modelos lineares

Modelo	Schwarz	HQC	AIC
Modelo 1	-6,0239	-6,2270<	-6,3563<
Modelo 2	-6,0251<	-6,1973	-6,3070

Fonte: Elaboração própria

Tabela 17 – EUA: GFC - Modelos não-lineares

Modelo	Schwarz	HQC	AIC
Modelo 3	-6,0191	-6,1913	-6,3009
Modelo 4	-6,0345<	-6,2023<	-6,3091<
Modelo 5	-6,0297	-6,1842	-6,2826
Modelo 6	-6,0253	-6,1931	-6,2999

Fonte: Elaboração própria

Embora tenha se saído bem em relação aos demais processos STAR, o desempenho do Modelo 4 não foi suficiente para superar o *benchmark* segundo os critérios HQC e AIC (conforme evidenciado na tabela 18). Observa-se ainda que o Modelo 2, também linear, mesmo sem conseguir dominar por nenhum dos critérios, saiu-se bem e ao bater 3 dos 4 métodos não lineares. Sendo assim, acabou sendo o terceiro melhor desta estimação.

Focando agora na análise dos erros das regressões, todos os 3 modelos rejeitaram a hipótese nula de homocedasticidade dos resíduos a 10%. O Modelo 2 apresentou ainda uma rejeição à hipótese de ausência de auto correlação serial dos dados também a 10%.

Tabela 18 – EUA: GFC - GERAL

Modelo	Schwarz	HQC	AIC
Modelo 1	-6,0239	-6,2270<	-6,3563<
Modelo 2	-6,0251	-6,1973	-6,3070
Modelo 4	-6,0345<	-6,2023	-6,3091

Fonte: Elaboração própria

Na tabela da próxima página estão listados todos os regressores dos 6 modelos para o período que antecedeu a crise financeira de 2008. Vale notar que mais uma vez a primeira defasagem da volatilidade se mostrou um regressor relevante para todos os modelos pertinentes (2,4,5 e 6).

Tabela 19 – EUA - GFC Variáveis relevante por modelo

MODELO 1	MODELO 2	MODELO 3	MODELO 4	MODELO 5	MODELO 6
DLIP_5	DLIP_6	DLIP_1	DLIP_10	DLIP_1	DLIP_10
DLIP_12	DLIP_12	DLIP_7	DLIP_12	DLIP_7	DLIP_12
Constant	Constant	DLIP_10	Constant	DLIP_10	Constant
CSeasonal_1	DJIA_1	DLIP_12	DJIA_1	DLIP_12	DJIA_1
CSeasonal_2	CSeasonal_1	Constant	CSeasonal_1	DJIA_1	CSeasonal_1
CSeasonal_3	CSeasonal_2	DLIP_7 ²	CSeasonal_2	CSeasonal_1	CSeasonal_2
CSeasonal_4	CSeasonal_3	CSeasonal_1	CSeasonal_5	CSeasonal_5	CSeasonal_5
CSeasonal_5	CSeasonal_4	CSeasonal_2	CSeasonal_6	CSeasonal_6	CSeasonal_6
CSeasonal_6	CSeasonal_5	CSeasonal_5	CSeasonal_7	CSeasonal_7	CSeasonal_7
CSeasonal_7	CSeasonal_6	CSeasonal_6	CSeasonal_8	CSeasonal_10	CSeasonal_8
CSeasonal_8	CSeasonal_7	CSeasonal_7	CSeasonal_10	DLIP_7 ²	CSeasonal_10
CSeasonal_9	CSeasonal_8	CSeasonal_10	DJ_1*DLIP_5	DLIP_1*DLIP_6	DJ_1*DLIP_5
CSeasonal_10	CSeasonal_9	DLIP_1*DLIP_6	DJ_2*DLIP_1	DLIP_1*DLIP_12	DJ_2*DLIP_1
I:1956(8)	I:1956(8)	DLIP_1*DLIP_12	DJ_2*DLIP_2	DLIP_2*DLIP_6	DJ_2*DLIP_2
I:1957(12)	I:1957(9)	DLIP_2*DLIP_3	I:1956(8)	DLIP_2*DLIP_9	DLIP_1*DLIP_12
I:1958(2)	I:1957(12)	DLIP_2*DLIP_6	I:1957(9)	DLIP_2*DLIP_12	DLIP_2*DLIP_12
I:1958(6)	I:1958(2)	DLIP_2*DLIP_9	I:1957(12)	I:1956(8)	I:1956(8)
I:1958(8)	I:1958(11)	DLIP_2*DLIP_12	I:1958(2)	I:1957(12)	I:1957(9)
I:1958(11)	I:1959(1)	I:1956(8)	I:1958(6)	I:1958(2)	I:1957(12)
I:1959(1)	I:1959(4)	I:1957(3)	I:1958(11)	I:1958(6)	I:1958(2)
I:1959(4)	I:1959(7)	I:1957(12)	I:1959(1)	I:1958(11)	I:1958(6)
I:1959(7)	I:1959(8)	I:1958(2)	I:1959(4)	I:1959(4)	I:1958(8)
I:1959(8)	I:1959(12)	I:1958(6)	I:1959(7)	I:1959(7)	I:1958(11)
I:1959(12)	I:1960(1)	I:1958(11)	I:1959(8)	I:1959(8)	I:1959(1)
I:1960(1)	I:1960(2)	I:1959(4)	I:1959(12)	I:1959(12)	I:1959(4)
I:1960(6)	I:1960(11)	I:1959(7)	I:1960(1)	I:1960(1)	I:1959(7)
I:1960(11)	I:1960(12)	I:1959(8)	I:1960(6)	I:1960(12)	I:1959(8)
I:1960(12)	I:1961(4)	I:1959(12)	I:1960(12)	I:1961(4)	I:1959(12)
I:1961(4)	I:1971(9)	I:1960(1)	I:1961(4)	I:1972(1)	I:1960(1)
I:1964(11)	I:1972(1)	I:1960(6)	I:1972(1)	I:1974(11)	I:1960(6)
I:1966(9)	I:1972(4)	I:1960(12)	I:1974(11)	I:1974(12)	I:1960(12)
I:1970(10)	I:1974(11)	I:1961(4)	I:1974(12)	I:1979(4)	I:1961(4)
I:1971(1)	I:1974(12)	I:1972(1)	I:1978(4)	I:1980(5)	I:1972(1)
I:1971(9)	I:1975(2)	I:1974(11)	I:1979(4)	I:1982(2)	I:1974(11)
I:1972(1)	I:1978(4)	I:1974(12)	I:1979(8)	I:1983(1)	I:1974(12)
I:1973(8)	I:1979(4)	I:1979(4)	I:1980(5)		I:1979(4)
I:1974(11)	I:1980(5)	I:1980(5)	I:1982(2)		I:1980(5)
I:1974(12)	I:1983(1)	I:1982(2)	I:1983(1)		I:1983(1)
I:1975(2)	I:2005(9)	I:1983(1)			
I:1978(4)					
I:1979(4)					
I:1979(8)					
I:1980(5)					
I:1982(1)					
I:1983(1)					
I:2001(4)					

Fonte: Elaboração própria

Crise Econômica e Sanitária COVID-19:

Os dados que vão de 07/1955-01/2019 correspondem a 763 observações. Um exame das tabelas 20 e 22 reiteram o que foi mencionado anteriormente; novamente o modelo base saiu-se bem, dominando completamente o Modelo 2 na análise dos processos lineares e conseguindo a melhor colocação segundo o AIC e segunda melhor colocação pelo critério HQC.

Tabela 20 – EUA: Crise COVID-19 - Modelos lineares

Modelo	Schwarz	HQC	AIC
Modelo 1	-6,0706<	-6,3092<	-6,4587<
Modelo 2	-6,0589	-6,2520	-6,3731

Fonte: Elaboração própria

O Modelo 5, por sua vez, liderou os demais métodos STAR em todos os critérios de informação e na classificação geral ficou com a melhor colocação tanto pelo SBC como pelo HQC

Tabela 21 – EUA: Crise COVID-19 - Modelos não-lineares

Modelo	Schwarz	HQC	AIC
Modelo 3	-6,0669	-6,2789	-6,4118
Modelo 4	-6,1002	-6,2516	-6,3466
Modelo 5	-6,1093<	-6,3424<	-6,4235<
Modelo 6	-6,1063	-6,2691	-6,3712

Fonte: Elaboração própria

Tabela 22 – EUA: Crise COVID-19 - GERAL

Modelo	Schwarz	HQC	AIC
Modelo 1	-6,0706	-6,3092	-6,4587<
Modelo 5	-6,1093<	-6,3424<	-6,4235
Modelo 6	-6,1063	-6,2691	-6,3712

Fonte: Elaboração própria

Checando a lista de regressores relevantes em cada modelo, disponíveis na tabela 23, percebe-se a especificação de um número bem maior de *outliers* no Modelo 1 em relação aos não lineares, o que pode ajudar a explicar o bom desempenho do mesmo nesta estimação. Como nos casos anteriores, nota-se a relevância da primeira defasagem da volatilidade nos modelos.

Tabela 23 – EUA - COVID-19 Variáveis relevante por modelo

MODELO 1	MODELO 2	MODELO 3	MODELO 4	MODELO 5	MODELO 6
DLIP_1	DLIP_1	DLIP_3	DLIP_2	DLIP_1	DLIP_7
DLIP_4	DLIP_5	DLIP_4	DLIP_10	DLIP_10	DLIP_10
DLIP_5	DLIP_10	DLIP_9	DLIP_12	DLIP_12	DLIP_12
DLIP_9	DLIP_12	DLIP_10	Constant	Constant	Constant
DLIP_10	Constant	DLIP_11	DJIA_1	DJIA_1	DJIA_1
DLIP_12	DJIA_1	DLIP_12	CSeasonal_1	CSeasonal_1	CSeasonal_1
CSeasonal_1	CSeasonal_1	CSeasonal	CSeasonal_2	CSeasonal_2	CSeasonal_2
CSeasonal_2	CSeasonal_2	CSeasonal_1	CSeasonal_5	CSeasonal_3	CSeasonal_3
CSeasonal_4	CSeasonal_5	CSeasonal_2	CSeasonal_6	CSeasonal_5	CSeasonal_5
CSeasonal_5	CSeasonal_6	CSeasonal_3	CSeasonal_7	CSeasonal_6	CSeasonal_6
CSeasonal_6	CSeasonal_7	CSeasonal_4	CSeasonal_10	CSeasonal_7	CSeasonal_7
CSeasonal_7	CSeasonal_8	CSeasonal_5	DLIP_2 ²	CSeasonal_10	CSeasonal_10
CSeasonal_8	CSeasonal_10	CSeasonal_6	DLIP_5 ²	DLIP_7 ²	DLIP_7 ²
I:1956(8)	I:1956(8)	CSeasonal_7	DLIP_7 ²	DLIP_8 ²	DJ_1*DLIP_5
I:1957(4)	I:1957(9)	CSeasonal_9	DLIP_8 ²	DLIP_1*DLIP_2	DLIP_1*DLIP_2
I:1957(12)	I:1957(12)	DLIP_5 ²	DJ_1*DLIP_3	DLIP_1*DLIP_12	DLIP_1*DLIP_12
I:1958(2)	I:1958(2)	DLIP_1*DLIP_2	DJ_2*DLIP_1	DLIP_2*DLIP_3	DLIP_2*DLIP_3
I:1958(6)	I:1958(6)	DLIP_1*DLIP_3	DJ_2*DLIP_2	DLIP_2*DLIP_9	DLIP_2*DLIP_6
I:1958(8)	I:1958(11)	DLIP_1*DLIP_12	I:1956(8)	DLIP_2*DLIP_12	DLIP_2*DLIP_9
I:1958(11)	I:1959(1)	DLIP_2*DLIP_3	I:1957(9)	I:1956(8)	DLIP_2*DLIP_12
I:1959(1)	I:1959(4)	DLIP_2*DLIP_4	I:1957(12)	I:1957(9)	I:1956(8)
I:1959(4)	I:1959(7)	DLIP_2*DLIP_5	I:1958(2)	I:1957(12)	I:1957(3)
I:1959(7)	I:1959(8)	DLIP_2*DLIP_6	I:1958(11)	I:1958(2)	I:1957(12)
I:1959(8)	I:1959(12)	DLIP_2*DLIP_9	I:1959(1)	I:1958(6)	I:1958(2)
I:1959(12)	I:1960(1)	DLIP_2*DLIP_12	I:1959(4)	I:1958(8)	I:1958(3)
I:1960(1)	I:1960(2)	I:1956(8)	I:1959(7)	I:1958(11)	I:1958(6)
I:1960(5)	I:1960(5)	I:1957(4)	I:1959(8)	I:1959(1)	I:1958(8)
I:1960(12)	I:1960(6)	I:1957(12)	I:1959(12)	I:1959(4)	I:1958(11)
I:1961(4)	I:1960(11)	I:1958(2)	I:1960(1)	I:1959(7)	I:1959(4)
I:1962(9)	I:1960(12)	I:1958(5)	I:1960(12)	I:1959(8)	I:1959(7)
I:1963(9)	I:1961(4)	I:1958(6)	I:1961(4)	I:1959(12)	I:1959(8)
I:1964(4)	I:1962(9)	I:1958(11)	I:1964(11)	I:1960(1)	I:1959(12)
I:1964(11)	I:1963(9)	I:1959(1)	I:1972(1)	I:1960(6)	I:1960(1)
I:1965(10)	I:1964(10)	I:1959(4)	I:1974(11)	I:1960(11)	I:1960(6)
I:1966(9)	I:1964(11)	I:1959(7)	I:1974(12)	I:1960(12)	I:1960(12)
I:1967(8)	I:1966(9)	I:1959(8)	I:1979(4)	I:1961(4)	I:1961(4)
I:1968(9)	I:1967(8)	I:1959(12)	I:1980(5)	I:1962(2)	I:1972(1)
I:1970(10)	I:1968(9)	I:1960(1)	I:1982(1)	I:1962(9)	I:1974(11)
I:1971(9)	I:1971(1)	I:1960(4)	I:1982(2)	I:1964(11)	I:1974(12)
I:1972(1)	I:1971(9)	I:1960(5)	I:1983(1)	I:1970(10)	I:1979(4)
I:1972(4)	I:1972(1)	I:1960(6)		I:1971(9)	I:1980(5)
I:1973(9)	I:1973(8)	I:1960(9)		I:1972(1)	I:1982(2)
I:1974(11)	I:1974(11)	I:1960(12)		I:1974(11)	I:1983(1)
I:1974(12)	I:1974(12)	I:1961(4)		I:1974(12)	
I:1975(4)	I:1975(4)	I:1961(10)		I:1976(2)	
I:1978(4)	I:1979(4)	I:1962(9)		I:1979(4)	
I:1979(4)	I:1979(8)	I:1970(10)		I:1979(5)	
I:1979(5)	I:1980(5)	I:1972(1)		I:1980(5)	
I:1979(8)	I:1982(2)	I:1974(11)		I:1982(2)	
I:1980(5)	I:1983(1)	I:1974(12)		I:1983(1)	
I:1980(9)	I:1983(9)	I:1975(4)		I:1983(9)	
I:1982(1)		I:1979(4)			
I:1982(2)		I:1980(5)			
I:1983(1)		I:1980(9)			
I:1983(9)		I:1982(2)			
I:1986(4)		I:1983(1)			
I:1989(4)					
I:1989(5)					
I:1991(4)					
I:2001(4)					
I:2008(9)					
I:2009(1)					
I:2009(7)					

Fonte: Elaboração própria

5.2 PREVISÃO

As previsões foram feitas para um período de 24 observações a partir do mês em que os modelos foram estimados. As especificações dos modelos ficam inalteradas durante toda a janela de previsão, que por sua vez acontece em incrementos de um passo (*one step approach*), ou mês a mês. Nesta abordagem, calcula-se a previsão de um dado mês e o seu respectivo erro ao compará-lo com valor real da série; a série é então incrementada pelo valor real da variável para que a previsão do mês seguinte seja feita.

As tabelas 24 a 28 abaixo retratam os erros de previsão de cada um dos 6 modelos durante todos os eventos analisados. Para uma fácil comparação dos erros, reportamos uma medida padrão muito popular correspondente ao erro quadrado médio (RMSE) que nos permite rapidamente avaliar quais modelos registraram maior acurácia. Elas reportam ainda as estatísticas-t referentes ao teste de Diebold-Mariano (coluna t-HACSE).

O teste DM tradicional é capaz de comparar os erros de previsão de apenas dois modelos de cada vez. Desta forma, optamos por fixar um deles como sendo o Modelo 1 e comparamos todos os demais em relação a ele.

Tabela 24 – Erros de previsão Brasil - GFC: JUL/07-JUN/09

		RMSE	Coeficiente	HACSE	t-HACSE
BRA - GFC	Modelo 1	0,034674			
BRA - GFC	Modelo 2	0,035538	-6,07e-5	1,07e-4	-0,566
BRA - GFC	Modelo 3	0,037169	-1,79e-4	1,49e-4	-1,2
BRA - GFC	Modelo 4	0,03555	-6,16e-5	8,25e-5	-0,747
BRA - GFC	Modelo 5	0,033646	7,02e-5	2,04e-4	0,344
BRA - GFC	Modelo 6	0,032891	0,000120436	2,65e-4	0,454

Em negrito estão o Modelo 1 (*benchmark*) e o modelo com menor erro de previsão.

Fonte: Elaboração própria

Tabela 25 – Erros de previsão Brasil - Dilma: AGO/13-JUL/15

		RMSE	Coeficiente	HACSE	t-HACSE
BRA - Dilma	Modelo 1	0,028773			
BRA - Dilma	Modelo 2	0,029202	-2,48e-5	1,27e-4	-0,195
BRA - Dilma	Modelo 3	0,024462	2,29e-4	1,54e-4	1,49
BRA - Dilma	Modelo 4	0,026318	1,35e-4	1,09e-4	1,24
BRA - Dilma	Modelo 5	0,025198	1,93e-4	1,70e-4	1,14
BRA - Dilma	Modelo 6	0,029453	-3,96e-5	1,66e-4	-0,239

Em negrito estão o Modelo 1 (*benchmark*) e o modelo com menor erro de previsão.

Fonte: Elaboração própria

Pensando apenas nos Modelos 1 e 2 (lineares), cuja única diferença é a adição do componente volatilidade, a análise dos RMSE indica que de fato estes regressores adicionais podem

Tabela 26 – Erros de previsão Brasil - Covid-19: FEV/19-JAN/21

		RMSE	Coeficiente	HACSE	t-HACSE
BRA - Covid-19	Modelo 1	0,084792			
BRA - Covid-19	Modelo 2	0,084079	1,20e-4	3,34e-4	0,36
BRA - Covid-19	Modelo 3	0,082234	4,27e-4	8,96e-4	0,477
BRA - Covid-19	Modelo 4	0,0743	1,02e-3	8,83e-4	1,16
BRA - Covid-19	Modelo 5	0,065941	1,67e-3	9,85e-4	1,70*
BRA - Covid-19	Modelo 6	0,077137	2,84e-3	1,58e-3	1,79*

Em negrito estão o Modelo 1 (*benchmark*) e o modelo com menor erro de previsão.

Em negrito os modelos 5 e 6 para o teste DM, onde ambos se mostraram significantes a 10%

Fonte: Elaboração própria

Tabela 27 – Erros de previsão EUA - GFC: JUL/07-JUN/09

		RMSE	Coeficiente	HACSE	t-HACSE
EUA - GFC	Modelo 1	0,017365			
EUA - GFC	Modelo 2	0,015689	5,54e-5	3,49e-5	1,59
EUA - GFC	Modelo 3	0,014453	9,27e-5	4,29e-5	2,16**
EUA - GFC	Modelo 4	0,012839	0,000136707	7,45e-5	1,83*
EUA - GFC	Modelo 5	0,013173	0,000128009	5,87e-5	2,18**
EUA - GFC	Modelo 6	0,01266	0,000141281	7,56e-5	1,87*

Em negrito estão o Modelo 1 (*benchmark*) e o modelo com menor erro de previsão.

Em negrito os modelos 3,4,5 e 6 para o teste DM, onde todos se mostraram significantes

Fonte: Elaboração própria

Tabela 28 – Erros de previsão EUA - Covid-19: FEV/19-JAN/21

		RMSE	Coeficiente	HACSE	t-HACSE
EUA - Covid-19	Modelo 1	0,042356			
EUA - Covid-19	Modelo 2	0,039892	2,03e-4	1,97e-4	1,03
EUA - Covid-19	Modelo 3	0,043877	-1,31e-4	2,53e-4	-0,517
EUA - Covid-19	Modelo 4	0,053365	-0,00105372	9,41e-4	-1,12
EUA - Covid-19	Modelo 5	0,043374	-8,72e-5	2,82e-4	-0,309
EUA - Covid-19	Modelo 6	0,042001	3,00e-5	1,84e-4	0,163

Em negrito estão o Modelo 1 (*benchmark*) e o modelo com menor erro de previsão.

Fonte: Elaboração própria

trazer benefícios à previsão da série de produção industrial. Dos 5 eventos estudados, o RMSE do Modelo 2 foi menor que do *benchmark* em 3 ocasiões (BRA-COVID, EUA-GFC E EUA-COVID).

Refletindo sobre o segundo objetivo desta dissertação, que é o de analisar se processos STAR podem trazer ganhos de precisão frente aos AR na previsão da série de produção industrial, chegamos a conclusão que esta modelagem não linear de fato tem potencial de contribuir. Em todos os 5 eventos, pelos menos um processo STAR foi capaz de gerar erros de previsão menores que aqueles observados no modelo base, sendo que em 2 oportunidades (BRA-COVID e EUA-COVID) todos os 4 modelos não-lineares propostos conseguiram gerar erros de previsão menores que os do Modelo 1.

No entanto, estes resultados encorajadores foram confirmados apenas parcialmente pela

estatística-t do teste DM. Com exceção feita às análises dos períodos BRA-Covid e EUA-GFC, em nenhum outro período os diferentes modelos testados conseguiram se provar estatisticamente superiores segundo o teste de Diebold-Mariano, apresentando resultados sempre $t < |1,96|$, ou seja, não significativos a 5% ou mesmo $t < |1,645|$ (não significativos a 10%)

5.3 DISCUSSÃO

Considerando conjuntamente todos os modelos estimados, observamos que alguns regressores mostram bastante persistência ao estar presente em diversos modelos já otimizados. Para a série brasileira temos um total de 18 regressões (3 eventos x 6 modelos por regressão) e o regressor mais relevante de todos foi a primeira defasagem da própria série de produção industrial. Esta variável se mostrou significativa em todas as 18 regressões, evidenciando que de fato parece haver um *carry over* de um mês para o seguinte no Índice de Produção Industrial brasileiro. Também bastante relevante foi a forma quadrática da segunda defasagem da série ($DLIP_2^2$) que apareceu em praticamente todos os modelos não lineares.

A primeira defasagem da volatilidade, já mencionada antes, mostrou-se importante em 9 das 12 regressões possíveis. Por outro lado, a volatilidade contemporânea e a segunda defasagem da volatilidade não foram retidas como variáveis significativas em nenhuma ocasião. Outras variáveis recorrentes e que indicam não linearidade foram os termos cruzados entre a primeira defasagem da volatilidade e a décima segunda defasagem da série ($VOL_1 * DLIP_{12}$); e a primeira defasagem da série contra sua própria décima segunda defasagem ($DLIP_1 * DLIP_{12}$).

A leitura dos resultados na seção de estimação indica a presença de algumas variáveis *dummies* pontuais comuns a todos os 6 modelos independente do período de estimação. No caso da economia brasileira, estas *dummies* estão centradas no final da década de 1980 e principalmente começo dos anos 1990 com o confisco da poupança durante a inauguração do governo Collor e os meses que se sucederam.

Fazendo a ponte entre estimação e previsão, chegamos a resultados mistos, parecendo mais consistentes para os casos envolvendo a economia brasileira. Olhando para o episódio da crise econômica durante o governo Dilma, o modelo 5 dominou todos os demais segundo os três critérios de informação escolhidos. Sua boa especificação foi comprovada durante o período de *forecast* onde seu RMSE lhe rendeu a segunda posição. No caso da crise da Covid-19 os

melhores modelos estimados, 6 e 5 nesta ordem, foram também os que geraram as previsões de menor RMSE, só que agora com 5 à frente de 6. O Modelo 6 também foi um dos melhores durante a estimação do período pré-crise de 2008 e confirmou as expectativas ao recordar os menores erros de previsão. A próxima tabela resume os resultados de todo o estudo, ordenando os dois melhores modelos na estimação e na previsão.

Tabela 29 – Resumo do estudo

		Estimação	Previsão (RMSE)
Brasil	GFC	Modelo 4, Modelo 6	Modelo 6, Modelo 5
	Dilma	Modelo 5, Modelo 4	Modelo 3, Modelo 5
	Covid-19	Modelo 6, Modelo 4	Modelo 5, Modelo 4
Estados Unidos	GFC	Modelo 1, Modelo 4	Modelo 6, Modelo 4
	Covid-19	Modelo 5, Modelo 1	Modelo 2, Modelo 6

Fonte: Elaboração própria

Acredito que os dados acima ressaltam o bom desempenho de dois modelos em particular para a modelagem da série de produção industrial brasileira. O Modelo 4 parece ser um bom estimador já que aparece como um dos dois melhores nas três estimações feitas para o Brasil (além de ser um dos melhores previsores em uma oportunidade); enquanto o Modelo 5 parece ser um bom previsor, pois está presente entre os melhores em todos os exercícios de previsão para a economia brasileira (acabou ainda sendo um dos melhores estimadores em uma das ocasiões).

Pelo teste DM não foi possível constatar que os aparentes ganhos de previsão observados pelo RMSE para a economia brasileira fossem consistentemente significantes estatisticamente em todos os eventos. O único experimento onde alguns modelos conseguiram resultados mais expressivos foi o da Covid-19 (janela de previsão fev/2019-jan/2021), onde o Modelo 5 ($t\text{-HACSE} = 1,70$) e o Modelo 6 ($t\text{-HACSE} = 1,79$) se mostraram estatisticamente significantes a 10%.

Focando agora nos resultados da economia norte americana, vimos que no exercício de estimação o Modelo 1 se saiu muito bem tanto no período que antecedeu a crise financeira de 2008, como na Covid-19; dominando seus competidores pelos critérios de informação AIC e HQC no primeiro caso e pelo AIC no segundo. Embora relevante, este resultado parece só ter sido possível através da especificação de uma quantidade substancialmente maior de variáveis *dummies* pontuais, pois mesmo sendo o método mais simples e com menor número de regressores potenciais, em ambos os casos o Modelo 1 otimizado acabou exibindo um número maior

de variáveis do que qualquer outro modelo.

Outra evidencia a favor de um possível *overfitting* do Modelo 1 àquelas janelas de dados é o fato do exercício de previsão ter mostrado que para o período de fev-2019 a jan-2021 o Modelo 1 foi o que apresentou pior RMSE dentre todos os avaliados mesmo depois dos resultados positivos durante o exercício de estimação.

Os *outliers* encontrados na série americana estão muito concentrados entre o início da amostra e o começo da década de 1980. A partir deste ponto os dados parecem ficar mais bem comportados e o número de observações classificadas como *outliers* cai drasticamente. A partir da década de 1990, nenhuma variável *dummy* precisa ser especificada aos processos STAR.

Ao buscarmos identificar quais regressores são comuns ao maior número de modelos, vemos que a décima segunda defasagem da série ($DLIP_{12}$) está presente em todas as 12 regressões (2 eventos x 6 especificações). As outras duas defasagens que mais aparecem são a décima ($DLIP_{10}$) e a primeira ($DLIP_1$), nesta ordem. Exatamente como no caso brasileiro, a primeira defasagem da volatilidade ($DJIA_1$) mostrou-se relevante na maioria das regressões a que ela poderia ser especificada, enquanto a volatilidade contemporânea e a segunda defasagem não parecem ter impacto direto algum (ressalta-se que alguns termos não lineares fruto do cruzamento entre a segunda defasagem da volatilidade e defasagens da produção industrial foram identificados em algumas das regressões).

Os termos cruzados mais significantes são os que envolvem a primeira e a décima segunda defasagens ($DLIP_1 * DLIP_{12}$) e também o da segunda com a décima segunda ($DLIP_2 * DLIP_{12}$).

Como foram analisados os resultados de apenas dois eventos específicos, não é possível tirar nenhuma conclusão a respeito da forma como os erros de previsão da série realmente se comportam no longo prazo, mas dada a proposta do estudo, não deixa de ser um bom indicador o fato de que em ambas as ocasiões, tanto os métodos não lineares como o modelo linear com volatilidade alcançaram RMSE menores que os apresentados pelo modelo base.

Para o período da EUA-GFC, estes ganhos de previsão foram, inclusive, confirmados como estatisticamente significantes pelo teste Diebold-Mariano; cuja estatística-t se mostrou significativa a 5% (maior que 1,96) para o Modelo 3 ($t\text{-HACSE} = 2,16$) e para o Modelo 5

($t\text{-HACSE} = 2,18$) e a 10% no Modelo 4 ($t\text{-HACSE} = 1,83$) e no Modelo 6 ($t\text{-HACSE} = 1,87$).

Desta forma, na EUA-GFC as previsões de todos os 4 modelos não lineares se mostraram significantes segundo o teste DM, fazendo com que este evento tivesse os resultados mais expressivos dentre os 5 estudados.

6 CONCLUSÃO

Seguindo o que parece ser um padrão recorrente nesta literatura, vide Stock e Watson (1998) e Terasvirta e Anderson (1992), ao fazer uso de modelos não lineares para estimar e prever a série da Produção Industrial chegamos a resultados inconclusivos, mas que não deixam de ser encorajadores. No exercício de estimação de modelos, vimos que processos STAR dominaram os AR na maioria dos casos, sugerindo possíveis benefícios no uso dos mesmos.

Este resultado foi corroborado quando medimos os erros de previsão de cada um dos 6 modelos propostos durante uma janela de 24 meses imediatamente posterior à estimação otimizada. De forma consistente, em todos os 5 eventos analisados, pelo menos um dos processos não lineares foi capaz de produzir uma estimação mais precisa que aquelas geradas pelos modelos lineares. Em contrapartida, fomos capazes de validar que estes ganhos nos erros de previsão fossem estatisticamente significantes usando como medida de desempenho o teste DM em apenas 2 das 5 ocasiões, sendo elas: BRA-Covid. e EUA-GFC.

Algo similar pode ser dito à respeito do benefício trazido pela adição da volatilidade da bolsa de valores ao processo auto-regressivo básico. Dos 5 episódios estudados (3 para o Brasil e 2 para os EUA), o Modelo 1 levou vantagem em duas e o Modelo 2 também em duas, enquanto na última delas os critérios de informação foram incapazes de demonstrar preferência absoluta por um ou outro. Os *forecasts* vão na mesma linha e apontam que o Modelo 2 registrou erros de previsão menores em 3 das 5 oportunidades quando comparado diretamente ao Modelo 1.

Procuramos, neste estudo, examinar modelos não lineares que fossem uma aproximação de um processo STAR, onde a transição entre os regimes acontece de forma suave; porém, é possível que esta passagem de um regime para outro ocorra de forma mais abrupta. Imagine que na maior parte do tempo a volatilidade realizada oscile dentro de uma certa banda e seja incapaz de afetar ou prever a produção industrial, mas onde choques repentinos fazem com que o nível da volatilidade suba para patamares além da banda e aí sim ela consiga antecipar movimentos da atividade econômica. Nestes casos, outras classes de modelos, como por exemplo TAR e Markov-Switch, podem ser testados.

Uma segunda alteração poderia ser a adição ou a substituição da volatilidade realizada da bolsa de valores por algum outro indicador que captasse mudanças de percepção em relação ao

risco financeiro e econômico, como por exemplo o uso da volatilidade do *EMBI+Br* (*Emerging Markets Bond Index Plus - Brazil*)¹ que acredito apresentar menos ruído quando comparada a volatilidade da bolsa de valores. Outra sugestão seria fazer uso de *leading indicators* como o LEI (*Leading Economic Indicator*) divulgado mensalmente pelo FGV-IBRE para a economia brasileira. Este indicador, exibe componentes tanto do mercado financeiro como da economia real e modelos de agregação/desagregação como o MIDAS (*Mixed Data Sampling*) poderiam ser capazes de aumentar a frequência da série caso seja necessário o uso de informação mais granular. Especificamente para o caso da economia norte-americana, poderia ser proposta a substituição do índice *Dow Jones Industrial Average* pelo *SP500*, já que atualmente é o índice de referência para a bolsa de valores dos Estados Unidos.

Continuando no tópico sobre volatilidade, neste trabalho usamos a volatilidade contemporânea da bolsa como um dos possíveis regressores dos modelos uma vez que ela pode ser calculada já ao final do último pregão do mês corrente, enquanto a divulgação do índice de produção referente ao mesmo mês acontece somente após um período de 5-6 semanas. Este descasamento nos garante que, do ponto de vista temporal, não haja nenhuma inconsistência ao usarmos a volatilidade contemporânea. Por outro lado, a análise como um todo pode ser enriquecida com a adição de um teste de exogeneidade com o intuito de melhor avaliar e entender a relação entre as duas variáveis.

Estudos futuros poderão ainda contemplar formas alternativas de se testar a significância estatística das diferenças entre os erros de previsão gerados pelos diversos modelos. Nossa comparação foi pautada no teste Diebold-Mariano, que em sua forma original compara apenas dois processos de cada vez, mas testes mais sofisticados estaticamente e com o potencial de testar múltiplos modelos simultaneamente (*Model Confidence Set – MCS* de Hansen²) foram desenvolvidos ao longo da última década e podem ser explorados. Por fim, uma última maneira de tentar incrementar o estudo, até como resposta à Crítica de Lucas, seria trabalhar com janelas de estimação/previsão menores com a intenção de deixar os modelos mais dinâmicos e adaptados à realidade de cada momento.

¹ calculado e divulgado pelo banco norte-americano de investimentos *J.P. Morgan*

² Hansen, P. R., Lunde, A. e Nason, J. M. (2011) - *The model confidence set*

REFERÊNCIAS

- Aghion P., Bacchetta P., Ranciere R., Rogoff K.* Exchange rate volatility and productivity growth: The role of financial development // *Journal of monetary economics*. 2009. 56, 4. 494–513.
- Castle J. L., Doornik J. A., Hendry D. F.* Model selection when there are multiple breaks // *Journal of Econometrics*. 2012. 169, 2. 239–246.
- Castle J. L., Hendry D. F.* A low-dimension portmanteau test for non-linearity // *Journal of econometrics*. 2010. 158, 2. 231–245.
- Chudik A., Mohaddes K., Pesaran M. H., Raissi M., Rebucci A.* A counterfactual economic analysis of Covid-19 using a threshold augmented multi-country model // *National Bureau of Economic Research*. 2020. WP27855.
- Cochrane J. H.* Production-based asset pricing and the link between stock returns and economic fluctuations // *The Journal of Finance*. 1991. 46, 1. 209–237.
- Cochrane J. H., Hansen L. P.* Asset pricing explorations for macroeconomics // *NBER macroeconomics annual*. 1992. 7. 115–165.
- Cryer J. D., Chan K.S.* Time series analysis: with applications in R // *Springer*. 2008.
- Diebold F. X., Mariano R. S.* Comparing predictive accuracy // *Journal of Business & economic statistics*. 2002. 20, 1. 134–144.
- Diebold Francis X.* Comparing predictive accuracy, twenty years later: A personal perspective on the use and abuse of Diebold–Mariano tests // *Journal of Business & Economic Statistics*. 2015. 33, 1. 1–1.
- Dijk D. van, Teräsvirta T., Franses P. H.* Smooth transition autoregressive models—a survey of recent developments // *Econometric reviews*. 2002. 21, 1. 1–47.
- Doornik J. A.* Autometrics // *Castle, and Shephard (2009)*. 2009. 88–121.
- Enders W.* Applied Econometric Time Series // *John Wiley Sons*. 2010.
- Engle R. F., Ghysels E., Sohn B.* Stock market volatility and macroeconomic fundamentals // *Review of Economics and Statistics*. 2013. 95, 3. 776–797.

- Hendry D. F., Doornik J. A.* Empirical model discovery and theory evaluation: automatic selection methods in econometrics // MIT Press. 2014.
- Johansen S., Nielsen B.* An analysis of the indicator saturation estimator as a robust regression estimator // Castle, and Shephard (2009). 2009. 1. 1–36.
- Kilian L., Taylor M. P.* Why is it so difficult to beat the random walk forecast of exchange rates? // Journal of International Economics. 2003. 60, 1. 85–107.
- Lundbergh S., Teräsvirta T.* Forecasting with smooth transition autoregressive models // A companion to economic forecasting. 2002. 485–509.
- Luukkonen R., Saikkonen P., Teräsvirta T.* Testing linearity against smooth transition autoregressive models // Biometrika. 1988. 75, 3. 491–499.
- Meese R. A., Rogoff K.* Empirical exchange rate models of the seventies: Do they fit out of sample? // Journal of international economics. 1983. 14, 1-2. 3–24.
- Nymoen R.* Dynamic Econometrics for Empirical Macroeconomic Modelling // The World Scientific Publishing. 2020.
- Paye B. S.* ‘Déjà vol’: Predictive regressions for aggregate stock market volatility using macroeconomic variables // Journal of Financial Economics. 2012. 106, 3. 527–546.
- Pesaran M. H., Schuermann T., Weiner S. M.* Modeling regional interdependencies using a global error-correcting macroeconomic model // Journal of Business & Economic Statistics. 2004. 22, 2. 129–162.
- Pesaran M.H.* Time Series and Panel Data Econometrics // Oxford University Press. 2015.
- Rech Gianluigi.* Forecasting with artificial network models. 2002.
- Santos C., Hendry D. F., Johansen S.* Automatic selection of indicators in a fully saturated regression // Computational Statistics. 2008. 23, 2. 317–335.
- Schwert G. W.* Why does stock market volatility change over time? // The Journal of Finance. 1989. 44, 5. 1115–1153.
- Spanos A.* Reflections on the LSE Tradition in Econometrics: a Student’s Perspective // *Æconomia. History, Methodology, Philosophy.* 2014. 4-3. 343–380.

- Stock J. H., Watson M. W.* A comparison of linear and nonlinear univariate models for forecasting macroeconomic time series // National Bureau of Economic Research. 1998. WP6607.
- Teräsvirta T.* Specification, estimation, and evaluation of smooth transition autoregressive models // Journal of the American Statistical Association. 1994. 89, 425. 208–218.
- Teräsvirta T., Anderson H. M.* Characterizing nonlinearities in business cycles using smooth transition autoregressive models // Journal of applied econometrics. 1992. 7, S1. S119–S136.
- Teräsvirta T., Dijk D. van, Medeiros M. C.* Linear models, smooth transition autoregressions, and neural networks for forecasting macroeconomic time series: A re-examination // International Journal of Forecasting. 2005. 21, 4. 755–774.

APÊNDICE A –

Tabela 30 – *Index-test* de não linearidade - Produção Industrial Geral: 04/1986-01/2021

	Coeficiente	Std Error	t-value
$Z0^2$	0.0060023	0.03547	0.1692
$Z1^2$	-0.030894	0.05159	-0.5989
$Z2^2$	-0.073878	0.062	-1.192
$Z3^2$	0.016471	0.06852	0.2404
$Z4^2$	0.078452	0.0629	1.247
$Z5^2$	0.014134	0.1114	0.1269
$Z6^2$	-0.12764	0.09023	-1.415
$Z7^2$	0.062628	0.05833	1.074
$Z8^2$	0.1898	0.108	1.757
$Z9^2$	0.11149	0.05088	2.191
$Z10^2$	0.011311	0.00927	1.22
$Z11^2$	0.00026995	0.00143	-0.1888
$Z12^2$	0.00024545	0.0008886	-0.2762
$Z13^2$	-0.001574	0.001167	-1.349
$Z14^2$	2.03e-5	0.001536	0.01323
$Z15^2$	0.00018085	0.001458	-0.124
$Z16^2$	-0.0014186	0.001205	-1.177
$X0* Z0 $	-2.3062	0.5358	-4.304
$X1* Z1 $	0.82572	0.3979	2.075
$X2* Z2 $	-0.45434	0.844	-0.5383
$X3* Z3 $	0.040032	0.5354	0.07476
$X4* Z4 $	-0.62982	0.6574	-0.9581
$X5* Z5 $	-0.089772	0.4937	-0.1818
$X6* Z6 $	-11.815	6.022	-1.962
$X7* Z7 $	0.4558	2.733	0.1668
$X8* Z8 $	-5.6268	2.276	-2.472
$X9* Z9 $	0.43476	0.8888	0.4891
$X10* Z10 $	-0.0095351	0.0935	-0.102
$X11* Z11 $	-0.0039526	0.02466	-0.1603
$X12* Z12 $	-0.026071	0.02962	-0.8802
$X13* Z13 $	0.010258	0.0277	0.3704
$X14* Z14 $	-0.015608	0.01745	-0.8942
$X15* Z15 $	-0.0063807	0.02682	-0.2379
$X16* Z16 $	-0.0077851	0.03124	-0.2492
$X0*Z0^2$	1.29	0.3325	3.879
$X1*Z1^2$	-0.39181	0.2165	-1.81
$X2*Z2^2$	0.36655	0.5696	0.6435
$X3*Z3^2$	-0.086252	0.3665	-0.2354
$X4*Z4^2$	0.37925	0.385	0.985
$X5*Z5^2$	0.1126	0.3448	0.3266
$X6*Z6^2$	4.6713	2.372	1.97
$X7*Z7^2$	-0.20417	1.467	-0.1391
$X8*Z8^2$	4.3017	2.032	2.117
$X9*Z9^2$	0.044542	0.3614	0.1233
$X10*Z10^2$	0.063707	0.09931	0.6415
$X11*Z11^2$	0.009692	0.01143	0.8476
$X12*Z12^2$	0.019636	0.01811	1.084
$X13*Z13^2$	-0.0022471	0.01343	-0.1673
$X14*Z14^2$	0.0035072	0.004116	0.8522
$X15*Z15^2$	0.0023452	0.01052	0.2229
$X16*Z16^2$	0.0050503	0.01638	0.3082
RSS =	0.199134	sigma =	0.00064654
Chi ² (51) =	93.525 [0.0003]**		
F-form F(51,308) =	1.8133 [0.0012]**		

Fonte: Elaboração própria

Tabela 31 – *Index-test* de não linearidade - Industrial Production Manufacturing: 07/1955-01/2021

	Coefficiente	Std Error	t-value
Z0 ²	-0.14793	0.1501	-0.9854
Z1 ²	0.1207	0.04057	2.975
Z2 ²	-0.048549	0.03654	-1.329
Z3 ²	-0.056062	0.07776	-0.721
Z4 ²	-0.023821	0.05568	-0.4278
Z5 ²	0.23178	0.1247	1.858
Z6 ²	-0.088775	0.04934	-1.799
Z7 ²	-0.0020983	0.006436	-0.326
Z8 ²	0.00021768	0.0004075	0.5342
Z9 ²	6.20e-5	0.0008349	0.07421
Z10 ²	7.41e-5	0.000279	-0.2656
Z11 ²	2.37e-6	0.0003153	0.007518
Z12 ²	0.00011209	0.0002393	-0.4685
Z13 ²	0.00034867	0.0002152	1.621
Z14 ²	0.00010851	0.0002887	-0.3758
Z15 ²	0.00026137	0.0002446	1.069
X0* Z0	-0.051695	0.1893	-0.2731
X1* Z1	0.24452	0.1843	1.327
X2* Z2	-0.2461	0.1297	-1.898
X3* Z3	-0.43456	0.3724	-1.167
X4* Z4	-0.28469	0.1742	-1.635
X5* Z5	0.037589	0.1499	0.2507
X6* Z6	-0.11268	0.1751	-0.6435
X7* Z7	-0.30437	0.3075	-0.99
X8* Z8	-0.018883	0.007311	-2.583
X9* Z9	-0.002175	0.0115	-0.1892
X10* Z10	-0.0072682	0.004993	-1.456
X11* Z11	-0.0081844	0.006417	-1.275
X12* Z12	0.0022722	0.006852	0.3316
X13* Z13	0.0014839	0.004943	0.3002
X14* Z14	-0.0050091	0.007048	-0.7107
X15* Z15	0.00024619	0.006013	0.04095
X0*Z0 ²	-0.015937	0.1175	-0.1356
X1*Z1 ²	-0.14031	0.08764	-1.601
X2*Z2 ²	0.094236	0.04151	2.27
X3*Z3 ²	0.18123	0.1491	1.216
X4*Z4 ²	0.084467	0.08856	0.9538
X5*Z5 ²	0.02437	0.06102	0.3994
X6*Z6 ²	0.070196	0.08921	0.7868
X7*Z7 ²	0.023881	0.1643	0.1453
X8*Z8 ²	0.0094779	0.003578	2.649
X9*Z9 ²	0.004822	0.01117	0.4317
X10*Z10 ²	0.00094816	0.001587	0.5975
X11*Z11 ²	0.0027955	0.003483	0.8026
X12*Z12 ²	0.00032562	0.003407	-0.09558
X13*Z13 ²	0.00037383	0.001967	-0.19
X14*Z14 ²	0.002572	0.003606	0.7132
X15*Z15 ²	-0.0026895	0.003308	-0.8131
RSS =	0.0382386	sigma =	6.23e-5
Chi ² (48) =	112.46 [0.0000]**		
F-form F(48,614) =		2.1746 [0.0000]**	

Fonte: Elaboração própria

Tabela 32 – ESTIMAÇÃO: GFC - BRA - Modelo 1

GFC - Brasil - Modelo linear AR base (benchmark)					
	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.248708	0.05144	-4.84	0	0.0993
DLGeral_4	-0.130867	0.04313	-3.03	0.0027	0.0416
DLGeral_7	-0.288685	0.04437	-6.51	0	0.1665
CSeasonal	0.0629396	0.009951	6.32	0	0.1587
CSeasonal_1	0.0821676	0.009381	8.76	0	0.2657
CSeasonal_2	0.228807	0.00971	23.6	0	0.7237
CSeasonal_3	0.074258	0.01505	4.93	0	0.103
CSeasonal_4	0.16859	0.009317	18.1	0	0.607
CSeasonal_5	0.0952691	0.01214	7.84	0	0.225
CSeasonal_6	1.26e-1	0.01342	9.38	0	0.2932
CSeasonal_7	1.32e-1	0.01107	11.9	0	0.3999
CSeasonal_8	8.85e-2	0.0109	8.12	0	0.2373
CSeasonal_9	0.159074	0.009226	17.2	0	0.5837
CSeasonal_10	0.061594	0.01075	5.73	0	0.134
I:1988(6)	0.0970442	0.02807	3.46	0.0007	0.0534
I:1989(2)	-0.0739828	0.02819	-2.62	0.0093	0.0315
I:1989(6)	0.0984571	0.02828	3.48	0.0006	0.0541
I:1990(3)	-0.108227	0.02811	-3.85	0.0002	0.0653
I:1990(4)	-0.31159	0.02856	-10.9	0	0.3595
I:1990(5)	0.190315	0.03153	6.04	0	0.1467
I:1990(6)	0.0830702	0.03126	2.66	0.0085	0.0322
I:1990(7)	0.068778	0.02833	2.43	0.016	0.0271
I:1990(11)	-0.125843	0.031	-4.06	0.0001	0.0721
I:1991(4)	0.139452	0.02847	4.9	0	0.1017
I:1991(9)	-0.0908038	0.02809	-3.23	0.0014	0.047
I:1991(12)	-0.0981275	0.02826	-3.47	0.0006	0.0538
I:1992(2)	0.115378	0.02817	4.1	0.0001	0.0733
I:1992(3)	-0.0828206	0.02867	-2.89	0.0043	0.0379
I:1994(12)	0.0952127	0.02827	3.37	0.0009	0.0508
I:1995(5)	-0.101509	0.02828	-3.59	0.0004	0.0573
sigma	0.0273174	RSS	0.158203305		
log-likelihood	543.887				
no. of observations	242	no. of parameters	30		
mean(DLGeral)	0.00145427	se(DLGeral)	0.0745255		
AR 1-7 test:	F(7,205) =	2.2118 [0.0347]*			
ARCH 1-7 test:	F(7,228) =	0.62939 [0.7314]			
Normality test:	Chi ² (2) =	0.41083 [0.8143]			
Hetero test:	F(17,208) =	1.1374 [0.3203]			
RESET23 test:	F(2,210) =	0.38361 [0.6819]			

Fonte: Elaboração própria

Tabela 33 – ESTIMAÇÃO: GFC - BRA - Modelo 2

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.337004	0.05218	-6.46	0	0.1644
DLGeral_7	-0.204658	0.04991	-4.1	0.0001	0.0735
DLGeral_12	0.138548	0.04682	2.96	0.0034	0.0397
Constant	0.00929288	0.003895	2.39	0.0179	0.0261
CSeasonal	0.0497812	0.0112	4.45	0	0.0853
CSeasonal_1	0.0693411	0.01017	6.82	0	0.1797
CSeasonal_2	0.204342	0.01397	14.6	0	0.5023
CSeasonal_3	0.0996321	0.01395	7.14	0	0.1939
CSeasonal_4	0.149001	0.01229	12.1	0	0.4096
CSeasonal_5	1.02e-1	0.01272	7.99	0	0.2313
CSeasonal_6	1.09e-1	0.01423	7.64	0	0.2157
CSeasonal_7	1.32e-1	0.01197	11	0	0.3639
CSeasonal_8	0.0756184	0.01128	6.7	0	0.1749
CSeasonal_9	0.135846	0.01178	11.5	0	0.3854
CSeasonal_10	0.0638422	0.01117	5.72	0	0.1336
I:1988(6)	0.0898988	0.0287	3.13	0.002	0.0442
I:1989(6)	0.101768	0.02925	3.48	0.0006	0.054
I:1990(3)	-0.106321	0.02874	-3.7	0.0003	0.0607
I:1990(4)	-0.29761	0.03035	-9.8	0	0.312
I:1990(5)	0.172606	0.03312	5.21	0	0.1136
I:1990(6)	0.103146	0.03204	3.22	0.0015	0.0466
I:1990(7)	0.0853396	0.02865	2.98	0.0032	0.0402
I:1990(11)	-0.112365	0.03196	-3.52	0.0005	0.0551
I:1990(12)	-0.0781608	0.03183	-2.46	0.0149	0.0276
I:1991(4)	0.195405	0.03159	6.19	0	0.1529
I:1991(12)	-0.0908103	0.0294	-3.09	0.0023	0.0431
I:1992(2)	0.126149	0.02904	4.34	0	0.0818
I:1994(12)	0.0806872	0.02889	2.79	0.0057	0.0355
I:1995(5)	-0.111748	0.02904	-3.85	0.0002	0.0653
Vol_Ibov_1	-0.0192096	0.008279	-2.32	0.0213	0.0248
sigma	0.0278551	RSS	0.164491913		
R ²	0.87711	F(29,212) =	52.18 [0.000]**		
Adj.R ²	0.860299	log-likelihood	539.17		
no. of observations	242	no. of parameters	30		
mean(DLGeral)	0.00145427	se(DLGeral)	0.0745255		
AR 1-7 test:	F(7,205) =	1.6354 [0.1271]			
ARCH 1-7 test:	F(7,228) =	0.39617 [0.9040]			
Normality test:	Chi ² (2) =	2.2815 [0.3196]			
Hetero test:	F(19,208) =	1.0731 [0.3807]			
RESET23 test:	F(2,210) =	1.2166 [0.2983]			

Fonte: Elaboração própria

Tabela 34 – ESTIMAÇÃO: GFC - BRA - Modelo 3

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.361842	0.05599	-6.46	0	0.1627
DLGeral_7	-0.247154	0.05207	-4.75	0	0.0948
DLGeral_8	-0.164435	0.04992	-3.29	0.0012	0.048
DLGeral_12	0.153583	0.04774	3.22	0.0015	0.0459
CSeasonal	0.0618368	0.0122	5.07	0	0.1068
CSeasonal_1	0.0722773	0.01061	6.81	0	0.1775
CSeasonal_2	0.204008	0.01523	13.4	0	0.4549
CSeasonal_3	0.108342	0.0152	7.13	0	0.1912
CSeasonal_4	0.14731	0.01261	11.7	0	0.3884
CSeasonal_5	0.105186	0.01375	7.65	0	0.214
CSeasonal_6	0.0960714	0.01435	6.7	0	0.1726
CSeasonal_7	0.111122	0.01231	9.03	0	0.2748
CSeasonal_8	0.0798648	0.01171	6.82	0	0.1779
CSeasonal_9	0.135736	0.01208	11.2	0	0.3701
CSeasonal_10	0.0846174	0.01406	6.02	0	0.1442
DLGER_3 ²	0.515041	0.1667	3.09	0.0023	0.0425
I:1988(6)	0.0803397	0.0294	2.73	0.0068	0.0336
I:1990(3)	-0.114344	0.02953	-3.87	0.0001	0.0652
I:1990(4)	-0.314742	0.02998	-10.5	0	0.3389
I:1990(5)	0.139968	0.03393	4.12	0.0001	0.0733
I:1990(6)	0.10505	0.03314	3.17	0.0017	0.0446
I:1990(11)	-0.140244	0.0337	-4.16	0	0.0745
I:1990(12)	-0.119594	0.03493	-3.42	0.0007	0.0517
I:1991(4)	0.20051	0.03226	6.22	0	0.1523
I:1991(9)	-0.0792944	0.02955	-2.68	0.0079	0.0324
I:1992(2)	0.115596	0.02973	3.89	0.0001	0.0657
I:1995(5)	-0.118717	0.02984	-3.98	0.0001	0.0686
sigma	0.0286405	RSS	0.176360163		
log-likelihood	530.741				
no. of observations	242	no. of parameters	27		
mean(DLGeral)	0.00145427	se(DLGeral)	0.0745255		
AR 1-7 test:	F(7,208) =	1.6827 [0.1147]			
ARCH 1-7 test:	F(7,228) =	1.0053 [0.4282]			
Normality test:	Chi ² (2) =	2.3423 [0.3100]			
Hetero test:	F(21,209) =	0.87483 [0.6238]			
RESET23 test:	F(2,213) =	0.31780 [0.7281]			

Fonte: Elaboração própria

Tabela 35 – ESTIMAÇÃO: GFC - BRA - Modelo 4

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.295522	0.05003	-5.91	0	0.1402
DLGeral_7	-0.2447	0.04576	-5.35	0	0.1179
CSeasonal	0.0425141	0.01082	3.93	0.0001	0.0672
CSeasonal_1	0.0588682	0.009735	6.05	0	0.1459
CSeasonal_2	0.208827	0.01199	17.4	0	0.5865
CSeasonal_3	0.0855419	0.01291	6.63	0	0.1702
CSeasonal_4	0.155034	0.01062	14.6	0	0.4989
CSeasonal_5	0.0806793	0.01231	6.56	0	0.1672
CSeasonal_6	0.100814	0.0128	7.88	0	0.2248
CSeasonal_7	0.118692	0.01104	10.8	0	0.3508
CSeasonal_8	0.0718848	0.01066	6.74	0	0.1751
CSeasonal_9	0.132543	0.01036	12.8	0	0.4333
CSeasonal_10	0.0521626	0.01058	4.93	0	0.1019
VOL_1*DLGER_1	0.32353	0.07713	4.19	0	0.076
VOL_2*DLGER_2	-0.175739	0.06087	-2.89	0.0043	0.0375
VOL_2*DLGER_3	0.174804	0.06867	2.55	0.0116	0.0294
I:1988(6)	0.0766739	0.02836	2.7	0.0074	0.033
I:1989(6)	0.0770952	0.02885	2.67	0.0081	0.0323
I:1990(3)	-0.111692	0.02852	-3.92	0.0001	0.0669
I:1990(4)	-0.310408	0.0289	-10.7	0	0.3503
I:1990(5)	0.146986	0.03403	4.32	0	0.0802
I:1990(7)	0.15494	0.03339	4.64	0	0.0914
I:1990(11)	-0.134591	0.03106	-4.33	0	0.0807
I:1991(4)	0.183688	0.03206	5.73	0	0.133
I:1991(9)	-0.0701849	0.0285	-2.46	0.0146	0.0276
I:1991(12)	-0.0633472	0.02916	-2.17	0.0309	0.0216
I:1992(2)	0.130496	0.02926	4.46	0	0.085
I:1995(5)	-0.0787743	0.02957	-2.66	0.0083	0.0321
sigma	0.0275164	RSS	0.162031095		
log-likelihood	540.994				
no. of observations	242	no. of parameters	28		
mean(DLGeral)	0.00145427	se(DLGeral)	0.0745255		
AR 1-7 test:	F(7,207) =	0.75508 [0.6256]			
ARCH 1-7 test:	F(7,228) =	0.47438 [0.8526]			
Normality test:	Chi ² (2) =	2.7712 [0.2502]			
Hetero test:	F(21,208) =	0.65927 [0.8693]			
RESET23 test:	F(2,212) =	1.2548 [0.2873]			

Fonte: Elaboração própria

Tabela 36 – ESTIMAÇÃO: GFC - BRA - Modelo 5

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.185069	0.03611	-5.13	0	0.1089
DLGeral_2	-0.1889	0.04068	-4.64	0	0.0911
DLGeral_3	0.133618	0.04358	3.07	0.0024	0.0419
DLGeral_4	-0.175728	0.03864	-4.55	0	0.0878
DLGeral_5	-0.139377	0.04771	-2.92	0.0039	0.0382
DLGeral_6	-0.112322	0.03742	-3	0.003	0.0402
DLGeral_7	-0.267072	0.04579	-5.83	0	0.1366
DLGeral_12	0.176081	0.04502	3.91	0.0001	0.0664
CSeasonal_2	0.1498	0.01317	11.4	0	0.3758
CSeasonal_4	0.0915334	0.01276	7.17	0	0.1931
CSeasonal_6	0.0672913	0.01222	5.51	0	0.1236
CSeasonal_7	0.0725222	0.01049	6.91	0	0.1818
CSeasonal_8	0.0471506	0.009712	4.86	0	0.0988
CSeasonal_9	0.0953074	0.01099	8.68	0	0.2593
DLGER_1 ²	-0.911874	0.2536	-3.6	0.0004	0.0567
DLGER_2 ²	1.38773	0.2094	6.63	0	0.1696
DLGER_6 ²	-0.557922	0.2071	-2.69	0.0076	0.0327
DLGER_11 ²	0.406555	0.1805	2.25	0.0253	0.0231
DLGER_1*DLGER_9	1.34975	0.336	4.02	0.0001	0.0698
DLGER_1*DLGER_12	-1.55792	0.3924	-3.97	0.0001	0.0683
DLGER_2*DLGER_10	-1.4904	0.3386	-4.4	0	0.0826
I:1989(6)	0.104905	0.02972	3.53	0.0005	0.0548
I:1990(3)	-0.104116	0.02978	-3.5	0.0006	0.0538
I:1990(4)	-0.337047	0.02964	-11.4	0	0.3756
I:1990(5)	0.245463	0.04787	5.13	0	0.109
I:1992(6)	0.071642	0.03055	2.35	0.0199	0.0249
I:1995(5)	-0.0980628	0.03103	-3.16	0.0018	0.0444
sigma	0.0286475	RSS	0.1764457		
log-likelihood	530.682				
no. of observations	242	no. of parameters	27		
mean(DLGeral)	0.00145427	se(DLGeral)	0.0745255		
AR 1-7 test:	F(7,208) =	2.5551 [0.0152]*			
ARCH 1-7 test:	F(7,228) =	2.1967 [0.0355]*			
Normality test:	Chi ² (2) =	0.88275 [0.6432]			
Hetero test:	F(33,202) =	0.96416 [0.5290]			
RESET23 test:	F(2,213) =	0.64228 [0.5271]			

Fonte: Elaboração própria

Tabela 37 – ESTIMAÇÃO: GFC - BRA - Modelo 6

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.279048	0.03486	-8.01	0	0.2313
DLGeral_4	-0.175005	0.03913	-4.47	0	0.0859
DLGeral_7	-0.242261	0.05249	-4.62	0	0.0909
DLGeral_8	-0.124584	0.05184	-2.4	0.0171	0.0264
DLGeral_12	0.23048	0.04139	5.57	0	0.1271
CSeasonal_2	0.125282	0.01116	11.2	0	0.3717
CSeasonal_4	0.0827754	0.01022	8.1	0	0.2353
CSeasonal_5	0.0444064	0.009663	4.6	0	0.0902
CSeasonal_6	0.069765	0.01364	5.12	0	0.1094
CSeasonal_7	0.0631721	0.01069	5.91	0	0.1408
CSeasonal_8	0.0616469	0.009576	6.44	0	0.1629
CSeasonal_9	0.0855833	0.009988	8.57	0	0.2564
CSeasonal_10	0.0293757	0.01066	2.76	0.0064	0.0344
DLGER_2 ²	0.992421	0.1835	5.41	0	0.1207
DLGER_6 ²	-0.639709	0.204	-3.14	0.002	0.0441
DLGER_11 ²	0.80611	0.2081	3.87	0.0001	0.0658
VOL_1 ²	-0.0225296	0.007099	-3.17	0.0017	0.0452
VOL_1*DLGER_6	-0.201847	0.07797	-2.59	0.0103	0.0305
VOL_2*DLGER_2	-0.260507	0.05379	-4.84	0	0.0992
DLGER_1*DLGER_9	2.60748	0.5147	5.07	0	0.1075
DLGER_1*DLGER_12	-1.74515	0.3791	-4.6	0	0.0905
I:1989(6)	0.0944277	0.03033	3.11	0.0021	0.0435
I:1990(3)	-0.0988647	0.02983	-3.31	0.0011	0.049
I:1990(4)	-0.258311	0.03202	-8.07	0	0.234
I:1990(5)	0.179203	0.0382	4.69	0	0.0936
I:1990(12)	-0.0837437	0.03473	-2.41	0.0168	0.0266
I:1991(1)	-0.155393	0.04942	-3.14	0.0019	0.0444
I:1992(2)	0.0970647	0.03035	3.2	0.0016	0.0458
I:1993(3)	0.086482	0.02987	2.9	0.0042	0.0379
sigma	0.0285926	RSS	0.174135603		
log-likelihood	532.277				
no. of observations	242	no. of parameters	29		
mean(DLGeral)	0.00145427	se(DLGeral)	0.0745255		
AR 1-7 test:	F(7,206) =	1.4770 [0.1770]			
ARCH 1-7 test:	F(7,228) =	2.2282 [0.0329]*			
Normality test:	Chi ² (2) =	2.6512 [0.2656]			
Hetero test:	F(34,199) =	1.0369 [0.4207]			
RESET23 test:	F(2,211) =	1.6859 [0.1878]			

Fonte: Elaboração própria

Tabela 38 – ESTIMAÇÃO: DILMA - BRA - Modelo 1

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.261649	0.05	-5.23	0	0.0863
DLGeral_4	-0.150793	0.04372	-3.45	0.0006	0.0394
DLGeral_5	-0.125357	0.04333	-2.89	0.0041	0.0281
DLGeral_7	-0.253078	0.04415	-5.73	0	0.1018
CSeasonal	0.054049	0.009688	5.58	0	0.0969
CSeasonal_1	0.0715923	0.009021	7.94	0	0.1784
CSeasonal_2	0.217016	0.009238	23.5	0	0.6555
CSeasonal_3	0.062919	0.01465	4.3	0	0.0598
CSeasonal_4	0.142137	0.01106	12.9	0	0.3629
CSeasonal_5	0.0861976	0.01168	7.38	0	0.1581
CSeasonal_6	0.125371	0.01295	9.68	0	0.2442
CSeasonal_7	0.139746	0.01126	12.4	0	0.3467
CSeasonal_8	0.0733832	0.01057	6.94	0	0.1425
CSeasonal_9	0.160045	0.008824	18.1	0	0.5315
CSeasonal_10	0.0560817	0.01042	5.38	0	0.0908
I:1988(6)	0.0966887	0.03035	3.19	0.0016	0.0338
I:1989(6)	0.0988464	0.03052	3.24	0.0013	0.0349
I:1990(3)	-0.104726	0.03035	-3.45	0.0006	0.0394
I:1990(4)	-0.318152	0.03084	-10.3	0	0.2684
I:1990(5)	0.18618	0.03343	5.57	0	0.0966
I:1990(6)	0.0900344	0.03315	2.72	0.007	0.0248
I:1990(11)	-0.111168	0.03307	-3.36	0.0009	0.0375
I:1991(4)	0.129001	0.03092	4.17	0	0.0566
I:1991(12)	-0.0971174	0.0305	-3.18	0.0016	0.0338
I:1992(2)	0.104794	0.03046	3.44	0.0007	0.0392
sigma	0.0297075	RSS	0.255934674		
log-likelihood	673.711				
no. of observations	315	no. of parameters	25		
mean(DLGeral)	0.00146154	se(DLGeral)	0.0727158		
AR 1-7 test:	F(7,283) =	2.2962 [0.0273]*			
ARCH 1-7 test:	F(7,301) =	0.61950 [0.7397]			
Normality test:	Chi ² (2) =	13.657 [0.0011]**			
Hetero test:	F(19,285) =	1.7307 [0.0310]*			
RESET23 test:	F(2,288) =	0.61210 [0.5429]			

Fonte: Elaboração própria

Tabela 39 – ESTIMAÇÃO: DILMA - BRA - Modelo 2

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.389317	0.04917	-7.92	0	0.1835
DLGeral_2	-0.139735	0.04522	-3.09	0.0022	0.0331
DLGeral_4	-0.142039	0.03917	-3.63	0.0003	0.045
DLGeral_7	-0.249322	0.04442	-5.61	0	0.1015
DLGeral_8	-0.143548	0.04386	-3.27	0.0012	0.037
Constant	0.0147203	0.003147	4.68	0	0.0727
CSeasonal	0.0523003	0.01026	5.1	0	0.0852
CSeasonal_1	0.0726604	0.01016	7.15	0	0.155
CSeasonal_2	0.22321	0.009194	24.3	0	0.6787
CSeasonal_3	9.89e-2	0.01364	7.25	0	0.1586
CSeasonal_4	1.83e-1	0.009	20.3	0	0.5968
CSeasonal_5	1.09e-1	0.01126	9.72	0	0.2531
CSeasonal_6	0.139471	0.01206	11.6	0	0.3239
CSeasonal_7	0.127726	0.01018	12.6	0	0.3609
CSeasonal_8	0.0993791	0.009603	10.3	0	0.2774
CSeasonal_9	0.160833	0.008233	19.5	0	0.5776
CSeasonal_10	0.0927837	0.01221	7.6	0	0.1715
I:1988(6)	0.0896498	0.02754	3.26	0.0013	0.0366
I:1988(11)	-0.0651775	0.02767	-2.36	0.0192	0.0195
I:1989(6)	0.10768	0.02782	3.87	0.0001	0.051
I:1989(7)	0.0644433	0.02836	2.27	0.0238	0.0182
I:1990(3)	-0.0967326	0.02741	-3.53	0.0005	0.0427
I:1990(4)	-0.292209	0.02872	-10.2	0	0.2707
I:1990(5)	0.15846	0.03223	4.92	0	0.0797
I:1990(6)	0.0921434	0.03149	2.93	0.0037	0.0298
I:1990(7)	0.104613	0.03019	3.47	0.0006	0.0413
I:1990(11)	-0.138403	0.031	-4.46	0	0.0667
I:1990(12)	-0.102952	0.03148	-3.27	0.0012	0.0369
I:1991(4)	0.136142	0.02781	4.9	0	0.0791
I:1991(12)	-0.0826384	0.02821	-2.93	0.0037	0.0298
I:1992(2)	0.121282	0.02774	4.37	0	0.0641
I:1993(3)	0.0640998	0.02744	2.34	0.0202	0.0192
I:1994(3)	0.0769999	0.02761	2.79	0.0057	0.0271
I:1994(12)	0.085247	0.02753	3.1	0.0022	0.0332
I:1995(5)	-0.105801	0.02753	-3.84	0.0002	0.0503
Vol_Ibov_1	-0.0334869	0.007305	-4.58	0	0.07
sigma	0.026682	RSS	0.198627882		
R ²	0.880367	F(35,279) =	58.66 [0.000]**		
Adj.R ²	0.865359	log-likelihood	713.635		
no. of observations	315	no. of parameters	36		
mean(DLGeral)	0.00146154	se(DLGeral)	0.0727158		
AR 1-7 test:	F(7,272) =	0.42048 [0.8892]			
ARCH 1-7 test:	F(7,301) =	1.3508 [0.2260]			
Normality test:	Chi ² (2) =	11.914 [0.0026]**			
Hetero test:	F(23,273) =	1.6218 [0.0386]*			
RESET23 test:	F(2,277) =	3.6175 [0.0281]*			

Fonte: Elaboração própria

Tabela 40 – ESTIMAÇÃO: DILMA - BRA - Modelo 3

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.163406	0.02912	-5.61	0	0.0989
DLGeral_2	-0.1703	0.03532	-4.82	0	0.0749
DLGeral_3	0.139427	0.04375	3.19	0.0016	0.0342
DLGeral_4	-0.145561	0.03479	-4.18	0	0.0575
DLGeral_7	-0.232495	0.03894	-5.97	0	0.1105
DLGeral_12	0.177556	0.03901	4.55	0	0.0673
CSeasonal_2	0.151987	0.01141	13.3	0	0.382
CSeasonal_4	0.116271	0.01056	11	0	0.297
CSeasonal_5	0.024788	0.008701	2.85	0.0047	0.0275
CSeasonal_6	0.0784906	0.01072	7.32	0	0.1573
CSeasonal_7	0.0666398	0.008109	8.22	0	0.1905
CSeasonal_8	0.0523744	0.007865	6.66	0	0.1338
CSeasonal_9	0.0922031	0.009487	9.72	0	0.2476
DLGER_1 ²	-0.737305	0.2372	-3.11	0.0021	0.0326
DLGER_2 ²	1.44231	0.1976	7.3	0	0.1565
DLGER_6 ²	-0.712346	0.1835	-3.88	0.0001	0.0499
DLGER_11 ²	0.571811	0.1642	3.48	0.0006	0.0405
DLGER_1*DLGER_9	2.45473	0.4668	5.26	0	0.0879
DLGER_1*DLGER_12	-1.6278	0.3501	-4.65	0	0.07
DLGER_2*DLGER_10	-1.55181	0.3143	-4.94	0	0.0783
I:1989(6)	0.102846	0.02899	3.55	0.0005	0.042
I:1990(3)	-0.0907564	0.0288	-3.15	0.0018	0.0334
I:1990(4)	-0.319883	0.02859	-11.2	0	0.3036
I:1990(5)	0.261448	0.04316	6.06	0	0.1134
I:1991(1)	-0.144086	0.04664	-3.09	0.0022	0.0322
I:1991(9)	-0.100397	0.02877	-3.49	0.0006	0.0407
I:1992(6)	0.0809689	0.02927	2.77	0.006	0.026
I:1995(5)	-0.103305	0.0297	-3.48	0.0006	0.0405
sigma	0.027904	RSS	0.223468312		
log-likelihood	695.076				
no. of observations	315	no. of parameters	28		
mean(DLGeral)	0.00146154	se(DLGeral)	0.0727158		
AR 1-7 test:	F(7,280) =	2.6806 [0.0106]*			
ARCH 1-7 test:	F(7,301) =	0.51727 [0.8214]			
Normality test:	Chi ² (2) =	3.9021 [0.1421]			
Hetero test:	F(31,275) =	1.2310 [0.1932]			
RESET23 test:	F(2,285) =	1.0480 [0.3520]			

Fonte: Elaboração própria

Tabela 41 – ESTIMAÇÃO: DILMA - BRA - Modelo 4

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.294336	0.0413	7.13	0	0.1535
DLGeral_3	0.140415	0.04177	3.36	0.0009	0.0388
DLGeral_4	-0.131851	0.03991	3.3	0.0011	0.0375
DLGeral_9	0.236124	0.06274	3.76	0.0002	0.0481
CSeasonal	0.0705594	0.01104	6.39	0	0.1273
CSeasonal_1	0.0813173	0.0084	9.68	0	0.2508
CSeasonal_2	0.238977	0.01208	19.8	0	0.5827
CSeasonal_3	0.100441	0.01256	8	0	0.1859
CSeasonal_4	0.153933	0.009901	15.5	0	0.4633
CSeasonal_5	0.104614	0.01262	8.29	0	0.197
CSeasonal_6	0.151021	0.011	13.7	0	0.4023
CSeasonal_7	0.143021	0.01196	12	0	0.338
CSeasonal_8	0.127091	0.01278	9.94	0	0.2609
CSeasonal_9	0.148907	0.01056	14.1	0	0.4153
CSeasonal_10	0.0903218	0.01034	8.73	0	0.2141
DLGER_2 ²	1.10126	0.1851	5.95	0	0.1122
DLGER_6 ²	-0.445413	0.1677	2.66	0.0084	0.0246
VOL_1*DLGER_7	-0.294903	0.06223	4.74	0	0.0743
VOL_1*DLGER_9	-0.333936	0.1009	3.31	0.0011	0.0376
VOL_1*DLGER_12	0.305818	0.06976	4.38	0	0.0642
I:1988(6)	0.0862138	0.02652	3.25	0.0013	0.0364
I:1988(12)	0.0653445	0.02657	2.46	0.0145	0.0211
I:1989(6)	0.0772848	0.02701	2.86	0.0045	0.0284
I:1990(3)	-0.11726	0.02683	4.37	0	0.0639
I:1990(4)	-0.309276	0.02807	11	0	0.3024
I:1990(5)	0.192819	0.03137	6.15	0	0.1189
I:1991(4)	0.180184	0.0295	6.11	0	0.1176
I:1991(9)	-0.0992118	0.02792	3.55	0.0004	0.0431
I:1991(12)	-0.0644644	0.02685	2.4	0.017	0.0202
I:1992(2)	0.139301	0.0271	5.14	0	0.0862
I:1992(3)	-0.0656524	0.02732	2.4	0.0169	0.0202
I:1992(6)	0.0800594	0.02724	2.94	0.0036	0.0299
I:1994(12)	0.0956695	0.02662	3.59	0.0004	0.0441
I:1995(5)	-0.119237	0.02672	4.46	0	0.0664
Vol_Ibov_1	-0.00847758	0.004454	1.9	0.058	0.0128
sigma	0.0256928	RSS	0.184833913		
log-likelihood	724.971				
no. of observations	315	no. of parameters	35		
mean(DLGeral)	0.00146154	se(DLGeral)	0.0727158		
AR 1-7 test:	F(7,273) =	2.5417 [0.0150]*			
ARCH 1-7 test:	F(7,301) =	1.0820 [0.3747]			
Normality test:	Chi ² (2) =	3.8880 [0.1431]			
Hetero test:	F(31,269) =	1.1263 [0.3015]			
RESET23 test:	F(2,278) =	1.5744 [0.2090]			

Fonte: Elaboração própria

Tabela 42 – ESTIMAÇÃO: DILMA - BRA - Modelo 5

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.248025	0.04152	-5.97	0	0.1127
DLGeral_3	0.230084	0.03892	5.91	0	0.1106
DLGeral_7	-0.256798	0.03933	-6.53	0	0.1317
Vol_Ibov_1	-0.0193138	0.004792	-4.03	0.0001	0.0546
CSeasonal_1	0.0785702	0.008985	8.74	0	0.2139
CSeasonal_2	0.238671	0.00941	25.4	0	0.696
CSeasonal_3	0.0710933	0.01338	5.31	0	0.0913
CSeasonal_4	0.165631	0.01021	16.2	0	0.4838
CSeasonal_5	0.0541995	0.01144	4.74	0	0.074
CSeasonal_6	0.107035	0.01065	10	0	0.2643
CSeasonal_7	0.124261	0.009782	12.7	0	0.3648
CSeasonal_8	0.0618691	0.009187	6.73	0	0.139
CSeasonal_9	0.146615	0.009686	15.1	0	0.4491
CSeasonal_10	0.0473279	0.01013	4.67	0	0.072
DLGER_2 ²	1.13139	0.2021	5.6	0	0.1004
DLGER_5 ²	-0.515943	0.1764	-2.92	0.0037	0.0295
DLGER_9 ²	0.965694	0.2525	3.82	0.0002	0.0495
DLGER_1*DLGER_6	-1.27812	0.4559	-2.8	0.0054	0.0272
DLGER_1*DLGER_9	2.28953	0.475	4.82	0	0.0764
DLGER_1*DLGER_10	-1.38872	0.4052	-3.43	0.0007	0.0401
DLGER_1*DLGER_12	-1.37068	0.4534	-3.02	0.0027	0.0315
DLGER_2*DLGER_10	-2.44193	0.3673	-6.65	0	0.1359
I:1988(6)	0.0859199	0.02639	3.26	0.0013	0.0363
I:1988(10)	-0.0855007	0.02635	-3.24	0.0013	0.0361
I:1989(6)	0.138271	0.02673	5.17	0	0.087
I:1990(3)	-0.0906668	0.02652	-3.42	0.0007	0.0399
I:1990(4)	-0.285327	0.02733	-10.4	0	0.2794
I:1990(5)	0.237985	0.03349	7.11	0	0.1524
I:1990(11)	-0.131581	0.02875	-4.58	0	0.0694
I:1991(1)	-0.256634	0.05221	-4.92	0	0.0792
I:1991(4)	0.0837089	0.02922	2.87	0.0045	0.0284
I:1991(5)	0.137713	0.03401	4.05	0.0001	0.0551
I:1991(9)	-0.146367	0.0288	-5.08	0	0.0842
I:1995(5)	-0.113879	0.02724	-4.18	0	0.0586
sigma	0.0256867	RSS	0.185406344		
log-likelihood	724.484				
no. of observations	315	no. of parameters	34		
mean(DLGeral)	0.00146154	se(DLGeral)	0.0727158		
AR 1-7 test:	F(7,274) =	1.8843 [0.0721]			
ARCH 1-7 test:	F(7,301) =	0.44412 [0.8738]			
Normality test:	Chi ² (2) =	3.5741 [0.1674]			
Hetero test:	F(34,268) =	1.3133 [0.1230]			
RESET23 test:	F(2,279) =	1.0014 [0.3687]			

Fonte: Elaboração própria

Tabela 43 – ESTIMAÇÃO: DILMA - BRA - Modelo 6

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.315338	0.04747	-6.64	0	0.1361
DLGeral_4	-0.130963	0.03991	-3.28	0.0012	0.037
DLGeral_7	-0.196916	0.04136	-4.76	0	0.0749
DLGeral_8	-0.113119	0.04923	-2.3	0.0223	0.0185
DLGeral_9	0.123039	0.04531	2.72	0.007	0.0257
Vol_Ibov_1	0.0341407	0.011	3.1	0.0021	0.0333
CSeasonal	0.0556756	0.01159	4.8	0	0.0761
CSeasonal_1	0.0466294	0.01085	4.3	0	0.0619
CSeasonal_2	0.217398	0.0125	17.4	0	0.5192
CSeasonal_3	0.0874184	0.01354	6.46	0	0.1295
CSeasonal_4	0.141412	0.01163	12.2	0	0.3457
CSeasonal_5	0.082605	0.01279	6.46	0	0.1297
CSeasonal_6	0.122739	0.01263	9.72	0	0.2524
CSeasonal_7	0.137851	0.01434	9.61	0	0.2481
CSeasonal_8	0.106478	0.01433	7.43	0	0.1647
CSeasonal_9	0.150346	0.01088	13.8	0	0.4053
CSeasonal_10	0.0806392	0.01304	6.18	0	0.1201
DLGER_1 ²	-1.29685	0.2846	-4.56	0	0.0691
DLGER_2 ²	1.17077	0.212	5.52	0	0.0982
DLGER_5 ²	-0.507173	0.1914	-2.65	0.0085	0.0245
DLGER_7 ²	-0.392158	0.1971	-1.99	0.0476	0.0139
DLGER_11 ²	0.749715	0.1864	4.02	0.0001	0.0546
VOL_1 ²	-0.0473542	0.01233	-3.84	0.0002	0.0501
VOL_1*DLGER_5	-0.325088	0.06837	-4.75	0	0.0747
VOL_1*DLGER_12	0.2015	0.07079	2.85	0.0047	0.0281
VOL_2*DLGER_2	-0.272098	0.05982	-4.55	0	0.0688
VOL_2*DLGER_3	0.210279	0.06495	3.24	0.0014	0.0361
VOL_2*DLGER_6	-0.287445	0.0765	-3.76	0.0002	0.048
DLGER_1*DLGER_9	1.9061	0.3368	5.66	0	0.1026
DLGER_2*DLGER_10	-1.68593	0.3266	-5.16	0	0.0869
I:1988(10)	-0.0842588	0.02732	-3.08	0.0022	0.0328
I:1989(6)	0.08604	0.02763	3.11	0.002	0.0335
I:1990(3)	-0.113313	0.02739	-4.14	0	0.0576
I:1990(4)	-0.323334	0.03151	-10.3	0	0.2732
I:1990(5)	0.276967	0.04637	5.97	0	0.113
sigma	0.0262186	RSS	0.192476573		
log-likelihood	718.59				
no. of observations	315	no. of parameters	35		
mean(DLGeral)	0.00146154	se(DLGeral)	0.0727158		
AR 1-7 test:	F(7,273) =	1.3404 [0.2312]			
ARCH 1-7 test:	F(7,301) =	0.62413 [0.7359]			
Normality test:	Chi ² (2) = 0	0.068539 [0.9663]			
Hetero test:	F(46,263) =	1.3891 [0.0594]			
RESET23 test:	F(2,278) =	3.8241 [0.0230]*			

Fonte: Elaboração própria

Tabela 44 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 1

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.311686	0.04491	6.94	0	0.1198
DLGeral_3	0.180397	0.04123	4.37	0	0.0513
DLGeral_7	-0.185737	0.04487	4.14	0	0.0462
DLGeral_8	-0.12211	0.04296	2.84	0.0047	0.0223
CSeasonal	0.0764017	0.008907	8.58	0	0.1721
CSeasonal_1	0.0986454	0.007818	12.6	0	0.3102
CSeasonal_2	0.260657	0.008881	29.3	0	0.7087
CSeasonal_3	0.118862	0.012	9.91	0	0.217
CSeasonal_4	0.17545	0.007474	23.5	0	0.6089
CSeasonal_5	0.102193	0.012	8.52	0	0.17
CSeasonal_6	0.136709	0.01122	12.2	0	0.2955
CSeasonal_7	0.131233	0.009942	13.2	0	0.3299
CSeasonal_8	0.0920485	0.009122	10.1	0	0.2234
CSeasonal_9	0.149594	0.008512	17.6	0	0.466
CSeasonal_10	0.0807835	0.01146	7.05	0	0.1231
I:1988(6)	0.0916105	0.02923	3.13	0.0019	0.027
I:1989(6)	0.0976557	0.02942	3.32	0.001	0.0302
I:1990(3)	-0.0977732	0.02926	3.34	0.0009	0.0306
I:1990(4)	-0.308991	0.02953	10.5	0	0.2363
I:1990(5)	0.174844	0.03201	5.46	0	0.0777
I:1990(6)	0.123664	0.03179	3.89	0.0001	0.041
I:1990(7)	0.129388	0.03156	4.1	0.0001	0.0453
I:1990(11)	-0.123199	0.03226	3.82	0.0002	0.0396
I:1990(12)	-0.112004	0.03299	3.39	0.0008	0.0315
I:1991(4)	0.153987	0.02927	5.26	0	0.0725
I:1991(9)	-0.0800986	0.02928	2.74	0.0065	0.0207
I:1992(2)	0.117124	0.0294	3.98	0.0001	0.0429
sigma	0.0287445	RSS	0.29249084		
log-likelihood	825.674				
no. of observations	381	no. of parameters	27		
mean(DLGeral)	0.000443551	se(DLGeral)	0.0715202		
AR 1-7 test:	F(7,347) =	0.92585 [0.4864]			
ARCH 1-7 test:	F(7,367) =	1.2302 [0.2851]			
Normality test:	Chi ² (2) =	8.4195 [0.0148]*			
Hetero test:	F(19,349) =	1.8267 [0.0190]*			
RESET23 test:	F(2,352) =	2.0300 [0.1329]			

Fonte: Elaboração própria

Tabela 45 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 2

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.34047	0.04283	7.95	0	0.1541
DLGeral_3	0.19914	0.0392	5.08	0	0.0692
DLGeral_7	-0.136273	0.04178	3.26	0.0012	0.0298
Constant	0.00709031	0.002774	2.56	0.011	0.0185
CSeasonal	0.0570168	0.008087	7.05	0	0.1253
CSeasonal_1	0.0918565	0.007383	12.4	0	0.3085
CSeasonal_2	0.249234	0.008191	30.4	0	0.7274
CSeasonal_3	0.114144	0.01101	10.4	0	0.2364
CSeasonal_4	0.165159	0.007224	22.9	0	0.601
CSeasonal_5	9.32e-2	0.01084	8.6	0	0.1756
CSeasonal_6	1.43e-1	0.01057	13.6	0	0.3468
CSeasonal_7	1.39e-1	0.0091	15.3	0	0.4015
CSeasonal_8	0.0859038	0.008722	9.85	0	0.2185
CSeasonal_9	0.141654	0.008094	17.5	0	0.4688
CSeasonal_10	0.0631758	0.008904	7.1	0	0.1267
I:1987(9)	0.0718797	0.02767	2.6	0.0098	0.0191
I:1988(6)	0.0957343	0.02764	3.46	0.0006	0.0334
I:1988(10)	-0.0710552	0.02762	2.57	0.0105	0.0187
I:1989(5)	0.0683881	0.02811	2.43	0.0155	0.0168
I:1989(6)	0.116028	0.02783	4.17	0	0.0477
I:1990(3)	-0.0928221	0.02769	3.35	0.0009	0.0314
I:1990(4)	-0.293949	0.02889	10.2	0	0.2298
I:1990(5)	0.19491	0.03064	6.36	0	0.1044
I:1990(6)	0.141448	0.03032	4.66	0	0.059
I:1990(7)	0.141289	0.02981	4.74	0	0.0608
I:1990(11)	-0.0983833	0.02985	3.3	0.0011	0.0303
I:1990(12)	-0.092995	0.02984	3.12	0.002	0.0272
I:1991(4)	0.154513	0.0277	5.58	0	0.0823
I:1991(5)	0.0711774	0.02865	2.48	0.0134	0.0175
I:1991(9)	-0.0713111	0.02783	2.56	0.0108	0.0186
I:1991(12)	-0.093352	0.02791	3.35	0.0009	0.0312
I:1992(2)	0.125075	0.02799	4.47	0	0.0544
I:2008(12)	-0.11443	0.02791	4.1	0.0001	0.0462
Vol_Ibov_1	-0.0194572	0.006895	2.82	0.0051	0.0224
sigma	0.027124	RSS	0.255291226		
R ²	0.868661	F(33,347) =	69.55 [0.000]**		
Adj.R ²	0.85617	log-likelihood	851.587		
no. of observations	381	no. of parameters	34		
mean(DLGeral) 0	0.000443551	se(DLGeral)	0.0715202		
AR 1-7 test:	F(7,340) =	2.4788 [0.0171]*			
ARCH 1-7 test:	F(7,367) =	0.78991 [0.5961]			
Normality test:	Chi ² (2) =	3.6930 [0.1578]			
Hetero test:	F(19,343) =	1.8430 [0.0176]*			
RESET23 test:	F(2,345) =	7.8050 [0.0005]**			

Fonte: Elaboração própria

Tabela 46 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 3

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.307269	0.04648	-6.61	0	0.1104
DLGeral_2	-0.10779	0.04693	-2.3	0.0222	0.0148
DLGeral_3	0.227939	0.04366	5.22	0	0.0719
DLGeral_5	-0.12421	0.04085	-3.04	0.0025	0.0256
DLGeral_6	-0.150087	0.04493	-3.34	0.0009	0.0307
DLGeral_7	-0.182366	0.03991	-4.57	0	0.056
DLGeral_9	0.188056	0.04369	4.3	0	0.05
CSeasonal	0.0691017	0.0117	5.91	0	0.0902
CSeasonal_1	0.0690583	0.01208	5.72	0	0.085
CSeasonal_2	0.262071	0.01058	24.8	0	0.6353
CSeasonal_3	0.112252	0.01234	9.09	0	0.1903
CSeasonal_4	0.164075	0.01225	13.4	0	0.3377
CSeasonal_5	0.0806859	0.01497	5.39	0	0.0763
CSeasonal_6	0.134108	0.01188	11.3	0	0.2659
CSeasonal_7	0.177109	0.01234	14.4	0	0.3693
CSeasonal_8	0.13118	0.01452	9.03	0	0.1882
CSeasonal_9	0.160136	0.009624	16.6	0	0.4402
CSeasonal_10	0.0768849	0.01179	6.52	0	0.1078
DLGER_1 ²	-0.799659	0.2616	-3.06	0.0024	0.0259
DLGER_2 ²	1.51542	0.2221	6.82	0	0.1168
DLGER_5 ²	-0.718328	0.1821	-3.94	0.0001	0.0423
DLGER_1*DLGER_9	1.68144	0.3462	4.86	0	0.0628
DLGER_2*DLGER_10	-1.90822	0.3345	-5.7	0	0.0846
I:1988(10)	-0.0897111	0.02913	-3.08	0.0022	0.0262
I:1989(6)	0.124764	0.02923	4.27	0	0.0492
I:1990(3)	-0.108415	0.02928	-3.7	0.0002	0.0375
I:1990(4)	-0.334054	0.02987	-11.2	0	0.2621
I:1990(5)	0.284112	0.04237	6.71	0	0.1133
I:1991(5)	0.0799721	0.03178	2.52	0.0123	0.0177
sigma	0.0284427	RSS	0.284762652		
log-likelihood	830.775				
no. of observations	381	no. of parameters	29		
mean(DLGeral)	0.000443551	se(DLGeral)	0.0715202		
AR 1-7 test:	F(7,345) =	1.5699 [0.1432]			
ARCH 1-7 test:	F(7,367) =	1.6524 [0.1196]			
Normality test:	Chi ² (2) =	2.8557 [0.2398]			
Hetero test:	F(32,342) =	1.7159 [0.0109]*			
RESET23 test:	F(2,350) =	1.3323 [0.2652]			

Fonte: Elaboração própria

Tabela 47 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 4

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.362651	0.04354	8.33	0	0.1651
DLGeral_2	-0.163095	0.04387	3.72	0.0002	0.0379
DLGeral_3	0.135062	0.041	3.29	0.0011	0.03
CSeasonal	0.0501326	0.009225	5.43	0	0.0776
CSeasonal_1	0.0382099	0.01139	3.35	0.0009	0.0311
CSeasonal_2	0.217401	0.01051	20.7	0	0.5492
CSeasonal_3	0.109188	0.01065	10.3	0	0.2304
CSeasonal_4	0.150868	0.009779	15.4	0	0.4041
CSeasonal_5	0.0904949	0.01054	8.58	0	0.1734
CSeasonal_6	0.141871	0.009359	15.2	0	0.3956
CSeasonal_7	0.139213	0.00974	14.3	0	0.3679
CSeasonal_8	0.0892519	0.008395	10.6	0	0.2436
CSeasonal_9	0.136758	0.008703	15.7	0	0.413
CSeasonal_10	0.0554384	0.009168	6.05	0	0.0944
DLGER_1 ²	-0.834339	0.2539	3.29	0.0011	0.0298
DLGER_2 ²	1.3439	0.2111	6.37	0	0.1035
DLGER_11 ²	0.681014	0.1996	3.41	0.0007	0.0321
VOL_1 ²	-0.0241802	0.006538	3.7	0.0003	0.0375
VOL_1*DLGER_7	-0.352312	0.06421	5.49	0	0.079
VOL_1*DLGER_12	0.277139	0.06771	4.09	0.0001	0.0456
VOL_2*DLGER_4	-0.185021	0.06218	2.98	0.0031	0.0246
VOL_2*DLGER_5	-0.15436	0.06433	2.4	0.0169	0.0161
I:1989(6)	0.0923771	0.02862	3.23	0.0014	0.0288
I:1990(3)	-0.100833	0.02822	3.57	0.0004	0.0351
I:1990(4)	-0.333799	0.03221	10.4	0	0.2343
I:1990(5)	0.225288	0.04359	5.17	0	0.0707
I:1990(11)	-0.0983426	0.02961	3.32	0.001	0.0305
I:1992(2)	0.121679	0.02953	4.12	0	0.0461
I:1994(12)	0.0945314	0.02802	3.37	0.0008	0.0314
I:1995(5)	-0.113463	0.02841	3.99	0.0001	0.0435
sigma	0.0273578	RSS	0.262706624		
log-likelihood	846.132				
no. of observations	381	no. of parameters	30		
mean(DLGeral)	0.000443551	se(DLGeral)	0.0715202		
AR 1-7 test:	F(7,344) =	1.1008 [0.3621]			
ARCH 1-7 test:	F(7,367) =	0.93371 [0.4802]			
Normality test:	Chi ² (2) =	0.58211 [0.7475]			
Hetero test:	F(31,341) =	1.5723 [0.0296]*			
RESET23 test:	F(2,349) =	1.4930 [0.2261]			

Fonte: Elaboração própria

Tabela 48 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 5

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.385377	0.04562	-8.45	0	0.169
DLGeral_2	-0.223502	0.03519	-6.35	0	0.1031
DLGeral_4	-0.186246	0.03833	-4.86	0	0.063
DLGeral_5	-0.139367	0.0383	-3.64	0.0003	0.0364
DLGeral_7	-0.243059	0.04215	-5.77	0	0.0865
DLGeral_8	-0.131974	0.04319	-3.06	0.0024	0.0259
Vol_Ibov_1	-0.0108567	0.004151	-2.62	0.0093	0.0191
CSeasonal_1	0.0237519	0.008418	2.82	0.0051	0.0222
CSeasonal_2	0.186374	0.008082	23.1	0	0.6024
CSeasonal_3	0.0314075	0.01437	2.19	0.0295	0.0134
CSeasonal_4	0.129709	0.01088	11.9	0	0.2883
CSeasonal_5	0.0766608	0.01025	7.48	0	0.1375
CSeasonal_6	0.109772	0.0117	9.38	0	0.2004
CSeasonal_7	0.122008	0.01066	11.4	0	0.2718
CSeasonal_8	0.0670861	0.009521	7.05	0	0.1239
CSeasonal_9	0.131016	0.007847	16.7	0	0.4427
CSeasonal_10	0.0494495	0.01052	4.7	0	0.0592
DLGER_2 ²	1.12957	0.179	6.31	0	0.1018
DLGER_1*DLGER_9	2.52383	0.4429	5.7	0	0.0847
DLGER_1*DLGER_12	-1.93713	0.4146	-4.67	0	0.0586
DLGER_2*DLGER_10	-1.49065	0.3004	-4.96	0	0.0656
I:1989(6)	0.124627	0.02884	4.32	0	0.0505
I:1990(3)	-0.0992489	0.02837	-3.5	0.0005	0.0337
I:1990(4)	-0.312773	0.0292	-10.7	0	0.2463
I:1990(5)	0.125276	0.03428	3.65	0.0003	0.0366
I:1990(11)	-0.125514	0.03161	-3.97	0.0001	0.043
I:1990(12)	-0.0838459	0.03273	-2.56	0.0108	0.0184
I:1991(1)	-0.164013	0.04258	-3.85	0.0001	0.0406
I:1991(5)	0.120256	0.03423	3.51	0.0005	0.034
I:1995(5)	-0.101934	0.02906	-3.51	0.0005	0.0339
sigma	0.0276383	RSS	0.268121042		
log-likelihood	842.246				
no. of observations	381	no. of parameters	30		
mean(DLGeral)	0.000443551	se(DLGeral)	0.0715202		
AR 1-7 test:	F(7,344) =	2.2341 [0.0312]*			
ARCH 1-7 test:	F(7,367) =	1.2350 [0.2825]			
Normality test:	Chi ² (2) =	4.2116 [0.1218]			
Hetero test:	F(31,340) =	0.92119 [0.5914]			
RESET23 test:	F(2,349) =	1.3649 [0.2568]			

Fonte: Elaboração própria

Tabela 49 – ESTIMAÇÃO: COVID-19 - BRA - Modelo 6

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLGeral_1	-0.388081	0.04447	-8.73	0	0.1808
DLGeral_4	-0.124666	0.04247	-2.94	0.0036	0.0244
DLGeral_7	-0.187761	0.04258	-4.41	0	0.0534
DLGeral_8	-0.151574	0.04357	-3.48	0.0006	0.0339
CSeasonal	0.0454499	0.009941	4.57	0	0.0571
CSeasonal_1	0.07547	0.008995	8.39	0	0.1695
CSeasonal_2	0.187667	0.01123	16.7	0	0.4474
CSeasonal_3	0.0730805	0.01567	4.66	0	0.0593
CSeasonal_4	0.137354	0.009961	13.8	0	0.3553
CSeasonal_5	0.0899974	0.01152	7.81	0	0.1503
CSeasonal_6	0.115973	0.01203	9.64	0	0.2122
CSeasonal_7	0.124305	0.01046	11.9	0	0.2906
CSeasonal_8	0.0787902	0.009778	8.06	0	0.1584
CSeasonal_9	0.132602	0.009389	14.1	0	0.3663
CSeasonal_10	0.0802535	0.01182	6.79	0	0.118
DLGER_3 ²	0.522506	0.1908	2.74	0.0065	0.0213
VOL_1*DLGER_5	-0.253352	0.06227	-4.07	0.0001	0.0458
VOL_1*DLGER_12	0.295953	0.06859	4.31	0	0.0512
VOL_2*DLGER_2	-0.157208	0.05998	-2.62	0.0092	0.0195
DLGER_1*DLGER_2	-1.03871	0.2975	-3.49	0.0005	0.0341
DLGER_1*DLGER_9	1.01031	0.3215	3.14	0.0018	0.0278
DLGER_1*DLGER_12	-1.84551	0.4288	-4.3	0	0.051
DLGER_2*DLGER_10	-1.2643	0.2945	-4.29	0	0.0507
I:1988(6)	0.0810693	0.02735	2.96	0.0032	0.0248
I:1988(10)	-0.0697898	0.02738	-2.55	0.0112	0.0185
I:1989(6)	0.0970773	0.02818	3.44	0.0006	0.0332
I:1990(3)	-0.123509	0.02743	-4.5	0	0.0555
I:1990(4)	-0.324573	0.02898	-11.2	0	0.2666
I:1990(11)	-0.114651	0.03091	-3.71	0.0002	0.0384
I:1990(12)	-0.0786877	0.03198	-2.46	0.0144	0.0172
I:1991(4)	0.103303	0.03344	3.09	0.0022	0.0269
I:1991(5)	0.103018	0.03542	2.91	0.0039	0.0239
I:1992(6)	0.0704626	0.02761	2.55	0.0111	0.0185
I:1994(12)	0.0772844	0.02754	2.81	0.0053	0.0223
I:1995(5)	-0.117716	0.02955	-3.98	0.0001	0.044
Vol_Ibov_1	-0.00836132	0.004141	-2.02	0.0442	0.0117
sigma	0.0265881	RSS	0.243889724		
log-likelihood	860.291				
no. of observations	381	no. of parameters	36		
mean(DLGeral)	0.000443551	se(DLGeral)	0.0715202		
AR 1-7 test:	F(7,338) =	1.1039 [0.3601]			
ARCH 1-7 test:	F(7,367) =	0.65101 [0.7135]			
Normality test:	Chi ² (2) =	2.9127 [0.2331]			
Hetero test:	F(37,331) =	1.0581 [0.3833]			
RESET23 test:	F(2,343) =	2.4533 [0.0875]			

Fonte: Elaboração própria

Tabela 50 – ESTIMAÇÃO: GFC - EUA - Modelo 1

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_5	0.0872188	0.01804	4.83	0	0.0397
DLIP_12	0.245354	0.03314	7.4	0	0.0884
Constant	0.00197885	0.0004136	4.78	0	0.0389
CSeasonal_1	0.0275266	0.002121	13	0	0.2297
CSeasonal_2	0.0194807	0.001893	10.3	0	0.1579
CSeasonal_3	0.00802506	0.001798	4.46	0	0.0341
CSeasonal_4	0.0172379	0.00185	9.32	0	0.1332
CSeasonal_5	0.0278591	0.002089	13.3	0	0.2394
CSeasonal_6	-0.0376004	0.002571	-14.6	0	0.2745
CSeasonal_7	3.82e-2	0.002393	16	0	0.3108
CSeasonal_8	2.80e-2	0.002131	13.1	0	0.234
CSeasonal_9	1.39e-2	0.001827	7.61	0	0.093
CSeasonal_10	-0.00534327	0.001866	-2.86	0.0043	0.0143
I:1956(8)	0.0502308	0.009845	5.1	0	0.044
I:1957(12)	-0.0326219	0.009831	-3.32	0.001	0.0191
I:1958(2)	-0.0338477	0.009832	-3.44	0.0006	0.0205
I:1958(6)	0.0231348	0.009825	2.35	0.0189	0.0097
I:1958(8)	0.0253701	0.009866	2.57	0.0104	0.0116
I:1958(11)	0.0368677	0.00986	3.74	0.0002	0.0241
I:1959(1)	0.0282427	0.00989	2.86	0.0045	0.0142
I:1959(4)	0.0262889	0.009881	2.66	0.008	0.0124
I:1959(7)	-0.0286425	0.009824	-2.92	0.0037	0.0148
I:1959(8)	-0.0412492	0.009875	-4.18	0	0.03
I:1959(12)	0.0581251	0.009861	5.89	0	0.0579
I:1960(1)	0.0372422	0.009832	3.79	0.0002	0.0248
I:1960(6)	-0.0231718	0.009852	-2.35	0.019	0.0097
I:1960(11)	-0.0236683	0.009833	-2.41	0.0164	0.0102
I:1960(12)	-0.0431507	0.01001	-4.31	0	0.0319
I:1961(4)	0.0362031	0.009839	3.68	0.0003	0.0234
I:1964(11)	0.0256142	0.009827	2.61	0.0094	0.0119
I:1966(9)	0.0252261	0.009831	2.57	0.0105	0.0115
I:1970(10)	-0.0273427	0.009821	-2.78	0.0055	0.0135
I:1971(1)	0.0238783	0.009811	2.43	0.0152	0.0104
I:1971(9)	0.0279616	0.009822	2.85	0.0046	0.0141
I:1972(1)	0.0367847	0.009825	3.74	0.0002	0.0242
I:1973(8)	-0.0267936	0.009829	-2.73	0.0066	0.013
I:1974(11)	-0.0336722	0.009828	-3.43	0.0007	0.0204
I:1974(12)	-0.0516461	0.009828	-5.25	0	0.0466
I:1975(2)	-0.0310757	0.009825	-3.16	0.0016	0.0174
I:1978(4)	0.0264282	0.009835	2.69	0.0074	0.0126
I:1979(4)	-0.0339767	0.00987	-3.44	0.0006	0.0205
I:1979(8)	-0.0292633	0.009848	-2.97	0.0031	0.0154
I:1980(5)	-0.0407023	0.009842	-4.14	0	0.0294
I:1982(1)	-0.0250998	0.009798	-2.56	0.0107	0.0115
I:1983(1)	0.0336282	0.009829	3.42	0.0007	0.0203
I:2001(4)	-0.024889	0.00983	-2.53	0.0116	0.0112
sigma	0.00972302	RSS	0.0534135205		
R ²	0.892795	F(45,565) =	104.6 [0.000]**		
Adj.R ²	0.884257	log-likelihood	1987.86		
no. of observations	611	no. of parameters	46		
mean(DLIP)	0.00294514	se(DLIP)	0.0285794		
AR 1-7 test:	F(7,558) =	1.4297 [0.1906]			
ARCH 1-7 test:	F(7,597) =	1.2284 [0.2848]			
Normality test:	Chi ² (2) =	1.4317 [0.4888]			
Hetero test:	F(14,563) =	1.8544 [0.0287]*			
RESET23 test:	F(2,563) =	3.9121 [0.0205]*			

Fonte: Elaboração própria

Tabela 51 – ESTIMAÇÃO: GFC - EUA - Modelo 2

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_6	-0.087294	0.01985	-4.4	0	0.0327
DLIP_12	0.261793	0.03392	7.72	0	0.0943
DJIA_1	-0.0185378	0.006154	-3.01	0.0027	0.0156
CSeasonal_1	0.0353624	0.002514	14.1	0	0.257
CSeasonal_2	0.0239768	0.002111	11.4	0	0.1841
CSeasonal_3	0.0081344	0.001788	4.55	0	0.0349
CSeasonal_4	0.0157337	0.001771	8.88	0	0.1212
CSeasonal_5	0.0272145	0.002046	13.3	0	0.2362
CSeasonal_6	-0.0328522	0.002294	-14.3	0	0.2639
CSeasonal_7	4.22e-2	0.002678	15.8	0	0.303
CSeasonal_8	3.20e-2	0.002304	13.9	0	0.2524
CSeasonal_9	1.57e-2	0.001811	8.66	0	0.1159
I:1956(8)	0.0473618	0.01014	4.67	0	0.0368
I:1957(9)	-0.0256099	0.01013	-2.53	0.0118	0.011
I:1957(12)	-0.0332886	0.01008	-3.3	0.001	0.0187
I:1958(2)	-0.0351483	0.01013	-3.47	0.0006	0.0206
I:1958(11)	0.0382101	0.01008	3.79	0.0002	0.0245
I:1959(1)	0.0307963	0.01011	3.05	0.0024	0.016
I:1959(4)	0.0302055	0.01015	2.97	0.0031	0.0152
I:1959(7)	-0.0259106	0.01014	-2.56	0.0108	0.0113
I:1959(8)	-0.0402371	0.01018	-3.95	0.0001	0.0266
I:1959(12)	0.0536589	0.01008	5.32	0	0.0472
I:1960(1)	0.0310182	0.01019	3.04	0.0024	0.0159
I:1960(2)	-0.0244203	0.01015	-2.41	0.0164	0.01
I:1960(11)	-0.0268799	0.01006	-2.67	0.0077	0.0123
I:1960(12)	-0.048043	0.0102	-4.71	0	0.0373
I:1961(4)	0.0345713	0.01013	3.41	0.0007	0.0199
I:1971(9)	0.0273429	0.01013	2.7	0.0072	0.0126
I:1972(1)	0.0345397	0.01015	3.4	0.0007	0.0199
I:1972(4)	0.0231701	0.01014	2.29	0.0226	0.0091
I:1974(11)	-0.0289793	0.01016	-2.85	0.0045	0.014
I:1974(12)	-0.0509438	0.0101	-5.04	0	0.0426
I:1975(2)	-0.0318845	0.01015	-3.14	0.0018	0.0169
I:1978(4)	0.027001	0.01014	2.66	0.008	0.0122
I:1979(4)	-0.0324878	0.01018	-3.19	0.0015	0.0175
I:1980(5)	-0.0397852	0.01015	-3.92	0.0001	0.0262
I:1983(1)	0.034651	0.01014	3.42	0.0007	0.02
I:2005(9)	-0.0249414	0.01016	-2.46	0.0144	0.0104
Constant	0.00481256	0.0009003	5.35	0	0.0476

sigma	0.0100191	RSS	0.0574182412
R ²	0.884757	F(38,572) =	115.6 [0.000]**
Adj.R ²	0.877101	log-likelihood	1965.77
no. of observations	611	no. of parameters	39
mean(DLIP)	0.00294514	se(DLIP)	0.0285794
AR 1-7 test:	F(7,565) =	2.1126 [0.0406]*	
ARCH 1-7 test:	F(7,597) =	1.9932 [0.0539]	
Normality test:	Chi ² (2) =	1.1878 [0.5522]	
Hetero test:	F(15,569) =	2.0253 [0.0122]*	
RESET23 test:	F(2,570) =	7.6132 [0.0005]**	

Fonte: Elaboração própria

Tabela 52 – ESTIMAÇÃO: GFC - EUA - Modelo 3

	Coficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_1	0.135043	0.02795	4.83	0	0.0392
DLIP_7	0.101935	0.03264	3.12	0.0019	0.0168
DLIP_10	-0.126979	0.01926	-6.59	0	0.0706
DLIP_12	0.309355	0.03103	9.97	0	0.148
DLIP_7 ²	1.67899	0.569	2.95	0.0033	0.015
CSeasonal_1	0.018989	0.003939	4.82	0	0.039
CSeasonal_2	0.0042321	0.001955	2.16	0.0308	0.0081
CSeasonal_5	0.0270192	0.00242	11.2	0	0.1789
CSeasonal_6	-0.0405506	0.003291	-12.3	0	0.2098
CSeasonal_7	4.37e-2	0.003614	12.1	0	0.2034
CSeasonal_10	-9.72e-3	0.001947	-4.99	0	0.0418
DLIP_1*DLIP_6	3.04e+0	0.7598	4	0.0001	0.0272
DLIP_1*DLIP_12	-3.04406	0.8692	-3.5	0.0005	0.021
DLIP_2*DLIP_3	-1.30162	0.5233	-2.49	0.0132	0.0107
DLIP_2*DLIP_6	-3.16733	0.877	-3.61	0.0003	0.0223
DLIP_2*DLIP_9	1.93443	0.6398	3.02	0.0026	0.0157
DLIP_2*DLIP_12	-2.90347	0.7482	-3.88	0.0001	0.0257
I:1956(8)	0.0427209	0.01066	4.01	0.0001	0.0273
I:1957(3)	-0.0325969	0.011	-2.96	0.0032	0.0151
I:1957(12)	-0.0301183	0.0102	-2.95	0.0033	0.015
I:1958(2)	-0.043286	0.01037	-4.18	0	0.0296
I:1958(6)	0.0286461	0.01026	2.79	0.0054	0.0134
I:1958(11)	0.0394324	0.01028	3.83	0.0001	0.0251
I:1959(4)	0.0314606	0.01024	3.07	0.0022	0.0162
I:1959(7)	-0.0250267	0.01017	-2.46	0.0142	0.0105
I:1959(8)	-0.0467821	0.01079	-4.33	0	0.0318
I:1959(12)	0.0561793	0.01014	5.54	0	0.0509
I:1960(1)	0.0437719	0.01068	4.1	0	0.0285
I:1960(6)	-0.0233157	0.01019	-2.29	0.0225	0.0091
I:1960(12)	-0.0517155	0.01033	-5	0	0.0419
I:1961(4)	0.0333426	0.0101	3.3	0.001	0.0187
I:1972(1)	0.0305613	0.01029	2.97	0.0031	0.0152
I:1974(11)	-0.0325386	0.01018	-3.2	0.0015	0.0175
I:1974(12)	-0.0443763	0.01037	-4.28	0	0.031
I:1979(4)	-0.031642	0.01023	-3.09	0.0021	0.0164
I:1980(5)	-0.0394044	0.0102	-3.86	0.0001	0.0254
I:1982(2)	0.0326196	0.01025	3.18	0.0015	0.0174
I:1983(1)	0.0393494	0.01021	3.85	0.0001	0.0253
Constant	-0.00103845	0.0006601	-1.57	0.1162	0.0043
sigma	0.0100496	RSS	0.057768479		
R ²	0.884054	F(38,572) =	114.8 [0.000]**		
Adj.R ²	0.876352	log-likelihood	1963.92		
no. of observations	611	no. of parameters	39		
mean(DLIP)	0.00294514	se(DLIP)	0.0285794		
AR 1-7 test:	F(7,565) =	1.3917 [0.2061]			
ARCH 1-7 test:	F(7,597) =	1.6862 [0.1095]			
Normality test:	Chi ² (2) =	1.7818 [0.4103]			
Hetero test:	F(27,562) =	1.4118 [0.0828]			
RESET23 test:	F(2,570) =	0.60448 [0.5467]			

Fonte: Elaboração própria

Tabela 53 – ESTIMAÇÃO: GFC - USA - Modelo 4

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_10	-0.127733	0.01748	-7.31	0	0.0852
DLIP_12	0.305623	0.03195	9.57	0	0.1377
Constant	0.00476687	0.0009108	5.23	0	0.0456
DJIA_1	-0.0226972	0.006278	-3.62	0.0003	0.0223
CSeasonal_1	0.0208959	0.001956	10.7	0	0.166
CSeasonal_2	0.0119245	0.001803	6.61	0	0.0709
CSeasonal_5	0.025095	0.002065	12.2	0	0.205
CSeasonal_6	-0.0386207	0.002658	-14.5	0	0.2692
CSeasonal_7	0.0327896	0.002438	13.4	0	0.2399
CSeasonal_8	2.14e-2	0.002532	8.45	0	0.1108
CSeasonal_10	-1.24e-2	0.001809	-6.88	0	0.0763
DJ_1*DLIP_5	5.45e-1	0.1251	4.35	0	0.032
DJ_2*DLIP_1	0.566591	0.1654	3.43	0.0007	0.0201
DJ_2*DLIP_2	0.611945	0.1565	3.91	0.0001	0.026
I:1956(8)	0.0541644	0.01016	5.33	0	0.0472
I:1957(9)	-0.0252352	0.01014	-2.49	0.0131	0.0107
I:1957(12)	-0.0268132	0.01022	-2.62	0.009	0.0119
I:1958(2)	-0.0332276	0.01015	-3.27	0.0011	0.0183
I:1958(6)	0.0241986	0.01013	2.39	0.0172	0.0099
I:1958(11)	0.0361903	0.01015	3.56	0.0004	0.0217
I:1959(1)	0.0250563	0.01014	2.47	0.0137	0.0106
I:1959(4)	0.0309858	0.01013	3.06	0.0023	0.0161
I:1959(7)	-0.0268603	0.01013	-2.65	0.0082	0.0121
I:1959(8)	-0.0407651	0.01018	-4.01	0.0001	0.0272
I:1959(12)	0.0540709	0.01009	5.36	0	0.0477
I:1960(1)	0.0310867	0.01011	3.07	0.0022	0.0162
I:1960(6)	-0.0258462	0.01016	-2.54	0.0112	0.0112
I:1960(12)	-0.0509192	0.0102	-4.99	0	0.0417
I:1961(4)	0.0346038	0.01005	3.44	0.0006	0.0203
I:1972(1)	0.0365843	0.01013	3.61	0.0003	0.0223
I:1974(11)	-0.0377305	0.01024	-3.69	0.0002	0.0232
I:1974(12)	-0.0405532	0.01047	-3.87	0.0001	0.0255
I:1978(4)	0.026315	0.01009	2.61	0.0093	0.0117
I:1979(4)	-0.0346228	0.01011	-3.42	0.0007	0.02
I:1979(8)	-0.0278625	0.01015	-2.74	0.0063	0.013
I:1980(5)	-0.0348551	0.01017	-3.43	0.0007	0.0201
I:1982(2)	0.029434	0.01013	2.9	0.0038	0.0145
I:1983(1)	0.0399707	0.01022	3.91	0.0001	0.026
sigma	0.0100161	RSS	0.057484277		
R ²	0.884625	F(37,573) =	118.7 [0.000]**		
Adj.R ²	0.877175	log-likelihood	1965.42		
no. of observations	611	no. of parameters	38		
mean(DLIP)	0.00294514	se(DLIP)	0.0285794		
AR 1-7 test:	F(7,566) =	1.3442 [0.2270]			
ARCH 1-7 test:	F(7,597) =	1.1255 [0.3451]			
Normality test:	Chi ² (2) =	0.40963 [0.8148]			
Hetero test:	F(19,567) =	1.7491 [0.0255]*			
RESET23 test:	F(2,571) =	1.7528 [0.1742]			

Fonte: Elaboração própria

Tabela 54 – ESTIMAÇÃO: GFC - USA - Modelo 5

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_1	0.171148	0.02545	6.72	0	0.0728
DLIP_7	0.0981528	0.0316	3.11	0.002	0.0165
DLIP_10	-0.112851	0.01921	-5.87	0	0.0565
DLIP_12	0.334235	0.03085	10.8	0	0.1693
CSeasonal_1	0.0177951	0.003871	4.6	0	0.0354
CSeasonal_5	0.0242884	0.002375	10.2	0	0.1536
CSeasonal_6	-0.0409085	0.003311	-12.4	0	0.2095
CSeasonal_7	0.0436577	0.003638	12	0	0.2
CSeasonal_10	-0.0113077	0.001843	-6.14	0	0.0614
DLIP_7 ²	1.45037	0.4696	3.09	0.0021	0.0163
DLIP_1*DLIP_6	3.21257	0.7638	4.21	0	0.0298
DLIP_1*DLIP_1	-2.95935	0.8616	-3.43	0.0006	0.0201
DLIP_2*DLIP_6	-3.30433	0.8825	-3.74	0.0002	0.0238
DLIP_2*DLIP_9	2.05275	0.6424	3.2	0.0015	0.0174
DLIP_2*DLIP_1	-2.42482	0.7209	-3.36	0.0008	0.0193
I:1956(8)	0.044115	0.01076	4.1	0	0.0283
I:1957(12)	-0.0292509	0.01032	-2.83	0.0048	0.0138
I:1958(2)	-0.044002	0.01049	-4.2	0	0.0297
I:1958(6)	0.028754	0.01039	2.77	0.0058	0.0131
I:1958(11)	0.0381475	0.01039	3.67	0.0003	0.0229
I:1959(4)	0.0294633	0.01035	2.85	0.0046	0.0139
I:1959(7)	-0.025312	0.0103	-2.46	0.0142	0.0104
I:1959(8)	-0.0463226	0.01092	-4.24	0	0.0303
I:1959(12)	0.0558712	0.01025	5.45	0	0.049
I:1960(1)	0.0416424	0.0108	3.86	0.0001	0.0252
I:1960(12)	-0.0524484	0.01046	-5.01	0	0.0418
I:1961(4)	0.032125	0.01021	3.15	0.0017	0.0169
I:1972(1)	0.0311561	0.01041	2.99	0.0029	0.0153
I:1974(11)	-0.029885	0.01034	-2.89	0.004	0.0143
I:1974(12)	-0.0419351	0.0105	-3.99	0.0001	0.027
I:1979(4)	-0.0332588	0.01032	-3.22	0.0013	0.0177
I:1980(5)	-0.0390665	0.01033	-3.78	0.0002	0.0242
I:1982(2)	0.0336538	0.01036	3.25	0.0012	0.018
I:1983(1)	0.0401325	0.01035	3.88	0.0001	0.0254
DJIA_1	-0.00812137	0.003773	-2.15	0.0318	0.008
sigma	0.010173	RSS	0.0596105324		
log-likelihood	1954.33				
no. of observations	611	no. of parameters	35		
mean(DLIP)	0.00294514	se(DLIP)	0.0285794		
AR 1-7 test:	F(7,569) =	1.0880 [0.3693]			
ARCH 1-7 test:	F(7,597) =	1.1955 [0.3031]			
Normality test:	Chi ² (2) =	0.52819 [0.7679]			
Hetero test:	F(26,565) =	1.3205 [0.1342]			
RESET23 test:	F(2,574) =	0.61900 [0.5388]			

Fonte: Elaboração própria

Tabela 55 – ESTIMAÇÃO: GFC - USA - Modelo 6

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_10	-0.127753	0.01754	-7.28	0	0.0847
DLIP_12	0.307178	0.03216	9.55	0	0.1374
DJIA_1	-0.0219861	0.006307	-3.49	0.0005	0.0208
CSeasonal_1	0.019573	0.002018	9.7	0	0.141
CSeasonal_2	0.0118845	0.001824	6.52	0	0.069
CSeasonal_5	0.0247906	0.002072	12	0	0.1999
CSeasonal_6	-0.0427323	0.003096	-13.8	0	0.2495
CSeasonal_7	0.0294098	0.003145	9.35	0	0.1324
CSeasonal_8	0.0185262	0.002961	6.26	0	0.0639
CSeasonal_10	-1.43e-2	0.001883	-7.58	0	0.0911
DJ_1*DLIP_5	5.46e-1	0.1259	4.34	0	0.0318
DJ_2*DLIP_1	5.79e-1	0.1662	3.48	0.0005	0.0207
DJ_2*DLIP_2	0.636609	0.1574	4.04	0.0001	0.0278
DLIP_1*DLIP_12	-1.89256	0.8662	-2.18	0.0293	0.0083
DLIP_2*DLIP_12	-2.59867	0.8217	-3.16	0.0016	0.0172
I:1956(8)	0.0475583	0.0106	4.49	0	0.034
I:1957(9)	-0.0253234	0.01029	-2.46	0.0141	0.0105
I:1957(12)	-0.026208	0.01028	-2.55	0.011	0.0112
I:1958(2)	-0.0370512	0.01024	-3.62	0.0003	0.0224
I:1958(6)	0.0233216	0.01018	2.29	0.0224	0.0091
I:1958(8)	0.0229074	0.01032	2.22	0.0269	0.0085
I:1958(11)	0.0335958	0.01023	3.28	0.0011	0.0185
I:1959(1)	0.0248063	0.01019	2.43	0.0153	0.0102
I:1959(4)	0.0274959	0.01022	2.69	0.0073	0.0125
I:1959(7)	-0.0265749	0.01018	-2.61	0.0093	0.0117
I:1959(8)	-0.0459453	0.01067	-4.31	0	0.0314
I:1959(12)	0.054565	0.01014	5.38	0	0.0481
I:1960(1)	0.0309311	0.01018	3.04	0.0025	0.0159
I:1960(6)	-0.0264675	0.01021	-2.59	0.0098	0.0116
I:1960(12)	-0.0533108	0.01033	-5.16	0	0.0444
I:1961(4)	0.0335893	0.0101	3.33	0.0009	0.0189
I:1972(1)	0.0346801	0.01019	3.4	0.0007	0.0198
I:1974(11)	-0.0376593	0.01028	-3.66	0.0003	0.0229
I:1974(12)	-0.0372975	0.01063	-3.51	0.0005	0.021
I:1979(4)	-0.0318452	0.01019	-3.12	0.0019	0.0168
I:1980(5)	-0.0360343	0.01024	-3.52	0.0005	0.0212
I:1983(1)	0.0439103	0.01032	4.25	0	0.0306
Constant	0.0039362	0.0009385	4.19	0	0.0298
sigma	0.0100622	RSS	0.0580145877		
R ²	0.88356	F(37,573) =	117.5 [0.000]**		
Adj.R ²	0.876042	log-likelihood	1962.62		
no. of observations	611	no. of parameters	38		
mean(DLIP)	0.00294514	se(DLIP)	0.0285794		
AR 1-7 test:	F(7,566) =	1.1992 [0.3012]			
ARCH 1-7 test:	F(7,597) =	1.6310 [0.1238]			
Normality test:	Chi ² (2) =	0.88648 [0.6420]			
Hetero test:	F(23,565) =	1.5396 [0.0523]			
RESET23 test:	F(2,571) =	0.57865 [0.5610]			

Fonte: Elaboração própria

Tabela 56 – ESTIMAÇÃO: COVID-19 - EUA - Modelo 1

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_1	0.154185	0.02314	6.66	0	0.0607
DLIP_4	0.111061	0.01458	7.62	0	0.0778
DLIP_5	0.087899	0.01555	5.65	0	0.0444
DLIP_9	-0.0751375	0.01711	-4.39	0	0.0273
DLIP_10	-0.0994115	0.02175	-4.57	0	0.0295
DLIP_12	0.327436	0.02639	12.4	0	0.1831
CSeasonal_1	0.0200204	0.001559	12.8	0	0.1936
CSeasonal_2	0.0157441	0.001608	9.79	0	0.1225
CSeasonal_4	0.0112028	0.002132	5.25	0	0.0386
CSeasonal_5	0.0237839	0.001809	13.2	0	0.2011
CSeasonal_6	-0.0359852	0.002162	-16.6	0	0.2873
CSeasonal_7	0.0374888	0.002322	16.1	0	0.275
CSeasonal_8	0.00743338	0.001721	4.32	0	0.0264
I:1956(8)	0.0614861	0.00936	6.57	0	0.0591
I:1957(4)	-0.0210105	0.009362	-2.24	0.0251	0.0073
I:1957(12)	-0.0326904	0.009296	-3.52	0.0005	0.0177
I:1958(2)	-0.0308624	0.009299	-3.32	0.001	0.0158
I:1958(6)	0.0283386	0.009298	3.05	0.0024	0.0133
I:1958(8)	0.0263217	0.009314	2.83	0.0049	0.0115
I:1958(11)	0.0333417	0.009292	3.59	0.0004	0.0184
I:1959(1)	0.0250647	0.009344	2.68	0.0075	0.0104
I:1959(4)	0.0333248	0.009326	3.57	0.0004	0.0182
I:1959(7)	-0.0290411	0.009286	-3.13	0.0018	0.014
I:1959(8)	-0.0354168	0.009366	-3.78	0.0002	0.0204
I:1959(12)	0.0653251	0.009321	7.01	0	0.0667
I:1960(1)	0.0288968	0.009319	3.1	0.002	0.0138
I:1960(5)	-0.0262911	0.009386	-2.8	0.0052	0.0113
I:1960(12)	-0.0452413	0.009422	-4.8	0	0.0325
I:1961(4)	0.0405044	0.009318	4.35	0	0.0268
I:1962(9)	0.0275007	0.009289	2.96	0.0032	0.0126
I:1963(9)	0.025495	0.009309	2.74	0.0063	0.0108
I:1964(4)	0.0219205	0.009314	2.35	0.0189	0.008
I:1964(11)	0.0314528	0.00929	3.39	0.0008	0.0164
I:1965(10)	0.0246519	0.009285	2.66	0.0081	0.0102
I:1966(9)	0.0302481	0.009296	3.25	0.0012	0.0152
I:1967(8)	0.0252954	0.009291	2.72	0.0066	0.0107
I:1968(9)	0.025822	0.009299	2.78	0.0056	0.0111
I:1970(10)	-0.0285438	0.009283	-3.07	0.0022	0.0136
I:1971(9)	0.0331098	0.009289	3.56	0.0004	0.0182
I:1972(1)	0.0335163	0.009305	3.6	0.0003	0.0185
I:1972(4)	0.0262776	0.009313	2.82	0.0049	0.0115
I:1973(9)	0.0240676	0.009327	2.58	0.0101	0.0096
I:1974(11)	-0.0345631	0.009264	-3.73	0.0002	0.0199
I:1974(12)	-0.0421957	0.009306	-4.53	0	0.0291
I:1975(4)	0.0298252	0.009361	3.19	0.0015	0.0146
I:1978(4)	0.0264374	0.009298	2.84	0.0046	0.0116
I:1979(4)	-0.0349048	0.009314	-3.75	0.0002	0.02
I:1979(5)	0.0257852	0.009303	2.77	0.0057	0.0111
I:1979(8)	-0.0205405	0.009292	-2.21	0.0274	0.0071
I:1980(5)	-0.0391806	0.009325	-4.2	0	0.0251
I:1980(9)	0.024258	0.009315	2.6	0.0094	0.0098
I:1982(1)	-0.0208307	0.009253	-2.25	0.0247	0.0073
I:1982(2)	0.0353406	0.009298	3.8	0.0002	0.0206
I:1983(1)	0.0353803	0.009265	3.82	0.0001	0.0208
I:1983(9)	0.0234609	0.009285	2.53	0.0117	0.0092
I:1986(4)	0.0226793	0.009257	2.45	0.0145	0.0087
I:1989(4)	0.0222815	0.009264	2.41	0.0164	0.0084
I:1989(5)	-0.0237415	0.009294	-2.55	0.0109	0.0094
I:1991(4)	0.0289598	0.00927	3.12	0.0019	0.014
I:2001(4)	-0.0208326	0.009276	-2.25	0.025	0.0073
I:2008(9)	-0.0366088	0.00929	-3.94	0.0001	0.0221
I:2009(1)	-0.0249876	0.009282	-2.69	0.0073	0.0104
I:2009(7)	0.0319376	0.009352	3.41	0.0007	0.0167
sigma	0.0092012	RSS	0.0581628814		
log-likelihood	2485.01				
no. of observations	750	no. of parameters	63		
mean(DLIP)	0.00228601	se(DLIP)	0.027177		

Fonte: Elaboração própria

Tabela 57 – ESTIMAÇÃO: COVID-19 - EUA - Modelo 2

	Coeficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_1	0.144332	0.02323	6.21	0	0.0524
DLIP_5	0.0562868	0.01599	3.52	0.0005	0.0174
DLIP_10	-0.142091	0.016	-8.88	0	0.1014
DLIP_12	0.353971	0.02792	12.7	0	0.187
Constant	0.00407639	0.0007522	5.42	0	0.0403
DJIA_1	-0.0219931	0.004824	-4.56	0	0.0289
CSeasonal_1	0.016774	0.001593	10.5	0	0.137
CSeasonal_2	0.00870496	0.001542	5.64	0	0.0436
CSeasonal_5	0.0223585	0.001772	12.6	0	0.1854
CSeasonal_6	-0.0347523	0.00226	-15.4	0	0.2527
CSeasonal_7	0.0344534	0.002273	15.2	0	0.2473
CSeasonal_8	0.00564266	0.001727	3.27	0.0011	0.015
CSeasonal_10	-0.0101968	0.001568	-6.5	0	0.057
I:1956(8)	0.0593897	0.009861	6.02	0	0.0493
I:1957(9)	-0.0222781	0.009793	-2.27	0.0232	0.0073
I:1957(12)	-0.0300692	0.009774	-3.08	0.0022	0.0134
I:1958(2)	-0.0342167	0.009775	-3.5	0.0005	0.0172
I:1958(6)	0.0242365	0.009768	2.48	0.0133	0.0087
I:1958(11)	0.0343975	0.009796	3.51	0.0005	0.0173
I:1959(1)	0.0274426	0.009812	2.8	0.0053	0.0111
I:1959(4)	0.0322329	0.009761	3.3	0.001	0.0154
I:1959(7)	-0.0293987	0.00976	-3.01	0.0027	0.0128
I:1959(8)	-0.038262	0.009835	-3.89	0.0001	0.0212
I:1959(12)	0.0583451	0.009797	5.96	0	0.0483
I:1960(1)	0.0250555	0.009759	2.57	0.0105	0.0093
I:1960(2)	-0.0220028	0.009816	-2.24	0.0253	0.0071
I:1960(5)	-0.0200789	0.009808	-2.05	0.041	0.006
I:1960(6)	-0.0252444	0.009804	-2.57	0.0102	0.0094
I:1960(11)	-0.0203557	0.009784	-2.08	0.0378	0.0062
I:1960(12)	-0.0492867	0.009895	-4.98	0	0.0343
I:1961(4)	0.0340306	0.009715	3.5	0.0005	0.0173
I:1962(9)	0.0251523	0.009769	2.57	0.0102	0.0094
I:1963(9)	0.0233068	0.009796	2.38	0.0176	0.008
I:1964(10)	-0.0240293	0.009767	-2.46	0.0141	0.0086
I:1964(11)	0.0268622	0.009779	2.75	0.0062	0.0107
I:1966(9)	0.0291614	0.009777	2.98	0.003	0.0126
I:1967(8)	0.0245482	0.009782	2.51	0.0123	0.0089
I:1968(9)	0.0246874	0.009782	2.52	0.0118	0.009
I:1971(1)	0.0210332	0.009732	2.16	0.031	0.0066
I:1971(9)	0.0320905	0.009769	3.28	0.0011	0.0152
I:1972(1)	0.0348579	0.009763	3.57	0.0004	0.0179
I:1973(8)	-0.0222027	0.009765	-2.27	0.0233	0.0073
I:1974(11)	-0.0320777	0.009793	-3.28	0.0011	0.0151
I:1974(12)	-0.044922	0.0098	-4.58	0	0.0292
I:1975(4)	0.0226687	0.009722	2.33	0.02	0.0077
I:1979(4)	-0.0364698	0.009762	-3.74	0.0002	0.0196
I:1979(8)	-0.0246933	0.00977	-2.53	0.0117	0.0091
I:1980(5)	-0.0365561	0.009781	-3.74	0.0002	0.0196
I:1982(2)	0.0330253	0.009784	3.38	0.0008	0.016
I:1983(1)	0.0371244	0.009762	3.8	0.0002	0.0203
I:1983(9)	0.0234989	0.009766	2.41	0.0164	0.0082
sigma	0.00967456	RSS	0.0654243325		
R ²	0.881736	F(50,699) =	104.2 [0.000]**		
Adj.R ²	0.873276	log-likelihood	2440.9		
no. of observations	750	no. of parameters	51		
mean(DLIP)	0.00228601	se(DLIP)	0.027177		
AR 1-7 test:	F(7,692) =	2.3239 [0.0239]*			
ARCH 1-7 test:	F(7,736) =	1.2435 [0.2762]			
Normality test:	Chi ² (2) =	2.4995 [0.2866]			
Hetero test:	F(17,694) =	1.9474 [0.0123]*			
RESET23 test:	F(2,697) =	3.5146 [0.0303]*			

Fonte: Elaboração própria

Tabela 58 – ESTIMAÇÃO: COVID-19 - EUA - Modelo 3

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_3	0.080804	0.02916	2.77	0.0057	0.0109
DLIP_4	0.116087	0.02069	5.61	0	0.0434
DLIP_9	-0.0829648	0.02763	-3	0.0028	0.0128
DLIP_10	-0.138391	0.02724	-5.08	0	0.0358
DLIP_11	-0.103845	0.0294	-3.53	0.0004	0.0177
DLIP_12	0.306439	0.02853	10.7	0	0.1426
CSeasonal	0.00994185	0.002148	4.63	0	0.0299
CSeasonal_1	0.0268511	0.002428	11.1	0	0.1499
CSeasonal_2	0.0275299	0.002288	12	0	0.1726
CSeasonal_3	0.0128889	0.003087	4.18	0	0.0245
CSeasonal_4	0.0110712	0.002764	4.01	0.0001	0.0226
CSeasonal_5	0.025225	0.002764	9.13	0	0.1071
CSeasonal_6	-0.0230847	0.002889	-7.99	0	0.0842
CSeasonal_7	0.0347806	0.003272	10.6	0	0.14
CSeasonal_9	0.0100742	0.003048	3.31	0.001	0.0155
DLIP_5 ²	-1.18929	0.3809	-3.12	0.0019	0.0139
DLIP_1*DLIP_2	-3.60656	0.6135	-5.88	0	0.0474
DLIP_1*DLIP_3	-2.22684	0.7372	-3.02	0.0026	0.013
DLIP_1*DLIP_12	-2.31165	0.7304	-3.16	0.0016	0.0142
DLIP_2*DLIP_3	-2.95514	0.6046	-4.89	0	0.0333
DLIP_2*DLIP_4	-4.15025	0.7341	-5.65	0	0.044
DLIP_2*DLIP_5	-3.04692	0.8424	-3.62	0.0003	0.0185
DLIP_2*DLIP_6	-3.20173	0.8798	-3.64	0.0003	0.0187
DLIP_2*DLIP_9	2.80863	0.7869	3.57	0.0004	0.018
DLIP_2*DLIP_12	-2.58089	0.7178	-3.6	0.0003	0.0183
I:1956(8)	0.0504661	0.01013	4.98	0	0.0345
I:1957(4)	-0.0244675	0.009767	-2.51	0.0125	0.009
I:1957(12)	-0.0333575	0.009646	-3.46	0.0006	0.0169
I:1958(2)	-0.0384288	0.009895	-3.88	0.0001	0.0213
I:1958(5)	0.0215297	0.009755	2.21	0.0276	0.007
I:1958(6)	0.0327318	0.009707	3.37	0.0008	0.0161
I:1958(11)	0.0391927	0.009806	4	0.0001	0.0225
I:1959(1)	0.0267893	0.01	2.68	0.0076	0.0102
I:1959(4)	0.0384071	0.009678	3.97	0.0001	0.0222
I:1959(7)	-0.0233723	0.009639	-2.42	0.0156	0.0084
I:1959(8)	-0.0480902	0.01007	-4.78	0	0.0318
I:1959(12)	0.0687345	0.009785	7.02	0	0.0664
I:1960(1)	0.037094	0.009716	3.82	0.0001	0.0206
I:1960(4)	-0.0231824	0.00978	-2.37	0.018	0.008
I:1960(5)	-0.0219479	0.009665	-2.27	0.0235	0.0074
I:1960(6)	-0.0246411	0.009657	-2.55	0.0109	0.0093
I:1960(9)	0.0246905	0.01012	2.44	0.0149	0.0085
I:1960(12)	-0.0506697	0.009822	-5.16	0	0.0369
I:1961(4)	0.0304716	0.00963	3.16	0.0016	0.0142
I:1961(10)	0.023587	0.009767	2.42	0.016	0.0083
I:1962(9)	0.031003	0.009578	3.24	0.0013	0.0149
I:1970(10)	-0.0333666	0.009605	-3.47	0.0005	0.0171
I:1972(1)	0.0263058	0.009684	2.72	0.0068	0.0105
I:1974(11)	-0.0378318	0.009611	-3.94	0.0001	0.0218
I:1974(12)	-0.0500207	0.009673	-5.17	0	0.0371
I:1975(4)	0.0280807	0.00994	2.82	0.0049	0.0114
I:1979(4)	-0.0304601	0.009644	-3.16	0.0017	0.0142
I:1980(5)	-0.0461621	0.00965	-4.78	0	0.0319
I:1980(9)	0.0373523	0.009952	3.75	0.0002	0.0199
I:1982(2)	0.0374591	0.009614	3.9	0.0001	0.0214
I:1983(1)	0.0410573	0.009674	4.24	0	0.0253
sigma	0.00945969	RSS	0.0621030345		
log-likelihood	2460.43				
no. of observations	750	no. of parameters	56		
mean(DLIP)	0.00228601	se(DLIP)	0.027177		
AR 1-7 test:	F(7,687) =	2.4036 [0.0196]*			
ARCH 1-7 test:	F(7,736) =	1.8761 [0.0706]			
Normality test:	Chi ² (2) =	1.2364 [0.5389]			
Hetero test:	F(41,677) =	1.2543 [0.1366]			
RESET23 test:	F(2,692) =	2.0397 [0.1308]			

Fonte: Elaboração própria

Tabela 59 – ESTIMAÇÃO: COVID-19 - USA - Modelo 4

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_2	-0.116356	0.03009	-3.87	0.0001	0.0206
DLIP_10	-0.132839	0.01663	-7.99	0	0.0825
DLIP_12	0.332284	0.02905	11.4	0	0.1556
Constant	0.00369171	0.001025	3.6	0.0003	0.018
DJIA_1	-0.0201335	0.005014	-4.02	0.0001	0.0222
CSeasonal_1	0.0120609	0.002174	5.55	0	0.0415
CSeasonal_2	0.0117801	0.002068	5.7	0	0.0437
CSeasonal_5	0.0207303	0.001876	11	0	0.1467
CSeasonal_6	-0.0339315	0.002185	-15.5	0	0.2535
CSeasonal_7	3.09e-2	0.002143	14.4	0	0.2264
CSeasonal_10	-1.16e-2	0.001684	-6.89	0	0.0626
DLIP_2 ²	2.08e+0	0.4114	5.05	0	0.0347
DLIP_5 ²	-1.51786	0.4021	-3.77	0.0002	0.0197
DLIP_7 ²	1.71541	0.4818	3.56	0.0004	0.0175
DLIP_8 ²	-1.21641	0.4639	-2.62	0.0089	0.0096
DJ_1*DLIP_3	0.262002	0.1014	2.58	0.01	0.0093
DJ_2*DLIP_1	0.630542	0.1304	4.84	0	0.0319
DJ_2*DLIP_2	0.743251	0.1896	3.92	0.0001	0.0212
I:1956(8)	0.0549619	0.01	5.49	0	0.0408
I:1957(9)	-0.0271314	0.009996	-2.71	0.0068	0.0103
I:1957(12)	-0.02857	0.009983	-2.86	0.0043	0.0114
I:1958(2)	-0.0434775	0.01001	-4.34	0	0.0259
I:1958(11)	0.0384168	0.01001	3.84	0.0001	0.0203
I:1959(1)	0.0315894	0.01001	3.15	0.0017	0.0138
I:1959(4)	0.0352296	0.0101	3.49	0.0005	0.0168
I:1959(7)	-0.0282122	0.009964	-2.83	0.0048	0.0112
I:1959(8)	-0.0390316	0.01001	-3.9	0.0001	0.021
I:1959(12)	0.0612567	0.01014	6.04	0	0.0489
I:1960(1)	0.0256716	0.00995	2.58	0.0101	0.0093
I:1960(12)	-0.0493396	0.0101	-4.89	0	0.0325
I:1961(4)	0.0356255	0.0099	3.6	0.0003	0.0179
I:1964(11)	0.0256306	0.01003	2.56	0.0108	0.0091
I:1972(1)	0.0335431	0.009939	3.37	0.0008	0.0158
I:1974(11)	-0.0367038	0.01007	-3.65	0.0003	0.0184
I:1974(12)	-0.0440228	0.01013	-4.35	0	0.0259
I:1979(4)	-0.0374192	0.009968	-3.75	0.0002	0.0195
I:1980(5)	-0.0383593	0.009994	-3.84	0.0001	0.0203
I:1982(1)	-0.0262231	0.009945	-2.64	0.0086	0.0097
I:1982(2)	0.0282431	0.009986	2.83	0.0048	0.0111
I:1983(1)	0.0380101	0.01002	3.79	0.0002	0.0199
sigma	0.00987105	RSS	0.0691807701		
R ²	0.874945	F(39,710) =	127.4 [0.000]**		
Adj.R ²	0.868076	log-likelihood	2419.96		
no. of observations	750	no. of parameters	40		
mean(DLIP)	0.00228601	se(DLIP)	0.027177		
AR 1-7 test:	F(7,703) =	2.0197 [0.0503]			
ARCH 1-7 test:	F(7,736) =	1.2297 [0.2837]			
Normality test:	Chi ² (2) =	2.4807 [0.2893]			
Hetero test:	F(27,700) =	1.7615 [0.0103]*			
RESET23 test:	F(2,708) =	5.1677 [0.0059]**			

Fonte: Elaboração própria

Tabela 60 – ESTIMAÇÃO: COVID-19 - USA - Modelo 5

	Coeficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_1	0.0804297	0.0262	3.07	0.0022	0.0133
DLIP_10	-0.169011	0.01785	-9.47	0	0.1137
DLIP_12	0.336363	0.02674	12.6	0	0.1846
DJIA_1	-0.0230729	0.004705	-4.9	0	0.0333
CSeasonal_1	0.0131429	0.002162	6.08	0	0.0502
CSeasonal_2	0.0160699	0.002232	7.2	0	0.069
CSeasonal_3	0.00783977	0.002031	3.86	0.0001	0.0209
CSeasonal_5	0.0252041	0.001878	13.4	0	0.2049
CSeasonal_6	-0.0347482	0.002542	-13.7	0	0.2109
CSeasonal_7	3.16e-2	0.002959	10.7	0	0.1404
CSeasonal_10	-6.94e-3	0.001601	-4.34	0	0.0262
DLIP_7 ²	1.78e+0	0.46	3.87	0.0001	0.021
DLIP_8 ²	-1.5925	0.475	-3.35	0.0008	0.0158
DLIP_1*DLIP_2	-1.52321	0.5159	-2.95	0.0033	0.0123
DLIP_1*DLIP_12	-2.08125	0.7619	-2.73	0.0065	0.0106
DLIP_2*DLIP_3	-2.41543	0.5005	-4.83	0	0.0322
DLIP_2*DLIP_9	1.57046	0.6958	2.26	0.0243	0.0072
DLIP_2*DLIP_12	-3.09279	0.6955	-4.45	0	0.0275
I:1956(8)	0.048112	0.009952	4.83	0	0.0324
I:1957(9)	-0.02755	0.00968	-2.85	0.0046	0.0115
I:1957(12)	-0.0318406	0.0095	-3.35	0.0008	0.0158
I:1958(2)	-0.0380682	0.00961	-3.96	0.0001	0.022
I:1958(6)	0.0217432	0.009532	2.28	0.0228	0.0074
I:1958(8)	0.0278738	0.009758	2.86	0.0044	0.0115
I:1958(11)	0.0365501	0.009634	3.79	0.0002	0.0202
I:1959(1)	0.027891	0.009542	2.92	0.0036	0.0121
I:1959(4)	0.0372861	0.009687	3.85	0.0001	0.0208
I:1959(7)	-0.028645	0.009521	-3.01	0.0027	0.0128
I:1959(8)	-0.0467762	0.01	-4.68	0	0.0303
I:1959(12)	0.0557851	0.009504	5.87	0	0.047
I:1960(1)	0.0296502	0.009568	3.1	0.002	0.0136
I:1960(6)	-0.0251228	0.009547	-2.63	0.0087	0.0098
I:1960(11)	-0.0206488	0.009543	-2.16	0.0308	0.0067
I:1960(12)	-0.0554112	0.009648	-5.74	0	0.0451
I:1961(4)	0.0289563	0.009533	3.04	0.0025	0.013
I:1962(2)	0.0221211	0.009538	2.32	0.0207	0.0076
I:1962(9)	0.0243848	0.009499	2.57	0.0105	0.0093
I:1964(11)	0.0241013	0.009567	2.52	0.012	0.009
I:1970(10)	-0.0302238	0.009514	-3.18	0.0016	0.0142
I:1971(9)	0.0256706	0.009551	2.69	0.0074	0.0102
I:1972(1)	0.0342058	0.009522	3.59	0.0004	0.0181
I:1974(11)	-0.0338269	0.009552	-3.54	0.0004	0.0176
I:1974(12)	-0.046662	0.009648	-4.84	0	0.0324
I:1976(2)	0.0321731	0.009563	3.36	0.0008	0.0159
I:1979(4)	-0.0355634	0.009618	-3.7	0.0002	0.0192
I:1979(5)	0.0232721	0.009554	2.44	0.0151	0.0084
I:1980(5)	-0.0378929	0.009561	-3.96	0.0001	0.022
I:1982(2)	0.0343149	0.009563	3.59	0.0004	0.0181
I:1983(1)	0.0428667	0.009548	4.49	0	0.028
I:1983(9)	0.0256412	0.009468	2.71	0.0069	0.0104
Constant	0.00310336	0.0008999	3.45	0.0006	0.0167
sigma	0.00943366	RSS	0.0622067668		
R ²	0.887552	F(50,699) =	110.3 [0.000]**		
Adj.R ²	0.879509	log-likelihood	2459.81		
no. of observations	750	no. of parameters	51		
mean(DLIP)	0.00228601	se(DLIP)	0.027177		
AR 1-7 test:	F(7,692) =	2.3094 [0.0248]*			
ARCH 1-7 test:	F(7,736) =	0.89038 [0.5135]			
Normality test:	Chi ² (2) =	1.2928 [0.5239]			
Hetero test:	F(29,688) =	1.2802 [0.1498]			
RESET23 test:	F(2,697) =	1.3484 [0.2603]			

Fonte: Elaboração própria

Tabela 61 – ESTIMAÇÃO: COVID-19 - USA - Modelo 6

	Coefficiente	Std Error	t-value	t-prob	Part. R ²
DLIP_7	0.075733	0.0285	2.66	0.0081	0.0099
DLIP_10	-0.171506	0.01798	-9.54	0	0.114
DLIP_12	0.303025	0.02803	10.8	0	0.1419
DJIA_1	-0.0241163	0.004826	-5	0	0.0341
CSeasonal_1	0.0163657	0.003169	5.16	0	0.0363
CSeasonal_2	0.0117644	0.001746	6.74	0	0.0603
CSeasonal_3	0.00862983	0.001865	4.63	0	0.0294
CSeasonal_5	0.0291343	0.002179	13.4	0	0.2018
CSeasonal_6	-0.033415	0.002615	-12.8	0	0.1877
CSeasonal_7	2.92e-2	0.002878	10.2	0	0.1273
CSeasonal_10	-7.56e-3	0.001773	-4.27	0	0.0251
DLIP_7 ²	1.96e+0	0.4986	3.94	0.0001	0.0214
DJ_1*DLIP_5	0.395082	0.108	3.66	0.0003	0.0186
DLIP_1*DLIP_2	-1.94776	0.5271	-3.69	0.0002	0.0189
DLIP_1*DLIP_12	-1.9404	0.7785	-2.49	0.0129	0.0087
DLIP_2*DLIP_3	-2.5203	0.4618	-5.46	0	0.0404
DLIP_2*DLIP_6	-2.12562	0.7938	-2.68	0.0076	0.01
DLIP_2*DLIP_9	2.60876	0.7108	3.67	0.0003	0.0187
DLIP_2*DLIP_12	-2.64567	0.7233	-3.66	0.0003	0.0186
I:1956(8)	0.0452138	0.01024	4.41	0	0.0268
I:1957(3)	-0.0339808	0.0106	-3.21	0.0014	0.0143
I:1957(12)	-0.0286212	0.009862	-2.9	0.0038	0.0118
I:1958(2)	-0.0428838	0.01008	-4.26	0	0.025
I:1958(3)	-0.0224421	0.009921	-2.26	0.024	0.0072
I:1958(6)	0.0260682	0.009895	2.63	0.0086	0.0097
I:1958(8)	0.0254506	0.01005	2.53	0.0116	0.009
I:1958(11)	0.0402188	0.009928	4.05	0.0001	0.0227
I:1959(4)	0.0319641	0.00989	3.23	0.0013	0.0146
I:1959(7)	-0.0283604	0.009828	-2.89	0.004	0.0116
I:1959(8)	-0.0505724	0.01033	-4.89	0	0.0328
I:1959(12)	0.0555864	0.00981	5.67	0	0.0434
I:1960(1)	0.0365481	0.009907	3.69	0.0002	0.0189
I:1960(6)	-0.0275763	0.00985	-2.8	0.0053	0.011
I:1960(12)	-0.0535819	0.009959	-5.38	0	0.0393
I:1961(4)	0.0300216	0.00983	3.05	0.0023	0.013
I:1972(1)	0.0336931	0.009864	3.42	0.0007	0.0162
I:1974(11)	-0.033345	0.009876	-3.38	0.0008	0.0159
I:1974(12)	-0.0477893	0.009944	-4.81	0	0.0316
I:1979(4)	-0.0324946	0.009908	-3.28	0.0011	0.015
I:1980(5)	-0.0394092	0.009838	-4.01	0.0001	0.0222
I:1982(2)	0.0321094	0.009863	3.26	0.0012	0.0148
I:1983(1)	0.0403143	0.009882	4.08	0.0001	0.023
Constant	0.00215958	0.000873	2.47	0.0136	0.0086

sigma	0.00973208	RSS	0.0669624115
R ²	0.878955	F(42,707) =	122.2 [0.000]**
Adj.R ²	0.871765	log-likelihood	2432.18
no. of observations	750	no. of parameters	43
mean(DLIP)	0.00228601	se(DLIP)	0.027177
AR 1-7 test:	F(7,700) =	2.2135 [0.0314]*	
ARCH 1-7 test:	F(7,736) =	1.4822 [0.1702]	
Normality test:	Chi ² (2) =	1.2801 [0.5273]	
Hetero test:	F(30,696) =	1.1536 [0.2632]	
RESET23 test:	F(2,705) =	4.5478 [0.0109]*	

Fonte: Elaboração própria

Tabela 62 – PREVISÃO BRASIL - GFC MODELO 1: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	0.0347646	0.02732	0.0294887	-0.005276	-0.193	-0.01987	0.089399
2007(8)	0.0258044	0.02732	0.0498393	0.024035	0.88	-0.02883	0.080439
2007(9)	-0.0282144	0.02732	-0.0639667	-0.035752	-1.309	-0.082849	0.02642
2007(10)	0.0278182	0.02732	0.0912369	0.063419	2.322	-0.026817	0.082453
2007(11)	-0.053597	0.02732	-0.0513909	0.002206	0.081	-0.10823	0.0010379
2007(12)	-0.128504	0.02732	-0.100598	0.027906	1.022	-0.18314	-0.073869
2008(1)	-0.00142178	0.02732	0.0234803	0.024902	0.912	-0.056057	0.053213
2008(2)	-0.050679	0.02732	-0.0398116	0.010867	0.398	-0.10531	0.0039558
2008(3)	0.124492	0.02732	0.0699438	-0.054548	-1.997	0.069857	0.17913
2008(4)	-0.0180604	0.02732	0.0152365	0.033297	1.219	-0.072695	0.036574
2008(5)	0.0288348	0.02732	0.0327248	0.0038899	0.142	-0.0258	0.08347
2008(6)	0.000621972	0.02732	0.00777458	0.0071526	0.262	-0.054013	0.055257
2008(7)	0.0372368	0.02732	0.0491128	0.011876	0.435	-0.017398	0.091872
2008(8)	0.00403081	0.02732	-0.0148564	-0.018887	-0.691	-0.050604	0.058666
2008(9)	-0.00710822	0.02732	0.00373483	0.010843	0.397	-0.061743	0.047527
2008(10)	0.0303818	0.02732	0.0101994	-0.020182	-0.739	-0.024253	0.085017
2008(11)	-0.0583225	0.02732	-0.119399	-0.061076	-2.236	-0.11296	-0.0036876
2008(12)	-0.0843615	0.02732	-0.195716	-0.11135	-4.076	-0.139	-0.029727
2009(1)	0.00232868	0.02732	-0.00506972	-0.0073984	-0.271	-0.052306	0.056964
2009(2)	-0.0386385	0.02732	-0.0335949	0.0050436	0.185	-0.093273	0.015996
2009(3)	0.150523	0.02732	0.152084	0.001561	0.057	0.095888	0.20516
2009(4)	-0.0455857	0.02732	-0.0391304	0.0064553	0.236	-0.10022	0.0090491
2009(5)	0.0694869	0.02732	0.0691494 -	-0.0003375	-0.012	0.014852	0.12412
2009(6)	0.0103822	0.02732	0.00980934 -	-0.00057281	-0.021	-0.044253	0.065017
mean(Error) =		-0.0034138				RMSE =	0.034674
SD(Error) =		0.034506				MAPE =	70.403

Fonte: Elaboração própria

Tabela 63 – PREVISÃO BRASIL - GFC MODELO 2: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	0.0496131	0.02786	0.0294887	-0.020124	-0.722	-0.0060971	0.10532
2007(8)	0.0338806	0.02786	0.0498393	0.015959	0.573	-0.02183	0.089591
2007(9)	-0.0347876	0.02786	-0.0639667	-0.029179	-1.048	-0.090498	0.020923
2007(10)	0.0371428	0.02786	0.0912369	0.054094	1.942	-0.018567	0.092853
2007(11)	-0.0519838	0.02786	-0.0513909	0.00059289	0.021	-0.10769	0.0037263
2007(12)	-0.11286	0.02786	-0.100598	0.012262	0.44	-0.16857	-0.05715
2008(1)	-0.00505514	0.02786	0.0234803	0.028535	1.024	-0.060765	0.050655
2008(2)	-0.0503224	0.02786	-0.0398116	0.010511	0.377	-0.10603	0.0053877
2008(3)	0.133892	0.02786	0.0699438	-0.063949	-2.296	0.078182	0.1896
2008(4)	-0.0159876	0.02786	0.0152365	0.031224	1.121	-0.071698	0.039723
2008(5)	0.0434317	0.02786	0.0327248	-0.010707	-0.384	-0.012278	0.099142
2008(6)	0.00287451	0.02786	0.00777458	0.0049001	0.176	-0.052836	0.058585
2008(7)	0.0355461	0.02786	0.0491128	0.013567	0.487	-0.020164	0.091256
2008(8)	0.0219071	0.02786	-0.0148564	-0.036763	-1.32	-0.033803	0.077617
2008(9)	-0.0155851	0.02786	0.00373483	0.01932	0.694	-0.071295	0.040125
2008(10)	0.02878	0.02786	0.0101994	-0.018581	-0.667	-0.02693	0.08449
2008(11)	-0.0597202	0.02786	-0.119399	-0.059679	-2.142	-0.11543	-0.00401
2008(12)	-0.0833969	0.02786	-0.195716	-0.11232	-4.032	-0.13911	-0.027687
2009(1)	0.0188717	0.02786	-0.00506972	-0.023941	-0.859	-0.036839	0.074582
2009(2)	-0.0434975	0.02786	-0.0335949	0.0099026	0.356	-0.099208	0.012213
2009(3)	0.13209	0.02786	0.152084	0.019993	0.718	0.07638	0.1878
2009(4)	-0.0482434	0.02786	-0.0391304	0.009113	0.327	-0.10395	0.0074668
2009(5)	0.0693862	0.02786	0.0691494 -	-0.00023685	-0.009	0.013676	0.1251
2009(6)	0.00683565	0.02786	0.00980934	0.0029737	0.107	-0.048874	0.062546
mean(Error) =		-0.0059388				RMSE =	0.035538
SD(Error) =		0.035038				MAPE =	100.39

Fonte: Elaboração própria

Tabela 64 – PREVISÃO BRASIL - GFC MODELO 3: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	0.039835	0.02864	0.0294887	-0.010346	-0.361	-0.017446	0.097116
2007(8)	0.0285193	0.02864	0.0498393	0.02132	0.744	-0.028762	0.0858
2007(9)	-0.0340448	0.02864	-0.0639667	-0.029922	-1.045	-0.091326	0.023236
2007(10)	0.0360754	0.02864	0.0912369	0.055161	1.926	-0.021206	0.093356
2007(11)	-0.0602572	0.02864	-0.0513909	0.0088663	0.31	-0.11754	-0.0029762
2007(12)	-0.108734	0.02864	-0.100598	0.0081365	0.284	-0.16602	-0.051453
2008(1)	-0.00653865	0.02864	0.0234803	0.030019	1.048	-0.06382	0.050742
2008(2)	-0.0456349	0.02864	-0.0398116	0.0058233	0.203	-0.10292	0.011646
2008(3)	0.129656	0.02864	0.0699438	-0.059712	-2.085	0.072375	0.18694
2008(4)	-0.0191296	0.02864	0.0152365	0.034366	1.2	-0.076411	0.038151
2008(5)	0.0450586	0.02864	0.0327248	-0.012334	-0.431	-0.012223	0.10234
2008(6)	-0.01165	0.02864	0.00777458	0.019425	0.678	-0.068931	0.045631
2008(7)	0.0306893	0.02864	0.0491128	0.018423	0.643	-0.026592	0.08797
2008(8)	0.0117649	0.02864	-0.0148564	-0.026621	-0.929	-0.045516	0.069046
2008(9)	-0.019105	0.02864	0.00373483	0.02284	0.797	-0.076386	0.038176
2008(10)	0.0383678	0.02864	0.0101994	-0.028168	-0.984	-0.018913	0.095649
2008(11)	-0.0426504	0.02864	-0.119399	-0.076748	-2.68	-0.099931	0.014631
2008(12)	-0.0833639	0.02864	-0.195716	-0.11235	-3.923	-0.14064	-0.026083
2009(1)	0.0284813	0.02864	-0.00506972	-0.033551	-1.171	-0.0288	0.085762
2009(2)	-0.038608	0.02864	-0.0335949	0.0050132	0.175	-0.095889	0.018673
2009(3)	0.1417	0.02864	0.152084	0.010384	0.363	0.084419	0.19898
2009(4)	-0.0433462	0.02864	-0.0391304	0.0042158	0.147	-0.10063	0.013935
2009(5)	0.0634104	0.02864	0.0691494	0.0057389	0.2	0.0061294	0.12069
2009(6)	0.0205736	0.02864	0.00980934	-0.010764	-0.376	-0.036707	0.077855
mean(Error) =		-0.0062828				RMSE =	0.037169
SD(Error) =		0.036634				MAPE =	124.58

Fonte: Elaboração própria

Tabela 65 – PREVISÃO BRASIL - GFC MODELO 4: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	0.0374075	0.02752	0.0294887	-0.0079188	-0.288	-0.017625	0.09244
2007(8)	0.0260601	0.02752	0.0498393	0.023779	0.864	-0.028973	0.081093
2007(9)	-0.0314872	0.02752	-0.0639667	-0.032479	-1.18	-0.08652	0.023546
2007(10)	0.0239498	0.02752	0.0912369	0.067287	2.445	-0.031083	0.078983
2007(11)	-0.0482334	0.02752	-0.0513909	-0.0031575	-0.115	-0.10327	0.0067995
2007(12)	-0.120277	0.02752	-0.100598	0.019679	0.715	-0.17531	-0.065244
2008(1)	-0.00367878	0.02752	0.0234803	0.027159	0.987	-0.058712	0.051354
2008(2)	-0.0528527	0.02752	-0.0398116	0.013041	0.474	-0.10789	0.0021801
2008(3)	0.119909	0.02752	0.0699438	-0.049966	-1.816	0.064877	0.17494
2008(4)	-0.0157579	0.02752	0.0152365	0.030994	1.126	-0.070791	0.039275
2008(5)	0.0381848	0.02752	0.0327248	-0.0054601	-0.198	-0.016848	0.093218
2008(6)	-0.0081083	0.02752	0.00777458	0.015883	0.577	-0.063141	0.046925
2008(7)	0.0328421	0.02752	0.0491128	0.016271	0.591	-0.022191	0.087875
2008(8)	0.0120886	0.02752	-0.0148564	-0.026945	-0.979	-0.042944	0.067121
2008(9)	-0.0145175	0.02752	0.00373483	0.018252	0.663	-0.06955	0.040515
2008(10)	0.0473054	0.02752	0.0101994	-0.037106	-1.349	-0.0077274	0.10234
2008(11)	-0.0666577	0.02752	-0.119399	-0.052741	-1.917	-0.12169	-0.011625
2008(12)	-0.0885206	0.02752	-0.195716	-0.1072	-3.896	-0.14355	-0.033488
2009(1)	0.0251994	0.02752	-0.00506972	-0.030269	-1.1	-0.029833	0.080232
2009(2)	-0.0439596	0.02752	-0.0335949	0.010365	0.377	-0.098993	0.011073
2009(3)	0.12185	0.02752	0.152084	0.030234	1.099	0.066817	0.17688
2009(4)	-0.0488337	0.02752	-0.0391304	0.0097033	0.353	-0.10387	0.0061991
2009(5)	0.0609807	0.02752	0.0691494	0.0081686	0.297	0.0059479	0.11601
2009(6)	0.00753106	0.02752	0.00980934	0.0022783	0.083	-0.047502	0.062564
mean(Error) =		-0.002506				RMSE =	0.03555
SD(Error) =		0.035462				MAPE =	114.28

Fonte: Elaboração própria

Tabela 66 – PREVISÃO BRASIL - GFC MODELO 5: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	0.034939	0.02865	0.0294887	-0.0054503	-0.19	-0.022356	0.092234
2007(8)	0.0456175	0.02865	0.0498393	0.0042218	0.147	-0.011677	0.10291
2007(9)	-0.0522841	0.02865	-0.0639667	-0.011683	-0.408	-0.10958	0.0050108
2007(10)	0.032835	0.02865	0.0912369	0.058402	2.039	-0.02446	0.09013
2007(11)	-0.0474473	0.02865	-0.0513909	-0.0039436	-0.138	-0.10474	0.0098476
2007(12)	-0.115428	0.02865	-0.100598	0.01483	0.518	-0.17272	-0.058133
2008(1)	0.0213132	0.02865	0.0234803	0.002167	0.076	-0.035982	0.078608
2008(2)	-0.0480215	0.02865	-0.0398116	0.0082099	0.287	-0.10532	0.0092735
2008(3)	0.119453	0.02865	0.0699438	-0.049509	-1.728	0.062158	0.17675
2008(4)	-0.0204576	0.02865	0.0152365	0.035694	1.246	-0.077753	0.036837
2008(5)	0.0361673	0.02865	0.0327248	-0.0034425	-0.12	-0.021128	0.093462
2008(6)	-0.0281931	0.02865	0.00777458	0.035968	1.256	-0.085488	0.029102
2008(7)	0.0466059	0.02865	0.0491128	0.0025069	0.088	-0.010689	0.1039
2008(8)	0.00764001	0.02865	-0.0148564	-0.022496	-0.785	-0.049655	0.064935
2008(9)	-0.0102343	0.02865	0.00373483	0.013969	0.488	-0.067529	0.047061
2008(10)	0.0486954	0.02865	0.0101994	-0.038496	-1.344	-0.0085995	0.10599
2008(11)	-0.0711408	0.02865	-0.119399	-0.048258	-1.685	-0.12844	-0.013846
2008(12)	-0.0965697	0.02865	-0.195716	-0.099147	-3.461	-0.15386	-0.039275
2009(1)	0.0141944	0.02865	-0.00506972	-0.019264	-0.672	-0.043101	0.071489
2009(2)	0.0164559	0.02865	-0.0335949	-0.050051	-1.747	-0.040839	0.073751
2009(3)	0.125263	0.02865	0.152084	0.026821	0.936	0.067968	0.18256
2009(4)	-0.0268237	0.02865	-0.0391304	-0.012307	-0.43	-0.084119	0.030471
2009(5)	0.0809619	0.02865	0.0691494	-0.011813	-0.412	0.023667	0.13826
2009(6)	0.00915091	0.02865	0.00980934	0.00065844	0.023	-0.048144	0.066446
	mean(Error) =	-0.0071838				RMSE =	0.033646
	SD(Error) =	0.03287				MAPE =	105.86

Fonte: Elaboração própria

Tabela 67 – PREVISÃO BRASIL - GFC MODELO 6: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	0.0403327	0.02859	0.0294887	-0.010844	-0.379	-0.016853	0.097518
2007(8)	0.0431652	0.02859	0.0498393	0.0066741	0.233	-0.01402	0.10035
2007(9)	-0.0525322	0.02859	-0.0639667	-0.011434	-0.4	-0.10972	0.004653
2007(10)	0.0439031	0.02859	0.0912369	0.047334	1.655	-0.013282	0.10109
2007(11)	-0.0635889	0.02859	-0.0513909	0.012198	0.427	-0.12077	-0.0064037
2007(12)	-0.109046	0.02859	-0.100598	0.0084488	0.295	-0.16623	-0.051861
2008(1)	0.00972266	0.02859	0.0234803	0.013758	0.481	-0.047463	0.066908
2008(2)	-0.0510012	0.02859	-0.0398116	0.01119	0.391	-0.10819	0.006184
2008(3)	0.132421	0.02859	0.0699438	-0.062477	-2.185	0.075236	0.18961
2008(4)	-0.0432186	0.02859	0.0152365	0.058455	2.044	-0.1004	0.013967
2008(5)	0.034026	0.02859	0.0327248	-0.0013013	-0.046	-0.023159	0.091211
2008(6)	-0.0176085	0.02859	0.00777458	0.025383	0.888	-0.074794	0.039577
2008(7)	0.0453384	0.02859	0.0491128	0.0037743	0.132	-0.011847	0.10252
2008(8)	0.00964065	0.02859	-0.0148564	-0.024497	-0.857	-0.047545	0.066826
2008(9)	0.00354224	0.02859	0.00373483	0.00019259	0.007	-0.053643	0.060727
2008(10)	0.0335862	0.02859	0.0101994	-0.023387	-0.818	-0.023599	0.090771
2008(11)	-0.0779849	0.02859	-0.119399	-0.041414	-1.448	-0.13517	-0.0208
2008(12)	-0.100593	0.02859	-0.195716	-0.095123	-3.327	-0.15778	-0.043408
2009(1)	0.0329204	0.02859	-0.00506972	-0.03799	-1.329	-0.024265	0.090106
2009(2)	-0.00881167	0.02859	-0.0335949	-0.024783	-0.867	-0.065997	0.048374
2009(3)	0.123759	0.02859	0.152084	0.028325	0.991	0.066574	0.18094
2009(4)	-0.0351813	0.02859	-0.0391304	-0.0039491	-0.138	-0.092367	0.022004
2009(5)	0.0582081	0.02859	0.0691494	0.010941	0.383	0.0010229	0.11539
2009(6)	0.00669687	0.02859	0.00980934	0.0031125	0.109	-0.050488	0.063882
	mean(Error) =	-0.0044756				RMSE =	0.032891
	SD(Error) =	0.032585				MAPE =	101.33

Fonte: Elaboração própria

Tabela 68 – PREVISÃO BRASIL - DILMA MODELO 1: 08/2013-07/2015

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2013(8)	0.000424594	0.02971	0.0363676	0.036792	1.238	-0.05984	0.05899
2013(9)	-0.0272497	0.02971	-0.0428702	-0.01562	-0.526	-0.086665	0.032165
2013(10)	0.0469766	0.02971	0.0482131	0.0012364	0.042	-0.012438	0.10639
2013(11)	-0.0710419	0.02971	-0.0594597	0.011582	0.39	-0.13046	-0.011627
2013(12)	-0.104338	0.02971	-0.163462	-0.059123	-1.99	-0.16375	-0.044924
2014(1)	0.00776096	0.02971	0.027369	0.019608	0.66	-0.051654	0.067176
2014(2)	-0.0517207	0.02971	-0.003245	0.048476	1.632	-0.11114	0.0076943
2014(3)	0.112538	0.02971	0.0527548	-0.059784	-2.012	0.053124	0.17195
2014(4)	-0.00697686	0.02971	-0.0134508	-0.0064739	-0.218	-0.066392	0.052438
2014(5)	0.0507735	0.02971	0.0576791	0.0069056	0.232	-0.0086415	0.11019
2014(6)	-0.0158324	0.02971	-0.0692036	-0.053371	-1.797	-0.075247	0.043583
2014(7)	0.0782536	0.02971	0.095406	0.017152	0.577	0.018839	0.13767
2014(8)	0.00422747	0.02971	0.0180356	0.013808	0.465	-0.055187	0.063642
2014(9)	-0.0365708	0.02971	-0.00660691	0.029964	1.009	-0.095986	0.022844
2014(10)	0.0525824	0.02971	0.034438	-0.018144	-0.611	-0.0068325	0.112
2014(11)	-0.0542811	0.02971	-0.0909282	-0.036647	-1.234	-0.1137	0.0051339
2014(12)	-0.10453	0.02971	-0.129246	-0.024716	-0.832	-0.16395	-0.045115
2015(1)	0.00507065	0.02971	0.00455063	-0.00052001	-0.018	-0.054344	0.064486
2015(2)	-0.0571531	0.02971	-0.0512336	0.0059196	0.199	-0.11657	0.0022618
2015(3)	0.136206	0.02971	0.119242	-0.016964	-0.571	0.076791	0.19562
2015(4)	-0.0347653	0.02971	-0.0600945	-0.025329	-0.853	-0.09418	0.02465
2015(5)	0.0656156	0.02971	0.0472875	-0.018328	-0.617	0.0062007	0.12503
2015(6)	0.00494731	0.02971	-0.00646554	-0.011413	-0.384	-0.054468	0.064362
2015(7)	0.0491689	0.02971	0.0319176	-0.017251	-0.581	-0.010246	0.10858
mean(Error) =		-0.0071767				RMSE =	0.028773
SD(Error) =		0.027864				MAPE =	125.86

Fonte: Elaboração própria

Tabela 69 – PREVISÃO BRASIL - DILMA MODELO 2: 08/2013-07/2015

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2013(8)	0.00808805	0.02668	0.0363676	0.02828	1.06	-0.045276	0.061452
2013(9)	-0.0198414	0.02668	-0.0428702	-0.023029	-0.863	-0.073205	0.033523
2013(10)	0.054977	0.02668	0.0482131	-0.0067639	-0.254	0.0016131	0.10834
2013(11)	-0.0581035	0.02668	-0.0594597	-0.0013561	-0.051	-0.11147	-0.0047396
2013(12)	-0.107391	0.02668	-0.163462	-0.056071	-2.101	-0.16075	-0.054027
2014(1)	0.0297383	0.02668	0.027369	-0.0023693	-0.089	-0.023626	0.083102
2014(2)	-0.0367146	0.02668	-0.003245	0.03347	1.254	-0.090079	0.016649
2014(3)	0.105316	0.02668	0.0527548	-0.052561	-1.97	0.051952	0.15868
2014(4)	0.00208147	0.02668	-0.0134508	-0.015532	-0.582	-0.051282	0.055445
2014(5)	0.0659529	0.02668	0.0576791	-0.0082738	-0.31	0.012589	0.11932
2014(6)	-0.00754278	0.02668	-0.0692036	-0.061661	-2.311	-0.060907	0.045821
2014(7)	0.0956145	0.02668	0.0954060	-0.00020857	-0.008	0.042251	0.14898
2014(8)	0.01481	0.02668	0.0180356	0.0032256	0.121	-0.038554	0.068174
2014(9)	-0.0369759	0.02668	-0.00660691	0.030369	1.138	-0.09034	0.016388
2014(10)	0.0511373	0.02668	0.034438	-0.016699	-0.626	-0.0022267	0.1045
2014(11)	-0.0510152	0.02668	-0.0909282	-0.039913	-1.496	-0.10438	0.0023488
2014(12)	-0.0918387	0.02668	-0.129246	-0.037408	-1.402	-0.1452	-0.038475
2015(1)	0.0158424	0.02668	0.00455063	-0.011292	-0.423	-0.037522	0.069206
2015(2)	-0.037267	0.02668	-0.0512336	-0.013967	-0.523	-0.090631	0.016097
2015(3)	0.132264	0.02668	0.119242	-0.013022	-0.488	0.0789	0.18563
2015(4)	-0.0291633	0.02668	-0.0600945	-0.030931	-1.159	-0.082527	0.024201
2015(5)	0.076669	0.02668	0.0472875	-0.029381	-1.101	0.023305	0.13003
2015(6)	0.019725	0.02668	-0.00646554	-0.026191	-0.982	-0.033639	0.073089
2015(7)	0.0591558	0.02668	0.0319176	-0.027238	-1.021	0.0057919	0.11252
mean(Error) =		-0.015772				RMSE =	0.029202
SD(Error) =		0.024576				MAPE =	126.26

Fonte: Elaboração própria

Tabela 70 – PREVISÃO BRASIL - DILMA MODELO 3: 08/2013-07/2015

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2013(8)	0.00435307	0.0279	0.0363676	0.032015	1.147	-0.051455	0.060161
2013(9)	-0.019248	0.0279	-0.0428702	-0.023622	-0.847	-0.075056	0.03656
2013(10)	0.0591279	0.0279	0.0482131	-0.010915	-0.391	0.0033199	0.11494
2013(11)	-0.0658055	0.0279	-0.0594597	0.0063459	0.227	-0.12161	-0.0099975
2013(12)	-0.110149	0.0279	-0.163462	-0.053313	-1.911	-0.16596	-0.054341
2014(1)	-0.00172266	0.0279	0.027369	0.029092	1.043	-0.057531	0.054085
2014(2)	-0.00813921	0.0279	-0.003245	0.0048942	0.175	-0.063947	0.047669
2014(3)	0.0952827	0.0279	0.0527548	-0.042528	-1.524	0.039475	0.15109
2014(4)	-0.0108073	0.0279	-0.0134508	-0.0026435	-0.095	-0.066615	0.045001
2014(5)	0.0472734	0.0279	0.0576791	0.010406	0.373	-0.0085346	0.10308
2014(6)	-0.0363998	0.0279	-0.0692036	-0.032804	-1.176	-0.092208	0.019408
2014(7)	0.0744423	0.0279	0.095406	0.020964	0.751	0.018634	0.13025
2014(8)	0.0112107	0.0279	0.0180356	0.0068249	0.245	-0.044597	0.067019
2014(9)	-0.0252254	0.0279	-0.00660691	0.018618	0.667	-0.081033	0.030583
2014(10)	0.0682985	0.0279	0.034438	-0.03386	-1.213	0.01249	0.12411
2014(11)	-0.0564311	0.0279	-0.0909282	-0.034497	-1.236	-0.11224	-0.00062307
2014(12)	-0.128714	0.0279	-0.129246	-0.00053191	-0.019	-0.18452	-0.072906
2015(1)	0.0253541	0.0279	0.00455063	-0.020803	-0.746	-0.030454	0.081162
2015(2)	-0.0443359	0.0279	-0.0512336	-0.0068977	-0.247	-0.10014	0.011472
2015(3)	0.122273	0.0279	0.119242	-0.0030304	-0.109	0.066465	0.17808
2015(4)	-0.0213324	0.0279	-0.0600945	-0.038762	-1.389	-0.077141	0.034476
2015(5)	0.0516714	0.0279	0.0472875	-0.0043839	-0.157	-0.0041366	0.10748
2015(6)	0.0147755	0.0279	-0.00646554	-0.021241	-0.761	-0.041033	0.070584
2015(7)	0.0484924	0.0279	0.0319176	-0.016575	-0.594	-0.0073157	0.1043
mean(Error) =		-0.009052				RMSE =	0.024462
SD(Error) =		0.022726				MAPE =	84.899

Fonte: Elaboração própria

Tabela 71 – PREVISÃO BRASIL - DILMA MODELO 4: 08/2013-07/2015

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2013(8)	-0.00306582	0.02569	0.0363676	0.039433	1.535	-0.054451	0.04832
2013(9)	-0.0334598	0.02569	-0.0428702	-0.0094105	-0.366	-0.084845	0.017926
2013(10)	0.0578243	0.02569	0.0482131	-0.0096113	-0.374	0.0064387	0.10921
2013(11)	-0.0621457	0.02569	-0.0594597	0.002686	0.105	-0.11353	-0.01076
2013(12)	-0.101837	0.02569	-0.163462	-0.061625	-2.399	-0.15322	-0.050452
2014(1)	0.0247014	0.02569	0.027369	0.0026675	0.104	-0.026684	0.076087
2014(2)	-0.0327264	0.02569	-0.003245	0.029481	1.147	-0.084112	0.018659
2014(3)	0.104937	0.02569	0.0527548	-0.052182	-2.031	0.053551	0.15632
2014(4)	0.0052752	0.02569	-0.0134508	-0.018726	-0.729	-0.04611	0.056661
2014(5)	0.0414824	0.02569	0.0576791	0.016197	0.63	-0.0099033	0.092868
2014(6)	-0.0413337	0.02569	-0.0692036	-0.02787	-1.085	-0.092719	0.010052
2014(7)	0.0672036	0.02569	0.095406	0.028202	1.098	0.015818	0.11859
2014(8)	0.000853322	0.02569	0.0180356	0.017182	0.669	-0.050532	0.052239
2014(9)	-0.0366834	0.02569	-0.00660691	0.030076	1.171	-0.088069	0.014702
2014(10)	0.0580272	0.02569	0.034438	-0.023589	-0.918	0.0066416	0.10941
2014(11)	-0.05923	0.02569	-0.0909282	-0.031698	-1.234	-0.11062	-0.0078444
2014(12)	-0.106966	0.02569	-0.129246	-0.02228	-0.867	-0.15835	-0.05558
2015(1)	0.00666566	0.02569	0.00455063	-0.002115	-0.082	-0.04472	0.058051
2015(2)	-0.0380615	0.02569	-0.0512336	-0.013172	-0.513	-0.089447	0.013324
2015(3)	0.1189	0.02569	0.119242	0.00034208	0.013	0.067514	0.17029
2015(4)	-0.0193405	0.02569	-0.0600945	-0.040754	-1.586	-0.070726	0.032045
2015(5)	0.0612667	0.02569	0.0472875	-0.013979	-0.544	0.0098811	0.11265
2015(6)	-0.00846013	0.02569	-0.00646554	0.0019946	0.078	-0.059846	0.042926
2015(7)	0.0302749	0.02569	0.0319176	0.0016427	0.064	-0.021111	0.081661
mean(Error) =		-0.0065461				RMSE =	0.026318
SD(Error) =		0.025491				MAPE =	96.824

Fonte: Elaboração própria

Tabela 72 – PREVISÃO BRASIL - DILMA MODELO 5: 08/2013-07/2015

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2013(8)	0.00435383	0.02569	0.0363676	0.032014	1.246	-0.04702	0.055727
2013(9)	-0.0120589	0.02569	-0.0428702	-0.030811	-1.2	-0.063432	0.039315
2013(10)	0.0585699	0.02569	0.0482131	-0.010357	-0.403	0.0071964	0.10994
2013(11)	-0.0596297	0.02569	-0.0594597	0.00016998	0.007	-0.111	-0.0082562
2013(12)	-0.11143	0.02569	-0.163462	-0.052032	-2.026	-0.1628	-0.060056
2014(1)	0.0115135	0.02569	0.027369	0.015855	0.617	-0.03986	0.062887
2014(2)	-0.00355482	0.02569	-0.003245	0.00030982	0.012	-0.054928	0.047819
2014(3)	0.0961547	0.02569	0.0527548	-0.0434	-1.69	0.044781	0.14753
2014(4)	-0.0151244	0.02569	-0.0134508	0.0016736	0.065	-0.066498	0.036249
2014(5)	0.0432817	0.02569	0.0576791	0.014397	0.56	-0.0080918	0.094655
2014(6)	-0.018782	0.02569	-0.0692036	-0.050422	-1.963	-0.070155	0.032592
2014(7)	0.0767826	0.02569	0.095406	0.018623	0.725	0.025409	0.12816
2014(8)	0.0042588	0.02569	0.0180356	0.013777	0.536	-0.047115	0.055632
2014(9)	-0.00804123	0.02569	-0.00660691	0.0014343	0.056	-0.059415	0.043332
2014(10)	0.0655805	0.02569	0.034438	-0.031142	-1.212	0.014207	0.11695
2014(11)	-0.0567749	0.02569	-0.0909282	-0.034153	-1.33	-0.10815	-0.0054014
2014(12)	-0.130345	0.02569	-0.129246	0.0010983	0.043	-0.18172	-0.078971
2015(1)	0.0153794	0.02569	0.00455063	-0.010829	-0.422	-0.035994	0.066753
2015(2)	-0.0459299	0.02569	-0.0512336	-0.0053037	-0.206	-0.097303	0.0054436
2015(3)	0.140939	0.02569	0.119242	-0.021697	-0.845	0.089566	0.19231
2015(4)	-0.0181434	0.02569	-0.0600945	-0.041951	-1.633	-0.069517	0.03323
2015(5)	0.0483654	0.02569	0.0472875	-0.0010779	-0.042	-0.0030081	0.099739
2015(6)	0.0155846	0.02569	-0.00646554	-0.02205	-0.858	-0.035789	0.066958
2015(7)	0.0366803	0.02569	0.0319176	-0.0047627	-0.185	-0.014693	0.088054
mean(Error) =		-0.01086				RMSE =	0.025198
SD(Error) =		0.022738				MAPE =	58.939

Fonte: Elaboração própria

Tabela 73 – PREVISÃO BRASIL - DILMA MODELO 6: 08/2013-07/2015

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2013(8)	0.0143685	0.02622	0.0363676	0.021999	0.839	-0.038069	0.066806
2013(9)	-0.0288538	0.02622	-0.0428702	-0.014016	-0.535	-0.081291	0.023583
2013(10)	0.0642509	0.02622	0.0482131	-0.016038	-0.612	0.011814	0.11669
2013(11)	-0.0612321	0.02622	-0.0594597	0.0017724	0.068	-0.11367	-0.0087948
2013(12)	-0.102278	0.02622	-0.163462	-0.061184	-2.334	-0.15471	-0.04984
2014(1)	-0.00713881	0.02622	0.027369	0.034508	1.316	-0.059576	0.045298
2014(2)	-0.0182656	0.02622	-0.003245	0.015021	0.573	-0.070703	0.034172
2014(3)	0.106473	0.02622	0.0527548	-0.053718	-2.049	0.054036	0.15891
2014(4)	0.0110241	0.02622	-0.0134508	-0.024475	-0.933	-0.041413	0.063461
2014(5)	0.0392443	0.02622	0.0576791	0.018435	0.703	-0.013193	0.091682
2014(6)	-0.0298645	0.02622	-0.0692036	-0.039339	-1.5	-0.082302	0.022573
2014(7)	0.0680584	0.02622	0.095406	0.027348	1.043	0.015621	0.1205
2014(8)	0.00952336	0.02622	0.0180356	0.0085122	0.325	-0.042914	0.061961
2014(9)	-0.0210548	0.02622	-0.00660691	0.014448	0.551	-0.073492	0.031382
2014(10)	0.0640064	0.02622	0.034438	-0.029568	-1.128	0.011569	0.11644
2014(11)	-0.0249539	0.02622	-0.0909282	-0.065974	-2.516	-0.077391	0.027483
2014(12)	-0.110184	0.02622	-0.129246	-0.019063	-0.727	-0.16262	-0.057746
2015(1)	0.00486942	0.02622	0.00455063	-0.00031879	-0.012	-0.047568	0.057307
2015(2)	-0.04039	0.02622	-0.0512336	-0.010844	-0.414	-0.092827	0.012047
2015(3)	0.120162	0.02622	0.119242	-0.00092002	-0.035	0.067725	0.1726
2015(4)	-0.0136246	0.02622	-0.0600945	-0.04647	-1.772	-0.066062	0.038813
2015(5)	0.0493865	0.02622	0.0472875	-0.002099	-0.08	-0.0030508	0.10182
2015(6)	0.00744385	0.02622	-0.00646554	-0.013909	-0.531	-0.044993	0.059881
2015(7)	0.0477738	0.02622	0.0319176	-0.015856	-0.605	-0.0046635	0.10021
mean(Error) =		-0.011323				RMSE =	0.029453
SD(Error) =		0.027189				MAPE =	82.152

Fonte: Elaboração própria

Tabela 74 – PREVISÃO BRASIL - COVID-19 MODELO 1: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	-0.0614522	0.02874	-0.0200257	0.041426	1.441	-0.11894	-0.0039632
2019(3)	0.112802	0.02874	0.0237363	-0.089066	-3.099	0.055313	0.17029
2019(4)	0.01079	0.02874	0.0279994	0.017209	0.599	-0.046699	0.068279
2019(5)	0.0441033	0.02874	0.088411	0.044308	1.541	-0.013386	0.10159
2019(6)	-0.0336752	0.02874	-0.0588405	-0.025165	-0.875	-0.091164	0.023814
2019(7)	0.0754021	0.02874	0.0848723	0.0094702	0.329	0.017913	0.13289
2019(8)	0.0126538	0.02874	0.029538	0.016884	0.587	-0.044835	0.070143
2019(9)	-0.0467568	0.02874	-0.0468171	-6.03e-5	-0.002	-0.10425	0.010732
2019(10)	0.0589854	0.02874	0.0550987	-0.0038867	-0.135	0.0014964	0.11647
2019(11)	-0.0577085	0.02874	-0.0973742	-0.039666	-1.38	-0.1152	-0.00021958
2019(12)	-0.116484	0.02874	-0.134831	-0.018347	-0.638	-0.17397	-0.058995
2020(1)	0.0099511	0.02874	0.0395208	0.02957	1.029	-0.047538	0.06744
2020(2)	-0.0583657	0.02874	-0.0138454	0.04452	1.549	-0.11585	-0.00087677
2020(3)	0.106251	0.02874	-0.0127553	-0.11901	-4.14	0.048762	0.16374
2020(4)	0.0165081	0.02874	-0.256094	-0.2726	-9.484	-0.040981	0.073997
2020(5)	0.129708	0.02874	0.164755	0.035047	1.219	0.072219	0.1872
2020(6)	-0.0586503	0.02874	0.0964603	0.15511	5.396	-0.11614	-0.0011613
2020(7)	-0.0211699	0.02874	0.150312	0.17148	5.966	-0.078659	0.036319
2020(8)	0.00468002	0.02874	0.0313709	0.026691	0.929	-0.052809	0.062169
2020(9)	-0.0211307	0.02874	0.0147994	0.03593	1.25	-0.07862	0.036358
2020(10)	0.0576086	0.02874	0.0207692	-0.036839	-1.282	0.00011964	0.1151
2020(11)	0.0105448	0.02874	-0.0746615	-0.085206	-2.964	-0.046944	0.068034
2020(12)	-0.091937	0.02874	-0.0806889	0.011248	0.391	-0.14943	-0.034448
2021(1)	-0.0512847	0.02874	-0.0206193	0.030665	1.067	-0.10877	0.0062043
mean(Error) =		0.00084516				RMSE =	0.084792
SD(Error) =		0.084788				MAPE =	140.85

Fonte: Elaboração própria

Tabela 75 – PREVISÃO BRASIL - COVID-19 MODELO 2: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	-0.0484225	0.02712	-0.0200257	0.028397	1.047	-0.10267	0.0058254
2019(3)	0.116336	0.02712	0.0237363	-0.0926	-3.414	0.062088	0.17058
2019(4)	0.0137103	0.02712	0.0279994	0.014289	0.527	-0.040538	0.067958
2019(5)	0.0360297	0.02712	0.088411	0.052381	1.931	-0.018218	0.090278
2019(6)	-0.0316024	0.02712	-0.0588405	-0.027238	-1.004	-0.08585	0.022646
2019(7)	0.0799155	0.02712	0.0848723	0.0049568	0.183	0.025668	0.13416
2019(8)	0.0154735	0.02712	0.029538	0.014064	0.519	-0.038774	0.069721
2019(9)	-0.0426882	0.02712	-0.0468171	-4.13e-3	-0.152	-0.096936	0.01156
2019(10)	0.0643701	0.02712	0.0550987	-0.0092714	-0.342	0.010122	0.11862
2019(11)	-0.0617836	0.02712	-0.0973742	-0.035591	-1.312	-0.11603	-0.0075357
2019(12)	-0.0958589	0.02712	-0.134831	-0.038972	-1.437	-0.15011	-0.041611
2020(1)	0.0150814	0.02712	0.0395208	0.024439	0.901	-0.039167	0.069329
2020(2)	-0.0614278	0.02712	-0.0138454	0.047582	1.754	-0.11568	-0.0071798
2020(3)	0.111824	0.02712	-0.0127553	-0.12458	-4.593	0.057576	0.16607
2020(4)	0.00419593	0.02712	-0.256094	-0.26029	-9.596	-0.050052	0.058444
2020(5)	0.128121	0.02712	0.164755	0.036634	1.351	0.073874	0.18237
2020(6)	-0.063028	0.02712	0.0964603	0.15949	5.88	-0.11728	-0.0087801
2020(7)	-0.0318959	0.02712	0.150312	0.18221	6.718	-0.086144	0.022352
2020(8)	0.0061149	0.02712	0.0313709	0.025256	0.931	-0.048133	0.060363
2020(9)	-0.0126402	0.02712	0.0147994	0.02744	1.012	-0.066888	0.041608
2020(10)	0.0591547	0.02712	0.0207692	-0.038386	-1.415	0.0049068	0.1134
2020(11)	-0.0125438	0.02712	-0.0746615	-0.062118	-2.29	-0.066792	0.041704
2020(12)	-0.103232	0.02712	-0.0806889	0.022543	0.831	-0.15748	-0.048984
2021(1)	-0.0323415	0.02712	-0.0206193	0.011722	0.432	-0.086589	0.021906
mean(Error) =		-0.0017405				RMSE =	0.084079
SD(Error) =		0.084061				MAPE =	135.18

Fonte: Elaboração própria

Tabela 76 – PREVISÃO BRASIL - COVID-19 MODELO 3: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	-0.0467331	0.02844	-0.0200257	0.026707	0.939	-0.10362	0.010152
2019(3)	0.126777	0.02844	0.0237363	-0.10304	-3.623	0.069891	0.18366
2019(4)	0.0210995	0.02844	0.0279994	0.0068999	0.243	-0.035786	0.077985
2019(5)	0.0361218	0.02844	0.088411	0.052289	1.838	-0.020763	0.093007
2019(6)	-0.0689574	0.02844	-0.0588405	0.010117	0.356	-0.12584	-0.012072
2019(7)	0.0788462	0.02844	0.0848723	0.0060261	0.212	0.021961	0.13573
2019(8)	0.0343794	0.02844	0.029538	-0.0048414	-0.17	-0.022506	0.091265
2019(9)	-0.035588	0.02844	-0.0468171	-1.12e-2	-0.395	-0.092473	0.021297
2019(10)	0.0568756	0.02844	0.0550987	-0.0017769	-0.062	-9.69e-6	0.11376
2019(11)	-0.0632288	0.02844	-0.0973742	-0.034145	-1.2	-0.12011	-0.0063435
2019(12)	-0.129719	0.02844	-0.134831	-0.0051119	-0.18	-0.1866	-0.072834
2020(1)	0.0107208	0.02844	0.0395208	0.0288	1.013	-0.046165	0.067606
2020(2)	-0.0301337	0.02844	-0.0138454	0.016288	0.573	-0.087019	0.026752
2020(3)	0.0900763	0.02844	-0.0127553	-0.10283	-3.615	0.033191	0.14696
2020(4)	0.0252483	0.02844	-0.256094	-0.28134	-9.892	-0.031637	0.082134
2020(5)	0.0722198	0.02844	0.164755	0.092535	3.253	0.015334	0.12911
2020(6)	0.0373425	0.02844	0.0964603	0.059118	2.078	-0.019543	0.094228
2020(7)	-0.00343566	0.02844	0.150312	0.15375	5.406	-0.060321	0.05345
2020(8)	-0.0223347	0.02844	0.0313709	0.053706	1.888	-0.07922	0.034551
2020(9)	0.0256558	0.02844	0.0147994	-0.010856	-0.382	-0.03123	0.082541
2020(10)	0.0853496	0.02844	0.0207692	-0.06458	-2.271	0.028464	0.14223
2020(11)	-0.0445694	0.02844	-0.0746615	-0.030092	-1.058	-0.10145	0.012316
2020(12)	-0.179122	0.02844	-0.0806889	0.098433	3.461	-0.23601	-0.12224
2021(1)	-0.0697904	0.02844	-0.0206193	0.049171	1.729	-0.12668	-0.012905
mean(Error) =		0.00016626				RMSE =	0.082234
SD(Error) =		0.082234				MAPE =	126.69

Fonte: Elaboração própria

Tabela 77 – PREVISÃO BRASIL - COVID-19 MODELO 4: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	-0.0408411	0.02768	-0.0200257	0.020815	0.752	-0.096203	0.014521
2019(3)	0.105444	0.02768	0.0237363	-0.081708	-2.952	0.050082	0.16081
2019(4)	0.0206423	0.02768	0.0279994	0.0073571	0.266	-0.034719	0.076004
2019(5)	0.0310344	0.02768	0.088411	0.057377	2.073	-0.024327	0.086396
2019(6)	-0.0516363	0.02768	-0.0588405	-0.0072042	-0.26	-0.107	0.0037254
2019(7)	0.0773502	0.02768	0.0848723	0.0075222	0.272	0.021988	0.13271
2019(8)	0.0286993	0.02768	0.029538	0.00083875	0.03	-0.026662	0.084061
2019(9)	-0.048846	0.02768	-0.0468171	2.03e-3	0.073	-0.10421	0.0065156
2019(10)	0.0717956	0.02768	0.0550987	-0.016697	-0.603	1.64e-2	0.12716
2019(11)	-0.0430209	0.02768	-0.0973742	-0.054353	-1.964	-0.098383	0.012341
2019(12)	-0.103591	0.02768	-0.134831	-0.03124	-1.129	-0.15895	-0.04823
2020(1)	0.0272167	0.02768	0.0395208	0.012304	0.444	-0.028145	0.082578
2020(2)	-0.059965	0.02768	-0.0138454	0.04612	1.666	-0.11533	-0.0046033
2020(3)	0.107915	0.02768	-0.0127553	-0.12067	-4.359	0.052553	0.16328
2020(4)	-0.00890753	0.02768	-0.256094	-0.24719	-8.93	-0.064269	0.046454
2020(5)	0.119872	0.02768	0.164755	0.044883	1.621	0.064511	0.17523
2020(6)	0.0116833	0.02768	0.0964603	0.084777	3.063	-0.043678	0.067045
2020(7)	-0.00629824	0.02768	0.150312	0.15661	5.658	-0.06166	0.049063
2020(8)	0.00901014	0.02768	0.0313709	0.022361	0.808	-0.046352	0.064372
2020(9)	-0.00152304	0.02768	0.0147994	0.016322	0.59	-0.056885	0.053839
2020(10)	0.0196528	0.02768	0.0207692	0.0011164	0.04	-0.035709	0.075014
2020(11)	-0.00785541	0.02768	-0.0746615	-0.066806	-2.413	-0.063217	0.047506
2020(12)	-0.09116	0.02768	-0.0806889	0.010471	0.378	-0.14652	-0.035798
2021(1)	0.00594358	0.02768	-0.0206193	-0.026563	-0.96	-0.049418	0.061305
mean(Error) =		-0.0067302				RMSE =	0.0743
SD(Error) =		0.073995				MAPE =	113.39

Fonte: Elaboração própria

Tabela 78 – PREVISÃO BRASIL - COVID-19 MODELO 5: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	-0.0351213	0.02764	-0.0200257	0.015096	0.546	-0.090398	0.020155
2019(3)	0.102257	0.02764	0.0237363	-0.078521	-2.841	0.046981	0.15753
2019(4)	0.0033636	0.02764	0.0279994	0.024636	0.891	-0.051913	0.05864
2019(5)	0.0464754	0.02764	0.088411	0.041936	1.517	-0.0088013	0.10175
2019(6)	-0.0657303	0.02764	-0.0588405	0.0068898	0.249	-0.12101	-0.010454
2019(7)	0.0914141	0.02764	0.0848723	-0.0065417	-0.237	0.036137	0.14669
2019(8)	0.0151722	0.02764	0.029538	0.014366	0.52	-0.040104	0.070449
2019(9)	-0.0520935	0.02764	-0.0468171	5.28e-3	0.191	-0.10737	0.0031832
2019(10)	0.0675591	0.02764	0.0550987	-0.01246	-0.451	1.23e-2	0.12284
2019(11)	-0.0486959	0.02764	-0.0973742	-0.048678	-1.761	-0.10397	0.0065807
2019(12)	-0.122812	0.02764	-0.134831	-0.012019	-0.435	-0.17809	-0.067535
2020(1)	0.0161199	0.02764	0.0395208	0.023401	0.847	-0.039157	0.071397
2020(2)	-0.0209248	0.02764	-0.0138454	0.0070794	0.256	-0.076201	0.034352
2020(3)	0.0933811	0.02764	-0.0127553	-0.10614	-3.84	0.038104	0.14866
2020(4)	-0.0079267	0.02764	-0.256094	-0.24817	-8.979	-0.063203	0.04735
2020(5)	0.179699	0.02764	0.164755	-0.014943	-0.541	0.12442	0.23498
2020(6)	0.0879289	0.02764	0.0964603	0.0085314	0.309	0.032652	0.14321
2020(7)	0.045346	0.02764	0.150312	0.10497	3.798	-0.0099306	0.10062
2020(8)	-0.0223292	0.02764	0.0313709	0.0537	1.943	-0.077606	0.032947
2020(9)	-0.0154774	0.02764	0.0147994	0.030277	1.095	-0.070754	0.039799
2020(10)	0.00997504	0.02764	0.0207692	0.010794	0.391	-0.045302	0.065252
2020(11)	-0.0168133	0.02764	-0.0746615	-0.057848	-2.093	-0.07209	0.038463
2020(12)	-0.104737	0.02764	-0.0806889	0.024048	0.87	-0.16001	-0.049461
2021(1)	-0.0202368	0.02764	-0.0206193	-0.00038245	-0.014	-0.075514	0.03504
mean(Error) =		-0.0089459				RMSE =	0.065941
SD(Error) =		0.065332				MAPE =	98.6

Fonte: Elaboração própria

Tabela 79 – PREVISÃO BRASIL - COVID-19 MODELO 6: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	-0.0470266	0.02659	-0.0200257	0.027001	1.016	-0.1002	0.0061496
2019(3)	0.111863	0.02659	0.0237363	-0.088127	-3.315	0.058687	0.16504
2019(4)	0.00442927	0.02659	0.0279994	0.02357	0.886	-0.048747	0.057605
2019(5)	0.0311719	0.02659	0.088411	0.057239	2.153	-0.022004	0.084348
2019(6)	-0.0547615	0.02659	-0.0588405	-0.004079	-0.153	-0.10794	-0.0015854
2019(7)	0.0928793	0.02659	0.0848723	-0.008007	-0.301	0.039703	0.14606
2019(8)	0.0113938	0.02659	0.029538	0.018144	0.682	-0.041782	0.06457
2019(9)	-0.044543	0.02659	-0.0468171	-2.27e-3	-0.086	-0.097719	0.0086332
2019(10)	0.0724447	0.02659	0.0550987	-0.017346	-0.652	1.93e-2	0.12562
2019(11)	-0.0462944	0.02659	-0.0973742	-0.05108	-1.921	-0.099471	0.0068818
2019(12)	-0.112256	0.02659	-0.134831	-0.022575	-0.849	-0.16543	-0.05908
2020(1)	0.00329585	0.02659	0.0395208	0.036225	1.362	-0.04988	0.056472
2020(2)	-0.0269542	0.02659	-0.0138454	0.013109	0.493	-0.08013	0.026222
2020(3)	0.0924936	0.02659	-0.0127553	-0.10525	-3.958	0.039317	0.14567
2020(4)	0.0338575	0.02659	-0.256094	-0.28995	-10.905	-0.019319	0.087034
2020(5)	0.19239	0.02659	0.164755	-0.027635	-1.039	0.13921	0.24557
2020(6)	0.013977	0.02659	0.0964603	0.082483	3.102	-0.039199	0.067153
2020(7)	0.0401524	0.02659	0.150312	0.11016	4.143	-0.013024	0.093329
2020(8)	-0.0178944	0.02659	0.0313709	0.049265	1.853	-0.071071	0.035282
2020(9)	-0.0315396	0.02659	0.0147994	0.046339	1.743	-0.084716	0.021637
2020(10)	0.0315945	0.02659	0.0207692	-0.010825	-0.407	-0.021582	0.084771
2020(11)	-0.00476636	0.02659	-0.0746615	-0.069895	-2.629	-0.057943	0.04841
2020(12)	-0.0974039	0.02659	-0.0806889	0.016715	0.629	-0.15058	-0.044228
2021(1)	-0.0418424	0.02659	-0.0206193	0.021223	0.798	-0.095019	0.011334
mean(Error) =		-0.0081488				RMSE =	0.077137
SD(Error) =		0.076706				MAPE =	119.92

Fonte: Elaboração própria

Tabela 80 – PREVISÃO EUA - GFC MODELO 1: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	-0.0580821	0.009723	-0.045835	0.012247	1.26	-0.077528	-0.038636
2007(8)	0.041901	0.009723	0.0347536	-0.0071474	-0.735	0.022455	0.061347
2007(9)	0.0197826	0.009723	0.00893331	-0.010849	-1.116	0.00033653	0.039229
2007(10)	2.73e-3	0.009723	-0.0104704	-0.0132	-1.358	-0.016717	0.022175
2007(11)	-0.0159794	0.009723	-0.0085411	0.0074383	0.765	-0.035425	0.0034666
2007(12)	-0.0138303	0.009723	-0.0152217	-1.39e-3	-0.143	-0.033276	0.0056157
2008(1)	-0.0114056	0.009723	-0.0164074	-0.0050017	-0.514	-0.030852	0.0080404
2008(2)	0.023266	0.009723	0.004927	-1.83e-2	-1.886	0.00382	0.042712
2008(3)	0.0158707	0.009723	0.0115801	-0.0042906	-0.441	-3.58e-3	0.035317
2008(4)	-0.00314155	0.009723	-0.00945369	-0.0063121	-0.649	-0.022588	0.016304
2008(5)	0.00845721	0.009723	-0.00531467	-0.013772	-1.416	-0.010989	0.027903
2008(6)	0.0236822	0.009723	0.0186405	-0.0050417	-0.519	0.0042361	0.043128
2008(7)	-0.057878	0.009723	-0.0506682	0.0072098	0.742	-0.077324	-0.038432
2008(8)	0.038274	0.009723	0.0182044	-0.02007	-2.064	0.018828	0.05772
2008(9)	0.0198983	0.009723	-0.0295126	-0.049411	-5.082	4.52e-4	0.039344
2008(10)	0.00141334	0.009723	-0.0148392	-0.016252	-1.672	-0.018033	0.020859
2008(11)	-0.0152746	0.009723	-0.0369499	-0.021675	-2.229	-0.034721	0.0041715
2008(12)	-0.0176154	0.009723	-0.0464962	-0.028881	-2.97	-0.037061	0.0018306
2009(1)	-0.0118993	0.009723	-0.046288	-3.44e-2	-3.537	-0.031345	0.0075467
2009(2)	0.0167	0.009723	0.00838186	-0.0083181	-0.856	-0.0027461	0.036146
2009(3)	0.0115662	0.009723	-0.00130827	-1.29e-2	-1.324	-0.0078799	0.031012
2009(4)	-0.00697866	0.009723	-0.0200064	-0.013028	-1.34	-0.026425	0.012467
2009(5)	0.00241706	0.009723	0.00321694	0.00079988	0.082	-0.017029	0.021863
2009(6)	0.0189339	0.009723	0.0190671	1.33e-4	0.014	-0.00051213	0.03838
mean(Error) =		-0.010934				RMSE =	0.017365
SD(Error) =		0.013491				MAPE =	123.09

Fonte: Elaboração própria

Tabela 81 – PREVISÃO EUA - GFC MODELO 2: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	-0.055907	0.01002	-0.045835	0.010072	1.005	-0.075945	-0.035869
2007(8)	0.040019	0.01002	0.0347536	-0.0052654	-0.526	0.019981	0.060057
2007(9)	0.0182948	0.01002	0.00893331	-0.0093615	-0.934	-0.0017433	0.038333
2007(10)	0.00166232	0.01002	-0.0104704	-0.012133	-1.211	-0.018376	0.0217
2007(11)	-0.0160863	0.01002	-0.0085411	0.0075452	0.753	-0.036124	0.0039518
2007(12)	-0.0162452	0.01002	-0.0152217	0.0010235	0.102	-0.036283	0.0037929
2008(1)	-0.0133212	0.01002	-0.0164074	-0.0030861	-0.308	-0.033359	0.0067169
2008(2)	0.0236496	0.01002	0.004927	-1.87e-2	-1.869	0.0036115	0.043688
2008(3)	0.0177452	0.01002	0.0115801	-0.0061652	-0.615	-2.29e-3	0.037783
2008(4)	-0.00563473	0.01002	-0.00945369	-0.003819	-0.381	-0.025673	0.014403
2008(5)	0.00646298	0.01002	-0.00531467	-0.011778	-1.176	-0.013575	0.026501
2008(6)	0.0239896	0.01002	0.0186405	-0.0053491	-0.534	0.0039515	0.044028
2008(7)	-0.0561185	0.01002	-0.0506682	0.0054502	0.544	-0.076157	-0.03608
2008(8)	0.0375357	0.01002	0.0182044	-0.019331	-1.929	0.017498	0.057574
2008(9)	0.0201241	0.01002	-0.0295126	-0.049637	-4.954	8.59e-5	0.040162
2008(10)	-0.00394691	0.01002	-0.0148392	-0.010892	-1.087	-0.023985	0.016091
2008(11)	-0.0247569	0.01002	-0.0369499	-0.012193	-1.217	-0.044795	-0.0047188
2008(12)	-0.0263899	0.01002	-0.0464962	-0.020106	-2.007	-0.046428	-0.0063518
2009(1)	-0.0168088	0.01002	-0.046288	-0.029479	-2.942	-0.036847	0.0032293
2009(2)	0.0201857	0.01002	0.00838186	-0.011804	-1.178	0.00014755	0.040224
2009(3)	0.0145147	0.01002	-0.00130827	-0.015823	-1.579	-0.0055234	0.034553
2009(4)	-0.0102324	0.01002	-0.0200064	-0.0097739	-0.976	-0.030271	0.0098057
2009(5)	0.00360857	0.01002	0.00321694	-0.00039163	-0.039	-0.01643	0.023647
2009(6)	0.0225577	0.01002	0.0190671	-0.0034906	-0.348	0.0025196	0.042596
mean(Error) =		-0.0097712				RMSE =	0.015689
SD(Error) =		0.012274				MAPE =	125.99

Fonte: Elaboração própria

Tabela 82 – PREVISÃO EUA - GFC MODELO 3: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	-0.05416	0.01005	-0.045835	0.0083249	0.828	-0.074259	-0.034061
2007(8)	0.0437504	0.01005	0.0347536	-0.0089968	-0.895	0.023651	0.06385
2007(9)	0.0151099	0.01005	0.00893331	-0.0061766	-0.615	-0.0049892	0.035209
2007(10)	4.96e-5	0.01005	-0.0104704	-0.01052	-1.047	-0.02005	0.020149
2007(11)	-0.0187681	0.01005	-0.0085411	0.010227	1.018	-0.038867	0.001331
2007(12)	-0.00796204	0.01005	-0.0152217	-0.0072597	-0.722	-0.028061	0.012137
2008(1)	-0.0130715	0.01005	-0.0164074	-0.0033358	-0.332	-0.033171	0.0070276
2008(2)	0.0182556	0.01005	0.004927	-1.33e-2	-1.326	-0.0018436	0.038355
2008(3)	0.0135869	0.01005	0.0115801	-0.0020068	-0.2	-6.51e-3	0.033686
2008(4)	-0.00709523	0.01005	-0.00945369	-0.0023585	-0.235	-0.027194	0.013004
2008(5)	0.00274083	0.01005	-0.00531467	-0.0080555	-0.802	-0.017358	0.02284
2008(6)	0.0258961	0.01005	0.0186405	-0.0072556	-0.722	0.0057969	0.045995
2008(7)	-0.0584538	0.01005	-0.0506682	0.0077856	0.775	-0.078553	-0.038355
2008(8)	0.0452605	0.01005	0.0182044	-0.027056	-2.692	0.025161	0.06536
2008(9)	0.00821382	0.01005	-0.0295126	-0.037726	-3.754	-1.19e-2	0.028313
2008(10)	-0.00693283	0.01005	-0.0148392	-0.0079063	-0.787	-0.027032	0.013166
2008(11)	-0.0187273	0.01005	-0.0369499	-0.018223	-1.813	-0.038826	0.0013719
2008(12)	-0.0199799	0.01005	-0.0464962	-0.026516	-2.639	-0.040079	0.00011925
2009(1)	-0.0179108	0.01005	-0.046288	-0.028377	-2.824	-0.03801	0.0021883
2009(2)	0.0096561	0.01005	0.00838186	-0.0012742	-0.127	-0.010443	0.029755
2009(3)	0.000929355	0.01005	-0.00130827 -	-0.00037892	-0.038	-0.021028	0.01917
2009(4)	-0.0113602	0.01005	-0.0200064	-0.0086462	-0.86	-0.031459	0.0087389
2009(5)	-0.00201316	0.01005	0.00321694	0.0052301	0.52	-0.022112	0.018086
2009(6)	0.0233672	0.01005	0.0190671	-0.0043001	-0.428	0.0032681	0.043466
mean(Error) =		-0.0082554				RMSE =	0.014453
SD(Error) =		0.011864				MAPE =	70.416

Fonte: Elaboração própria

Tabela 83 – PREVISÃO EUA - GFC MODELO 4: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	-0.0555348	0.01002	-0.045835	0.0096997	0.968	-0.075567	-0.035503
2007(8)	0.0447885	0.01002	0.0347536	-0.010035	-1.002	0.024756	0.064821
2007(9)	0.0183954	0.01002	0.00893331	-0.0094621	-0.945	-0.0016367	0.038428
2007(10)	2.40e-4	0.01002	-0.0104704	-0.010231	-1.021	-0.020272	0.019792
2007(11)	-0.0156942	0.01002	-0.0085411	0.0071531	0.714	-0.035726	0.004338
2007(12)	-0.0156477	0.01002	-0.0152217	0.000426	0.043	-0.03568	0.0043844
2008(1)	-0.0138461	0.01002	-0.0164074	-0.0025612	-0.256	-0.033878	0.006186
2008(2)	0.0196143	0.01002	0.004927	-1.47e-2	-1.466	-0.00041779	0.039646
2008(3)	0.0119239	0.01002	0.0115801 -	-0.00034378	-0.034	-8.11e-3	0.031956
2008(4)	-0.00984969	0.01002	-0.00945369	0.00039599	0.04	-0.029882	0.010182
2008(5)	0.00342004	0.01002	-0.00531467	-0.0087347	-0.872	-0.016612	0.023452
2008(6)	0.0228792	0.01002	0.0186405	-0.0042387	-0.423	0.002847	0.042911
2008(7)	-0.0569118	0.01002	-0.0506682	0.0062435	0.623	-0.076944	-0.03688
2008(8)	0.0373816	0.01002	0.0182044	-0.019177	-1.915	0.017349	0.057414
2008(9)	0.0140716	0.01002	-0.0295126	-0.043584	-4.351	-5.96e-3	0.034104
2008(10)	-0.014625	0.01002	-0.0148392 -	-0.00021413	-0.021	-0.034657	0.0054071
2008(11)	-0.0348716	0.01002	-0.0369499	-0.0020783	-0.207	-0.054904	-0.014839
2008(12)	-0.0595668	0.01002	-0.0464962	0.013071	1.305	-0.079599	-0.039535
2009(1)	-0.0429057	0.01002	-0.046288	-0.0033823	-0.338	-0.062938	-0.022874
2009(2)	-0.0116797	0.01002	0.00838186	0.020062	2.003	-0.031712	0.0083525
2009(3)	-0.00130418	0.01002	-0.00130827 -	-4.09e-6	0	-0.021336	0.018728
2009(4)	-0.0227631	0.01002	-0.0200064	0.0027567	0.275	-0.042795	-0.0027309
2009(5)	-0.0132062	0.01002	0.00321694	0.016423	1.64	-0.033238	0.006826
2009(6)	0.0139409	0.01002	0.0190671	0.0051263	0.512	-0.0060913	0.033973
mean(Error) =		-0.001974				RMSE =	0.012839
SD(Error) =		0.012686				MAPE =	81.118

Fonte: Elaboração própria

Tabela 84 – PREVISÃO EUA - GFC MODELO 5: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	-0.056538	0.009802	-0.045835	0.010703	1.092	-0.076143	-0.036933
2007(8)	0.0433551	0.009802	0.0347536	-0.0086015	-0.877	0.02375	0.06296
2007(9)	0.0152175	0.009802	0.00893331	-0.0062842	-0.641	-0.0043872	0.034822
2007(10)	5.29e-4	0.009802	-0.0104704	-0.0099415	-1.014	-0.020134	0.019076
2007(11)	-0.0176886	0.009802	-0.0085411	0.0091475	0.933	-0.037293	0.0019162
2007(12)	-0.010012	0.009802	-0.0152217	-0.0052097	-0.531	-0.029617	0.0095928
2008(1)	-0.0106979	0.009802	-0.0164074	-0.0057095	-0.582	-0.030303	0.0089069
2008(2)	0.0155606	0.009802	0.004927	-1.06e-2	-1.085	-0.0040442	0.035165
2008(3)	0.013086	0.009802	0.0115801	-0.0015059	-0.154	-6.52e-3	0.032691
2008(4)	-0.00541639	0.009802	-0.00945369	-0.0040373	-0.412	-0.025021	0.014188
2008(5)	0.00563601	0.009802	-0.00531467	-0.010951	-1.117	-0.013969	0.025241
2008(6)	0.0239018	0.009802	0.0186405	-0.0052613	-0.537	0.004297	0.043507
2008(7)	-0.0604718	0.009802	-0.0506682	0.0098036	1.000	-0.080077	-0.040867
2008(8)	0.0420175	0.009802	0.0182044	-0.023813	-2.429	0.022413	0.061622
2008(9)	0.00923605	0.009802	-0.0295126	-0.038749	-3.953	-1.04e-2	0.028841
2008(10)	-0.00891201	0.009802	-0.0148392	-0.0059271	-0.605	-0.028517	0.010693
2008(11)	-0.0284546	0.009802	-0.0369499	-0.0084953	-0.867	-0.048059	-0.0088498
2008(12)	-0.0263948	0.009802	-0.0464962	-0.020101	-2.051	-0.046	-0.00679
2009(1)	-0.0222362	0.009802	-0.046288	-0.024052	-2.454	-0.041841	-0.0026314
2009(2)	0.00296929	0.009802	0.00838186	0.0054126	0.552	-0.016635	0.022574
2009(3)	0.00162472	0.009802	-0.00130827	-2.93e-3	-0.299	-0.01798	0.02123
2009(4)	-0.0117535	0.009802	-0.0200064	-0.0082529	-0.842	-0.031358	0.0078513
2009(5)	-0.00419185	0.009802	0.00321694	0.0074088	0.756	-0.023797	0.015413
2009(6)	0.0190229	0.009802	0.0190671	4.42e-5	0.005	-0.00058185	0.038628
mean(Error) =		-0.0065808				RMSE =	0.013173
SD(Error) =		0.011412				MAPE =	78.977

Fonte: Elaboração própria

Tabela 85 – PREVISÃO EUA - GFC MODELO 6: 07/2007-06/2009

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2007(7)	-0.0555243	0.01006	-0.045835	0.0096892	0.963	-0.075649	-0.0354
2007(8)	0.0426228	0.01006	0.0347536	-0.0078692	-0.782	0.022498	0.062747
2007(9)	0.0162384	0.01006	0.00893331	-0.007305	-0.726	-0.003886	0.036363
2007(10)	1.43e-3	0.01006	-0.0104704	-0.011905	-1.183	-0.01869	0.021558
2007(11)	-0.017053	0.01006	-0.0085411	0.0085119	0.846	-0.037177	0.0030713
2007(12)	-0.0152934	0.01006	-0.0152217	7.17e-5	0.007	-0.035418	0.004831
2008(1)	-0.0145607	0.01006	-0.0164074	-0.0018467	-0.184	-0.034685	0.0055636
2008(2)	0.0199938	0.01006	0.004927	-1.51e-2	-1.497	-0.00013053	0.040118
2008(3)	0.013221	0.01006	0.0115801	-0.0016409	-0.163	-6.90e-3	0.033345
2008(4)	-0.00917797	0.01006	-0.00945369	-0.00027572	-0.027	-0.029302	0.010946
2008(5)	0.00381043	0.01006	-0.00531467	-0.0091251	-0.907	-0.016314	0.023935
2008(6)	0.0239343	0.01006	0.0186405	-0.0052938	-0.526	0.00381	0.044059
2008(7)	-0.0596365	0.01006	-0.0506682	0.0089682	0.891	-0.079761	-0.039512
2008(8)	0.036167	0.01006	0.0182044	-0.017963	-1.785	0.016043	0.056291
2008(9)	0.0123258	0.01006	-0.0295126	-0.041838	-4.158	-7.80e-3	0.03245
2008(10)	-0.014062	0.01006	-0.0148392	-0.00077716	-0.077	-0.034186	0.0060623
2008(11)	-0.037141	0.01006	-0.0369499	0.00019111	0.019	-0.057265	-0.017017
2008(12)	-0.0611337	0.01006	-0.0464962	0.014638	1.455	-0.081258	-0.041009
2009(1)	-0.0462365	0.01006	-0.0462880	-5.16e-5	-0.005	-0.066361	-0.026112
2009(2)	-0.0121563	0.01006	0.00838186	0.020538	2.041	-0.032281	0.0079681
2009(3)	0.000103534	0.01006	-0.00130827	-1.41e-3	-0.14	-0.020021	0.020228
2009(4)	-0.0219314	0.01006	-0.0200064	0.0019251	0.191	-0.042056	-0.0018071
2009(5)	-0.0130644	0.01006	0.00321694	0.016281	1.618	-0.033189	0.0070599
2009(6)	0.0148769	0.01006	0.0190671	4.19e-3	0.416	-0.0052475	0.035001
mean(Error) =		-0.0015569				RMSE =	0.01266
SD(Error) =		0.012564				MAPE =	85.823

Fonte: Elaboração própria

Tabela 86 – PREVISÃO EUA - COVID-19 MODELO 1: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	0.0195087	0.009201	0.0105162	-0.0089924	-0.977	0.0011063	0.037911
2019(3)	0.0123183	0.009201	0.0122040 -	-0.00011421	-0.012	-0.0060842	0.030721
2019(4)	-0.00545567	0.009201	-0.0103306	-0.0048749	-0.53	-0.023858	0.012947
2019(5)	-1.66e-3	0.009201	0.00109755	0.0027548	0.299	-0.02006	0.016745
2019(6)	0.0226624	0.009201	0.0243103	0.0016478	0.179	0.00426	0.041065
2019(7)	-0.0464011	0.009201	-0.0393196	7.08e-3	0.77	-0.064803	-0.027999
2019(8)	0.0366242	0.009201	0.0362168 -	-0.00040739	-0.044	0.018222	0.055027
2019(9)	0.00651156	0.009201	-0.0108504	-1.74e-2	-1.887	-0.011891	0.024914
2019(10)	-0.00324197	0.009201	-0.00440337	-0.0011614	-0.126	-2.16e-2	0.01516
2019(11)	-0.0137666	0.009201	-0.00569367	0.0080729	0.877	-0.032169	0.0046358
2019(12)	-0.012142	0.009201	-0.0122925 -	-0.00015048	-0.016	-0.030544	0.0062604
2020(1)	-0.0110819	0.009201	-0.00978225	0.0012996	0.141	-0.029484	0.0073205
2020(2)	0.0148166	0.009201	0.016831	0.0020145	0.219	-0.0035858	0.033219
2020(3)	0.0127394	0.009201	-0.0412974	-0.054037	-5.873	-0.005663	0.031142
2020(4)	-0.0177187	0.009201	-0.183028	-0.16531	-17.966	-3.61e-2	0.00068367
2020(5)	-0.024278	0.009201	0.047919	0.072197	7.846	-0.04268	-0.0058756
2020(6)	0.030716	0.009201	0.0921898	0.061474	6.681	0.012314	0.049118
2020(7)	-0.0429838	0.009201	0.00270129	0.045685	4.965	-0.061386	-0.024581
2020(8)	0.0200317	0.009201	0.0472116	2.72e-2	2.954	0.0016293	0.038434
2020(9)	-0.00475716	0.009201	-0.0102589	-0.0055017	-0.598	-0.02316	0.013645
2020(10)	0.00674346	0.009201	0.0247778	1.80e-2	1.96	-0.011659	0.025146
2020(11)	0.0034266	0.009201	-0.00610951	-0.0095361	-1.036	-0.014976	0.021829
2020(12)	-0.00469709	0.009201	-0.00604981	-0.0013527	-0.147	-0.023099	0.013705
2021(1)	0.0100916	0.009201	0.00770453	-2.39e-3	-0.259	-0.0083108	0.028494
mean(Error) =		0.00098937				RMSE =	0.042356
SD(Error) =		0.042345				MAPE =	137.01

Fonte: Elaboração própria

Tabela 87 – PREVISÃO EUA - COVID-19 MODELO 2: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	0.0192462	0.009675	0.0105162	-0.0087299	-0.902	-0.00010294	0.038595
2019(3)	0.0141903	0.009675	0.012204	-0.0019863	-0.205	-0.0051588	0.033539
2019(4)	-0.00236586	0.009675	-0.0103306	-0.0079647	-0.823	-0.021715	0.016983
2019(5)	-2.02e-3	0.009675	0.00109755	0.003113	0.322	-0.021365	0.017334
2019(6)	0.023554	0.009675	0.0243103	0.00075625	0.078	0.0042049	0.042903
2019(7)	-0.0426737	0.009675	-0.0393196	3.35e-3	0.347	-0.062023	-0.023325
2019(8)	0.0399685	0.009675	0.0362168	-0.0037516	-0.388	0.020619	0.059318
2019(9)	0.00671737	0.009675	-0.0108504	-1.76e-2	-1.816	-0.012632	0.026066
2019(10)	-0.00118688	0.009675	-0.00440337	-0.0032165	-0.332	-2.05e-2	0.018162
2019(11)	-0.0149698	0.009675	-0.00569367	0.0092761	0.959	-0.034319	0.0043793
2019(12)	-0.00890384	0.009675	-0.0122925	-0.0033886	-0.35	-0.028253	0.010445
2020(1)	-0.00722237	0.009675	-0.00978225	-0.0025599	-0.265	-0.026571	0.012127
2020(2)	0.0177426	0.009675	0.0168310 -	-0.00091154	-0.094	-0.0016065	0.037092
2020(3)	0.00995311	0.009675	-0.0412974	-0.051251	-5.297	-0.009396	0.029302
2020(4)	-0.0346652	0.009675	-0.183028	-0.14836	-15.335	-5.40e-2	-0.015316
2020(5)	-0.0295989	0.009675	0.047919	0.077518	8.013	-0.048948	-0.01025
2020(6)	0.027064	0.009675	0.0921898	0.065126	6.732	0.0077149	0.046413
2020(7)	-0.0399707	0.009675	0.00270129	0.042672	4.411	-0.05932	-0.020622
2020(8)	0.0431004	0.009675	0.0472116	4.11e-3	0.425	0.023751	0.06245
2020(9)	-0.00253341	0.009675	-0.0102589	-0.0077255	-0.799	-0.021883	0.016816
2020(10)	-0.00271558	0.009675	0.0247778	2.75e-2	2.842	-0.022065	0.016634
2020(11)	-0.00570896	0.009675	-0.00610951 -	-0.00040054	-0.041	-0.025058	0.01364
2020(12)	-0.0110917	0.009675	-0.00604981	0.0050419	0.521	-0.030441	0.0082574
2021(1)	0.00301873	0.009675	0.00770453	4.69e-3	0.484	-0.01633	0.022368
mean(Error) =		0.00061118				RMSE =	0.039892
SD(Error) =		0.039887				MAPE =	137.58

Fonte: Elaboração própria

Tabela 88 – PREVISÃO EUA - COVID-19 MODELO 3: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	0.0221562	0.00946	0.0105162	-0.01164	-1.23	0.0032368	0.041076
2019(3)	0.0148822	0.00946	0.012204	-0.0026781	-0.283	-0.0040372	0.033802
2019(4)	0.00082118	0.00946	-0.0103306	-0.011152	-1.179	-0.018098	0.019741
2019(5)	-1.71e-3	0.00946	0.00109755	0.0028116	0.297	-0.020633	0.017205
2019(6)	0.0234855	0.00946	0.0243103	0.00082478	0.087	0.0045661	0.042405
2019(7)	-0.0441242	0.00946	-0.0393196	4.80e-3	0.508	-0.063044	-0.025205
2019(8)	0.0366446	0.00946	0.0362168	-0.00042772	-0.045	0.017725	0.055564
2019(9)	0.000289528	0.00946	-0.0108504	-1.06e-2	-1.116	-0.019209	0.01863
2019(10)	0.00341279	0.00946	-0.00440337	-0.0078162	-0.826	-1.55e-2	0.022332
2019(11)	-0.0165535	0.00946	-0.00569367	0.01086	1.148	-0.035473	0.0023659
2019(12)	-0.0142609	0.00946	-0.0122925	0.0019684	0.208	-0.03318	0.0046585
2020(1)	-0.0114206	0.00946	-0.00978225	0.0016383	0.173	-0.03034	0.0074988
2020(2)	0.0183239	0.00946	0.016831	-0.0014928	-0.158	-0.00059552	0.037243
2020(3)	0.0163856	0.00946	-0.0412974	-0.057683	-6.098	-0.0025338	0.035305
2020(4)	-0.00293651	0.00946	-0.183028	-0.18009	-19.038	-2.19e-2	0.015983
2020(5)	-0.0258508	0.00946	0.047919	0.07377	7.798	-0.04477	-0.0069315
2020(6)	0.048072	0.00946	0.0921898	0.044118	4.664	0.029153	0.066991
2020(7)	0.000755531	0.00946	0.00270129	0.0034568	0.365	-0.019675	0.018164
2020(8)	0.0695126	0.00946	0.0472116	-2.23e-2	-2.357	0.050593	0.088432
2020(9)	-0.0475563	0.00946	-0.0102589	0.037297	3.943	-0.066476	-0.028637
2020(10)	0.0120211	0.00946	0.0247778	1.28e-2	1.349	-0.0068982	0.03094
2020(11)	-0.0137592	0.00946	-0.00610951	0.0076497	0.809	-0.032679	0.0051602
2020(12)	-0.0217606	0.00946	-0.00604981	0.015711	1.661	-0.04068	-0.0028413
2021(1)	0.0171526	0.00946	0.00770453	-9.45e-3	-0.999	-0.0017668	0.036072
mean(Error) =		-0.0040677				RMSE =	0.043877
SD(Error) =		0.043688				MAPE =	106.6

Fonte: Elaboração própria

Tabela 89 – PREVISÃO EUA - COVID-19 MODELO 4: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	0.0142098	0.009871	0.0105162	-0.0036936	-0.374	-0.0055323	0.033952
2019(3)	0.0180123	0.009871	0.012204	-0.0058082	-0.588	-0.0017298	0.037754
2019(4)	-0.00367426	0.009871	-0.0103306	-0.0066563	-0.674	-0.023416	0.016068
2019(5)	2.04e-5	0.009871	0.00109755	0.001118	0.113	-0.019763	0.019722
2019(6)	0.0246207	0.009871	0.0243103	-0.00031042	-0.031	0.0048786	0.044363
2019(7)	-0.0428727	0.009871	-0.0393196	3.55e-3	0.36	-0.062615	-0.023131
2019(8)	0.0392115	0.009871	0.0362168	-0.0029947	-0.303	0.019469	0.058954
2019(9)	0.00599938	0.009871	-0.0108504	-1.69e-2	-1.707	-0.013743	0.025741
2019(10)	0.00312124	0.009871	-0.00440337	-0.0075246	-0.762	-1.66e-2	0.022863
2019(11)	-0.0151549	0.009871	-0.00569367	0.0094612	0.958	-0.034897	0.0045872
2019(12)	-0.00768942	0.009871	-0.0122925	-0.004603	-0.466	-0.027432	0.012053
2020(1)	-0.0073421	0.009871	-0.00978225	-0.0024401	-0.247	-0.027084	0.0124
2020(2)	0.0177028	0.009871	0.0168310	-0.00087178	-0.088	-0.0020393	0.037445
2020(3)	0.0130357	0.009871	-0.0412974	-0.054333	-5.504	-0.0067064	0.032778
2020(4)	-0.0341809	0.009871	-0.183028	-0.14885	-15.079	-5.39e-2	-0.014439
2020(5)	-0.136215	0.009871	0.047919	0.18413	18.654	-0.15596	-0.11647
2020(6)	0.064953	0.009871	0.0921898	0.027237	2.759	0.045211	0.084695
2020(7)	-0.0449431	0.009871	0.00270129	0.047644	4.827	-0.064685	-0.025201
2020(8)	0.0721019	0.009871	0.0472116	-2.49e-2	-2.522	0.05236	0.091844
2020(9)	-0.047183	0.009871	-0.0102589	0.036924	3.741	-0.066925	-0.027441
2020(10)	-0.0016771	0.009871	0.0247778	2.65e-2	2.68	-0.021419	0.018065
2020(11)	0.0331243	0.009871	-0.00610951	-0.039234	-3.975	0.013382	0.052866
2020(12)	-0.045074	0.009871	-0.00604981	0.039024	3.953	-0.064816	-0.025332
2021(1)	0.0100284	0.009871	0.00770453	-2.32e-3	-0.235	-0.0097137	0.029771
mean(Error) =		0.0022571				RMSE =	0.053365
SD(Error) =		0.053317				MAPE =	210.62

Fonte: Elaboração própria

Tabela 90 – PREVISÃO EUA - COVID-19 MODELO 5: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	0.0157798	0.009434	0.0105162	-0.0052636	-0.558	-0.0030875	0.034647
2019(3)	0.0190812	0.009434	0.012204	-0.0068772	-0.729	0.00021392	0.037949
2019(4)	0.000391964	0.009434	-0.0103306	-0.010723	-1.137	-0.018475	0.019259
2019(5)	9.87e-4	0.009434	0.00109755	0.0020845	0.221	-0.019854	0.01788
2019(6)	0.025295	0.009434	0.0243103 -	-0.00098472	-0.104	0.0064277	0.044162
2019(7)	-0.0445116	0.009434	-0.0393196	5.19e-3	0.55	-0.063379	-0.025644
2019(8)	0.0377023	0.009434	0.0362168	-0.0014855	-0.157	0.018835	0.05657
2019(9)	0.00268042	0.009434	-0.0108504	-1.35e-2	-1.434	-0.016187	0.021548
2019(10)	0.00117505	0.009434	-0.00440337	-0.0055784	-0.591	-1.77e-2	0.020042
2019(11)	-0.0140469	0.009434	-0.00569367	0.0083533	0.885	-0.032914	0.0048204
2019(12)	-0.00889986	0.009434	-0.0122925	-0.0033926	-0.36	-0.027767	0.0099675
2020(1)	-0.00997672	0.009434	-0.00978225	0.00019446	0.021	-0.028844	0.0088906
2020(2)	0.0156203	0.009434	0.016831	0.0012107	0.128	-0.003247	0.034488
2020(3)	0.0136338	0.009434	-0.0412974	-0.054931	-5.823	-0.0052335	0.032501
2020(4)	-0.0289585	0.009434	-0.183028	-0.15407	-16.332	-4.78e-2	-0.010091
2020(5)	-0.0301286	0.009434	0.047919	0.078048	8.273	-0.048996	-0.011261
2020(6)	0.033565	0.009434	0.0921898	0.058625	6.214	0.014698	0.052432
2020(7)	-0.0202193	0.009434	0.00270129	0.022921	2.43	-0.039087	-0.0013519
2020(8)	0.0175103	0.009434	0.0472116	2.97e-2	3.148	-0.0013571	0.036378
2020(9)	-0.00173041	0.009434	-0.0102589	-0.0085285	-0.904	-0.020598	0.017137
2020(10)	-0.00347628	0.009434	0.0247778	2.83e-2	2.995	-0.022344	0.015391
2020(11)	0.047505	0.009434	-0.00610951	-0.053615	-5.683	0.028638	0.066372
2020(12)	-0.0622674	0.009434	-0.00604981	0.056218	5.959	-0.081135	-0.0434
2021(1)	0.01344	0.009434	0.00770453	-5.74e-3	-0.608	-0.0054274	0.032307
mean(Error) =		-0.001413				RMSE =	0.043374
SD(Error) =		0.043351				MAPE =	178.74

Fonte: Elaboração própria

Tabela 91 – PREVISÃO EUA - COVID-19 MODELO 6: 02/2019-01/2021

Horizon	Forecast	SE	Actual	Error	t-value	-2SE	+2SE
2019(2)	0.017028	0.009732	0.0105162	-0.0065118	-0.669	-0.0024361	0.036492
2019(3)	0.0161752	0.009732	0.012204	-0.0039712	-0.408	-0.0032889	0.035639
2019(4)	0.000701603	0.009732	-0.0103306	-0.0096289	-0.989	-0.020166	0.018763
2019(5)	3.63e-4	0.009732	0.00109755	0.0014607	0.15	-0.019827	0.019101
2019(6)	0.0249721	0.009732	0.0243103 -	-0.00066184	-0.068	0.0055079	0.044436
2019(7)	-0.0454073	0.009732	-0.0393196	6.09e-3	0.626	-0.064871	-0.025943
2019(8)	0.0354634	0.009732	0.0362168	0.00075349	0.077	0.015999	0.054928
2019(9)	0.000952266	0.009732	-0.0108504	-1.18e-2	-1.213	-0.018512	0.020416
2019(10)	0.00265904	0.009732	-0.00440337	-0.0070624	-0.726	-1.68e-2	0.022123
2019(11)	-0.0143738	0.009732	-0.00569367	0.0086802	0.892	-0.033838	0.0050903
2019(12)	-0.00985132	0.009732	-0.0122925	-0.0024411	-0.251	-0.029315	0.0096128
2020(1)	-0.00705067	0.009732	-0.00978225	-0.0027316	-0.281	-0.026515	0.012414
2020(2)	0.0165906	0.009732	0.016831	0.00024043	0.025	-0.0028735	0.036055
2020(3)	0.0107532	0.009732	-0.0412974	-0.052051	-5.348	-0.008711	0.030217
2020(4)	-0.0278765	0.009732	-0.183028	-0.15515	-15.942	-4.73e-2	-0.0084123
2020(5)	-0.0242377	0.009732	0.047919	0.072157	7.414	-0.043702	-0.0047735
2020(6)	0.0283702	0.009732	0.0921898	0.06382	6.558	0.008906	0.047834
2020(7)	-0.0265194	0.009732	0.00270129	0.029221	3.003	-0.045984	-0.0070552
2020(8)	0.00657054	0.009732	0.0472116	4.06e-2	4.176	-0.012894	0.026035
2020(9)	-0.0119177	0.009732	-0.0102589	0.0016588	0.17	-0.031382	0.0075465
2020(10)	0.0157991	0.009732	0.0247778	8.98e-3	0.923	-0.003665	0.035263
2020(11)	0.0466472	0.009732	-0.00610951	-0.052757	-5.421	0.027183	0.066111
2020(12)	-0.0110704	0.009732	-0.00604981	0.0050206	0.516	-0.030535	0.0083938
2021(1)	0.0279972	0.009732	0.00770453	-2.03e-2	-2.085	0.008533	0.047461
mean(Error) =		-0.0035977				RMSE =	0.042001
SD(Error) =		0.041847				MAPE =	153.02

Fonte: Elaboração própria