

**Universidade de Brasília**  
**Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas**  
**Departamento de Economia**

**Ricardo Sukanuma**

**Ensaio de Previsão Macroeconômica**

Brasília  
**2019**

**RICARDO SUGANUMA**

**Ensaio de Previsão Macroeconômica**

Tese de doutorado submetida ao Departamento de Economia da Universidade de Brasília como requisito para a obtenção do grau de Doutor em Economia.

Orientador(a): Victor Gomes e Silva

Brasília  
**2019**

Ficha catalográfica:

**Nome: Ricardo Sukanuma**

**Ensaio de Previsão Macroeconômica**

Tese de doutorado submetida ao Departamento de Economia da Universidade de Brasília como requisito para a obtenção do grau de Doutor em Economia.

Brasília, \_\_\_ de \_\_\_\_\_ de 201\_\_

**Banca Examinadora**

---

Prof. Dr. Victor Gomes e Silva (orientador)  
Departamento de Economia – UnB

---

Prof. Dr. Roberto de Góes Ellery Júnior  
Departamento de Economia - UnB

---

Prof. Dr. Antônio Nascimento Júnior  
Departamento de Administração - UnB

---

Prof. Dr. Carlos Eduardo Gasparini  
Instituto Brasiliense de Direito Público - IDP

*À minha família.*

## **Agradecimentos**

A todos que me auxiliaram em mais esta etapa acadêmica nessa minha vida de aprendizado. Em especial, a Victor Gomes e Silva, meu orientador, pelo acolhimento, orientação, sugestões e pelas infinitas disposição e paciência para com a presente tese, que nem por fórceps era parida, a minha gratidão. Como mentor dessa jornada, contribuiu de forma relevante e os erros e as imprecisões, porventura existentes no texto, certamente, a ele podem ser atribuídos. Aos professores da UnB, que tanto me ensinaram sobre as modernas visões de economia, e que evito nomear para não correr o risco de esquecer alguém. Aos ex-professores da USP e UCSD, em especial, Graham Elliott, Rob Engle, Clive Granger, Jim Hamilton, Alan Timmermann e Hal White, pelos ensinamentos e pela influência em como pensar a Economia, em geral, e a Econometria, minha obsessão. A Luiz Augusto Freire, Carlos Escosteguy, Rodrigo de Losso, Marcelo Rabbat, Ricardo Sassatani e Zeca de Souza Santos pela amizade e confiança. A meus atuais ou prévio chefes, Coronel Braga, José Tadeu Fanis, Marcelo Inácio de Aranha Menezes, Ana Maria Mafra, Wellington Caram, Allan Del Cistia, Rodrigo Galha e Wanderley Rabelo da Silva, por permitirem que realizasse meus estudos. A todos com que trabalhei e contribuíram em minha vida profissional. A Luiz Guilherme Lara Resende, pelo apoio na minha trajetória nos estudos. A meus pais, que me ensinaram a importância do conhecimento, da retidão e da dedicação. Por fim, a minha família, que, de forma mais que compreensiva, incentivou-me e abdicou de minha companhia para permitir que me dedicasse a mais essa fase.

Deus não joga dados com o Universo  
*Albert Einstein*





## Resumo

A falta de previsibilidade do câmbio tem intrigado estudiosos por mais de três décadas. Ferraro, Rogoff e Rossi (2015) encontraram capacidade preditiva contemporânea do preço do petróleo, principal bem exportado pelo Canadá, sobre o câmbio dólar canadense por dólar norte-americano. Investiga-se, no presente estudo, se esse mesmo fenômeno ocorre também em relação ao câmbio real por dólar e, se está restrito a apenas essa *commodity*. Conclui-se que a superioridade preditiva existe, mas não se restringe ao petróleo ou sequer aos principais itens da pauta de comércio exterior brasileiro. Em assunto conexo, analisa-se a relação entre os preços dos principais *benchmarks* de petróleo. Observa-se que não foi constante ao longo do tempo, mas que não se distanciam por longos períodos. Sugerem-se evidências de que há fator(es) não-observável(is) comum(ns) que determinam a dinâmica conjunta entre elas, permitindo que uma das séries, ou uma combinação entre elas, auxilie na previsão da outra. Por fim, mostra-se que variações passadas no preço do petróleo se mostram relevantes para explicar ou anteceder variações no crescimento do PIB.

**Palavras-Chave:** Previsibilidade cambial. Modelos de previsão. Capacidade preditiva. Cointegração. Crescimento econômico.

## Abstract

The lack of exchange rate predictability has puzzled scholars for more than three decades. Ferraro, Rogoff, and Rossi (2015) found contemporary predictive ability of oil prices - Canada's main export commodity - on the Canadian dollar - US dollar exchange rate. We investigate whether the same phenomenon also occurs in relation to the exchange rate Brazilian real - US dollar and whether it is restricted to this oil only. We concluded predictive superiority exists, but is not restricted to oil or even to the main items of the Brazilian foreign trade. In a related matter, the connection between the prices of the main oil benchmarks is analyzed. It is observed that it was not constant over time, but did not distance themselves over long periods. We suggest there are common unobservable factors that determine the joint dynamics between them, allowing one series or a combination of them to help predict the other. Finally, it is shown that past oil price changes are relevant to explain or precede changes in GDP growth.

**Keywords:** Exchange rate predictability. Forecasting models. Predictive ability. Cointegration. Economic growth.

## SUMÁRIO

<b>INTRODUÇÃO.....</b>	<b>13</b>
<b>Arcabouço Teórico e Notação Conceitual .....</b>	<b>16</b>
<b>Estrutura do Trabalho .....</b>	<b>19</b>
<b>CAPÍTULO 1 .....</b>	<b>20</b>
<b>Ferraro-Rogoff-Rossi (2015).....</b>	<b>20</b>
Modelo com (Fundamento em) Preço de <i>Commodity</i> .....	21
Teste Diebold e Mariano (1995).....	22
Modelo de <i>Commodity</i> com Preço Defasado .....	25
<b>Modelo com Fundamento em Diferencial de Juros.....</b>	<b>25</b>
Modelo com Preço de <i>Commodity</i> .....	25
Modelo de Cointegração.....	26
Teste de Flutuação de Giacomini e Rossi (2010).....	26
<b>Dados.....</b>	<b>29</b>
<b>Resultados.....</b>	<b>29</b>
Modelo de Preço de <i>Commodity</i> (Petróleo).....	29
Modelo de Preço de <i>Commodity</i> Defasado.....	34
Modelos com Fundamentos Econômicos: Diferencial de Taxa de Juros.....	36
Teste de Flutuação .....	38
Desempenho Dentro da Amostra Total .....	40
Alteração dos Fundamentos: Soja, Ouro e Cobre.....	41
<b>Conclusão .....</b>	<b>46</b>
<b>CAPÍTULO 2 .....</b>	<b>48</b>
<b>Conceitos e Testes .....</b>	<b>48</b>
Estacionariedade .....	48
Teste de Raiz Unitária .....	49
O Teste Phillips e Perron .....	53
Os testes de Elliot, Rothenberg e Stock (ou ADF-GLS) .....	54
Phillips-Perron Modificado (Ng e Perron(2001)).....	56
Testes de Estacionariedade (KPSS).....	57
Cointegração .....	58
Regressão Espúria.....	59
Teste de Cointegração Baseado em Resíduos .....	59
Formação de preços .....	61
<b>Dados.....</b>	<b>61</b>
<b>Resultados.....</b>	<b>63</b>
<b>Fator Comum.....</b>	<b>73</b>
<b>Formação de preços do diesel.....</b>	<b>75</b>

<b>Conclusão .....</b>	<b>81</b>
<b><i>CAPÍTULO 3</i> .....</b>	<b>83</b>
<b>Modelos.....</b>	<b>83</b>
Sazonalidade.....	83
AR Sazonal (Aditivo) ou AR Degenerado .....	83
Raiz Unitária Sazonal .....	84
Hamilton (2018) .....	84
<b>Petróleo e PIB.....</b>	<b>85</b>
<b>Não Linearidade dos Efeitos do Petróleo .....</b>	<b>85</b>
<b>Resultados.....</b>	<b>86</b>
<b>Conclusão .....</b>	<b>95</b>
<b><i>BIBLIOGRAFIA</i> .....</b>	<b>98</b>

## INTRODUÇÃO

Analistas concordam que a previsibilidade de variáveis econômicas é essencial para a tomada de decisões. O problema reside em como estabelecer as relações entre as diversas variáveis e fazer as previsões das quais têm interesse, como, por exemplo, o câmbio. O presente trabalho contribui no sentido de mostrar que a variação da taxa de câmbio real por dólar norte-americano, considerada tradicionalmente não relacionada a nenhuma outra variável para efeitos práticos, pode ser explicada pela variabilidade no preço do barril de petróleo. Além disso, a relação de preços do barril nos principais mercados estrangeiros é analisada. A partir do preço internacional do petróleo e câmbio, investiga-se se o preço de combustíveis no Brasil é por eles explicado. Por fim, analisa-se a existência de relação entre o petróleo e o crescimento da economia.

Em 21 de maio de 2018, eclodiu uma greve de caminhoneiros que afetou todo o país. A principal reivindicação<sup>1</sup> da categoria profissional era a redução, e manutenção, em nível inferior ao praticado a época, dos preços dos combustíveis, especificamente, o preço do óleo diesel, que vinha sendo objeto de elevação em função de três fatores: a liberação de preços a partir da saída da Presidente Dilma Rousseff do governo, com o consequente fim de controle artificial – possivelmente com intenção de controlar a inflação –, visando a recuperação financeira da companhia; as flutuações diárias no preço do barril de petróleo e a desvalorização cambial. A solução do imbróglio envolveu diminuição e manutenção de preços do diesel por sessenta dias, redução de tributos federais e estaduais, e aumento de subsídios, culminado na renúncia de receita e também aumento de despesa em um orçamento já deficitário e combalido<sup>2</sup>, e demandando medidas provisórias não somente para legislar acerca do assunto, mas também para ajustar o orçamento federal em razão desse evento. Como o principal modal de cargas no país é baseado no transporte rodoviário por caminhões, associado ao fato de os grevistas terem bloqueado o fluxo de várias das principais vias de escoação de mercadorias, a economia nacional foi séria e negativamente afetada pelo movimento.

A influência negativa do aumento inesperado nos preços dos combustíveis não é novidade. A relevância dos efeitos macroeconômicos do petróleo vem sendo estudada por analistas desde as duas crises originadas pela *commodity* nas décadas de 70, derivadas de

---

<sup>1</sup> Outras demandas incluíram alteração na cobrança de pedágio e redução de tributos sobre combustíveis.

<sup>2</sup> Argumento recorrente é de que têm ocorrido “frustrações” nas arrecadações, no sentido de serem realizados valores inferiores aos previstos.

restrição na oferta promovidas por cartéis de países produtores árabes. Já foi, por exemplo, associada à queda no crescimento do Produto Interno Bruto estadunidense, no sentido de choques de oferta antecederem a recessões. De modo geral, um choque do petróleo afeta a economia internacional e pode gerar declínio no crescimento econômico de vários países. Por ser importante insumo produtivo, tanto na geração de energia elétrica como no aquecimento a de residências, e seus derivados resultarem em combustível para transporte, a elevação em seu preço reflete na inflação. Assim, transmitida aos outros bens e serviços da economia, pode levar a autoridade monetária a elevar os juros na tentativa de conter os níveis de preço. Por meio da redução da demanda agregada, procura-se atuar sobre os preços livres, mas abre-se espaço para alteração dos preços relativos, inclusive da taxa de câmbio real. Por outro lado, pode-se ter atuação oposta, com o governo elevando o déficit ou reduzindo os juros para estimular a economia.

Por ser um bem transacionado (transportável e comercializável) internacionalmente, espera-se que a demanda e oferta definam seu preço internacional, com o detalhe de ser um bem com estoque finito de reservas. Alguns países, mormente no Oriente Médio, têm como principal atividade a exportação de petróleo, enquanto outros importam grandes quantidades do produto.

Outro preço, ou termo de troca, essencial na Economia internacional é a taxa de câmbio, determinada pelo fluxo comercial e financeiro do país com os outros países. Por ser um ativo financeiro, a previsibilidade da taxa de câmbio com base em algum padrão passado é questionável<sup>3</sup>. Nesse sentido, diversos autores, dentre os quais Rogoff (1996), propuseram que o câmbio se comportaria como um passeio aleatório (*random walk*).

A despeito de a literatura indicar que a taxa de câmbio apresenta padrão imprevisível, Ferraro, Rogoff e Rossi (2015) encontraram poder preditivo do preço de petróleo sobre o câmbio canadense para dados em frequência maior que a tradicionalmente usada nos estudos anteriores. O Capítulo 1 analisa se o mesmo resultado vale em relação à taxa de câmbio do real em relação ao dólar, com considerações adicionais às reportadas pelos autores.

Outra questão relacionada ao petróleo é que, por ser uma *commodity*, seus preços internacionais em diferentes mercados, excetuado alguns custos, como de transporte e armazenamento - posto se tratar de um ativo real -, deveriam apresentar comportamento similar no longo prazo. A ideia central é que um determinado choque pode afetar um mercado,

---

<sup>3</sup> Numa versão mais simples, a hipótese de eficiência de mercado é testada verificando se o logaritmo do preço do ativo segue um passeio aleatório, com fundamento na ideia de que toda informação relevante já se encontra incorporada em seu preço, não existindo padrão previsível a ser explorado.

elevando seu preço, mas, havendo diferencial de preços, o bem seria adquirido no local com preço inferior e vendido no mercado com cotação mais alta. Com isso, pressionam-se para cima os preços no mercado mais barato e, de modo geral, para baixo na localidade onde ocorreu o choque que aumentou o valor do bem. O equilíbrio seria atingido quando os preços nos diferentes locais se iguallassem. Esse fenômeno comum em ativos é chamado de arbitragem<sup>4</sup>. Para ativos financeiros, como o câmbio, esse movimento é instantâneo, e para outros ativos reais o processo pode demorar mais tempo, mas o diferencial de preços deve desaparecer com o tempo.

No caso específico do petróleo, os principais referenciais (*benchmarks*) de mercados são o *West Texas Intermediate* (WTI), o Brent e o Dubai. Contratos futuros têm como ativos subjacentes esses referenciais. Ao contrário de ativos puramente financeiros, existe um custo claro de extração, armazenagem e transporte para a *commodity*, mas, por ter efetivamente uso, há também a conveniência de se ter em mãos o produto nos momentos de demanda superior à oferta. Independente de tal fato, e apesar da qualidade entre o petróleo ser diferente entre esses referenciais, por serem razoavelmente substitutos<sup>5</sup>, é de se esperar que eventuais choques que perturbem a relação de preços entre eles sejam corrigidos a longo prazo. O Capítulo 2 avalia se existe evidência do equilíbrio de longo prazo no preço dos *benchmarks*. Correlata encontra-se a investigação sobre se a formação de preços dos combustíveis segue as variações do preço internacional do barril e cambial.

A última questão envolve outro ponto relevante: saber se há evidência, como nos Estados Unidos, da influência do preço do petróleo no PIB real da economia brasileira. Nessa parte, avaliaremos a existência de não-linearidades na relação entre ambas. Antes, expõe-se a seguir o referencial conceitual por trás da moderna literatura acerca de previsões econômicas.

---

<sup>4</sup> No caso de bens homogêneos e na ausência de restrições, a arbitragem fundamenta a lei do preço único, pela qual a *commodity*, convertidos os preços na mesma moeda, deve ter preços iguais nos dois países.

<sup>5</sup> O *blend* tipo Brent se refere a diversos petróleos extraídos em campos no Mar do Norte. Já o WTI é extraído em terra, mormente por empresas na região do Texas. Por isso, a extração do Brent é mais cara, porém o transporte marítimo para exportação é mais barato do que o efetuado por dutos (*pipelines*) se concentrando em Cushing, OK. Os petróleos do tipo Brent e Dubai são mais leves do que o WTI. Esse “leveza” possibilita a produção de derivados mais “nobres” como gasolina ou diesel. Para se ter uma ideia da importância dessa diferença na qualidade, a dificuldade no refino do derivado faz com o custo, a quantidade e a qualidade de produção seja diferente para cada tipo de petróleo. O Brasil tem exportado petróleo cru e importado derivados.

## Arcabouço Teórico e Notação Conceitual

A presente seção é baseada no trabalho de Elliott e Timmermann (2016), donde se extraiu a notação - com poucas adaptações -, que aparecia de forma não uniforme em diversos artigos relativos à previsão econômica. Expõem-se ainda conceitos subjacentes à teoria de previsão nem sempre explicitados nesses artigos.

Retomando a ideia inicial, o interesse do analista é realizar previsões das variáveis econômicas relevantes. Nem todos utilizam os mesmos modelos e dados, e a qualidade da previsão vai depender do quanto o valor efetivo da variável afastou-se do seu valor previsto. Não apenas isso, mas os diferentes agentes podem reagir de forma diversa a um mesmo desvio observado ao que era esperado. Para mensurar a perda ou custo desse erro de previsão, utiliza-se, em representação genérica, uma função de perda  $L(\cdot)$ , que depende do valor de  $Y$ , a variável que pretende se prever, de  $f$ , a previsão, e, muitas vezes, de  $Z$ , o vetor com outras variáveis. A função de perda utilizada afeta a escolha do modelo que o agente irá utilizar. Por isso, na aplicação ao caso concreto, deve-se selecionar a função de perda que melhor reflita as perdas associadas às decisões tomadas. Por exemplo, em certas situações, o custo de se errar “para mais” (desvio positivo) pode ser menor do que errar “para menos”, sendo adequado o uso de funções assimétricas em relação ao erro<sup>6</sup> que reflitam essa preferência. Isso porque, para determinados agentes, a qualidade da previsão, de acordo o critério definido, pode ser usado para avaliar a qualidade do próprio agente. Por exemplo, no mercado financeiro, um gestor de fundos que consiga de forma consistente entregar uma carteira de investimento com retorno maior e/ou risco menor é melhor avaliado, atraindo recursos à instituição. Para formalizar a discussão dos capítulos seguintes, procede-se, aqui, à exposição da teoria subjacente aos testes a serem aplicados.

Vamos nos ater ao caso de se desejar prever apenas o valor de uma variável. Seja  $Y$  uma variável aleatória de interesse e  $\mathcal{Y}$  o conjunto de todos os possíveis resultados (espaço amostral)

---

<sup>6</sup> Nesse sentido, Elliott e Timmerman (2016, p.13) apontam a possível assimetria inerente à função de perda: “For example, the Congressional Budget Office must provide forecasts of future budget deficits. Their loss function in providing the forecasts should be based on the relative costs of over- and underpredicting public deficits.” Ainda, esclarecem, relacionando perda e utilidade, que: “[l]oss functions, as used by forecasters to evaluate their performance, and utility functions, as used by economists to assess the economic value of different outcomes, are naturally related. Both are grounded in the same decision-theoretic setup which regards the forecast as the decision and the outcome as the true state and maps pairs of outcomes (states) and forecasts  $(Y, f)$  to the real line. In both cases we are interested in minimizing the expected loss or disutility that arises from the decision.” (*ibidem*, p. 15).



de  $Y$ . Por simplicidade, vamos supor que  $Y$  seja um número real, i.e.,  $Y = \mathbb{R}$ . A previsão  $f$  para a variável  $Y$  também encontra-se definida no conjunto  $\mathbb{R}$ , assim como o valor de  $L(f, Y)$ . O erro de previsão é definido por  $e = y - f$ , onde  $y$  é o valor (resultado) observado de  $Y$ .

As propriedades desejadas para que uma função de perda “razoável” são

$$L(0) = 0;$$

$$L(e) \geq 0, \text{ para todo } e;$$

$$L(e) \text{ é não-crescente em } e \text{ quando } e < 0 \text{ e não-decrescente em } e \text{ para } e > 0.$$

A primeira propriedade, associada à segunda, reflete à ideia de que a menor perda ocorre que o erro de previsão é zero, ou seja, se o valor previsto for igual ao valor observado. Da segunda, extrai-se que qualquer erro, seja positivo ou negativo, causa uma perda maior do que quando o erro é nulo. A terceira preconiza que a perda não pode diminuir conforme se afasta de  $e = 0$ , i.e.,  $L(e_1) \leq L(e_2)$  se  $e_2 < e_1 < 0$  e  $L(e_1) \leq L(e_2)$  se  $e_2 > e_1 > 0$ .

Existem propostas na teoria diversas funções de perda (ver a respeito Giacomini e Komunjer (2005) e Elliott e Timmermann (2016)), mas no presente trabalho nos restringiremos ao erro quadrático (ou erro quadrático médio, MSE, em inglês)

$$L(e) = L(y - f) = ae^2, a > 0.$$

A função de perda acima é homogênea com relação a  $a$ , é simétrica em torno de 0 e diferenciável em qualquer ponto, facilitando a otimização. Em virtude da sua convexidade,  $L$  penaliza os erros de forma mais forte conforme se afasta de zero. Pode-se mostrar, como será esboçado mais abaixo, que a previsão ótima quando se usa a função de perda quadrática corresponde à média condicional de  $Y$ , i.e., à projeção linear.

Para se chegar a  $f$ , em geral, precisa-se das variáveis observadas  $Z$ . De modo a estabelecer de forma mais clara essa relação, digamos que a previsão é efetuada na data  $T$ , com conhecimento dos valores realizados até essa data, e denotamos de  $I_T$  a sigma-álgebra<sup>7</sup> gerada por  $Z_t, t = 1, \dots, T$ , com  $I_{T-1} \subset I_T$  (tecnicamente, um filtragem), também chamado de conjunto de informação. Ou seja, o analista conhece os valores passados de todas as variáveis observadas. O valor esperado de  $Y$  dado  $Z = z$ , onde  $z$  é o valor observado ou sobre o qual se condiciona, representado por  $E[Y | z] = E[Y | Z = z] = E[Y | I_T]$ .  $Z$  pode conter valores passados da própria variável  $Y$  e outros regressores (contemporâneos ou passados) utilizados na previsão,  $X$ .

---

<sup>7</sup> Grosso modo, sigma-álgebra de um conjunto  $X$  é um conjunto formado por subconjuntos de  $X$ , uniões e interseções desses subconjuntos e o conjunto vazio, que permite definir medidas em  $X$ .

A previsão requer, em geral, a estimação de um modelo para se obter  $Y$  condicionado a  $z$ , juntamente com parâmetros desconhecidos. No caso de um modelo paramétrico, a função de previsão ótima é representada por  $f^*(z, \beta)$ , onde  $\beta$  é o vetor contendo os parâmetros do modelo. Como não se conhece  $\beta$  *a priori*, estima-se os parâmetros do modelo  $f(z, \beta)$  com base em  $z$  observado e passa-se a usar  $f(z, \hat{\beta}) = f(z)$ . O objetivo é obter a menor perda na média para diferentes valores de  $Y$ , i.e., minimizar a perda esperada,  $E_Y [L(f(Z), Y)|Z]$ .

Para uma função de perda quadrática, a previsão ótima é  $f^* = E [Y | z]$ , o que requer conhecer a relação verdadeira entre  $y$  e  $z$ . Num contexto de modelo de regressão,  $y_{t+1} = \beta x_t + \varepsilon_{t+1}$ , onde  $\varepsilon_{t+1} \sim iid(0, \sigma^2)$  é independente de (ortogonal a)  $Z_T = (x_0, \dots, x_T)$ , a projeção linear de  $y$  em  $z$  é:  $f(z) = \beta z$ . Por construção, os erros de previsão são ortogonais:  $EY [(Y - \beta z)z] = 0$ . Assim, dentro da classe de modelos lineares, a projeção da regressão é ótima. Restringindo à classe de modelos dependentes de parâmetros desconhecidos  $\beta$  e dos dados  $z$ , a previsão ótima é denotada por  $f(z, \beta^*)$ , com  $\beta^* = \arg \min_{\beta \in B} EY [L(f(Z, \beta), Y)]$ . Nesse contexto,  $\beta^*$  é denotado de valor pseudo-verdadeiro de  $\beta$ .

A questão da função de perda, tomada como primitiva, i.e. ponto a partir do qual se parte, é relevante, pois raramente se pode ter certeza de que o modelo está corretamente especificado, por exemplo, a forma funcional do modelo, os regressores ou as defasagens a serem incluídas serem de perfeito conhecimento do analista. Essa incerteza faz com se considere um conjunto de modelos alternativos para a previsão. Caso o analista tenha que escolher apenas um modelo – ou mesmo definir se deve combinar as previsões de diversos modelos para obter uma única previsão para  $Y$  – ele deve ser capaz de selecionar aquele que melhor represente seu objetivo. No caso, o melhor modelo é o que minimiza a (função de) perda em média, considerando o processo gerador de dados, o conjunto de informação e o horizonte de previsão.

Admite-se que existam um conjunto finito de modelos de previsão  $\mathcal{M}_K$ , e que cada modelo seja representado por  $M_k$ , para  $k = 1, \dots, K$ . A partir de cada um deles, pode ser obtida uma previsão,  $f_k(z_t, \beta_k)$ , onde  $z_t$  é o vetor contendo os regressores,  $\beta_k$  é o vetor de parâmetros do modelo  $k$ . Com isso, o problema é simplificado: buscar o modelo  $k$  que minimize a perda. Como apontam Elliott e Timmermann (2016), a seleção de modelos com base em critério pode tornar “nebulosa” a distinção entre escolha para estimação (na amostra, ou *in-sample*) e para previsão (fora da amostra, ou *out-of-sample*). Isso decorre do fato que, para o analista, o número de observações disponíveis é limitado e para avaliar a qualidade das previsões, deve dividir

uma parte para fazer a estimação e outra para avaliar a qualidade das previsões oriundas dos modelos.

## **Estrutura do Trabalho**

A contextualização do problema de previsão é importante para os capítulos que se seguem, em especial os dois primeiros. O Capítulo 1 aplica a teoria para uma questão prática: até recentemente, o câmbio era considerado uma variável imprevisível, e, por conta de um trabalho recente de Ferraro, Rogoff e Rossi (2015), vislumbrou-se a possibilidade de haver capacidade preditiva do preço contemporâneo da principal *commodity* exportada sobre o câmbio. Analisamos se essa hipótese para verificar se existe relação entre a taxa real-dólar e o petróleo - que tem sido um dos principais itens de exportação do país -, além de outras *commodities*. Já o Capítulo 2 avalia a relação entre os diferentes barris referencias no mercado internacional, sob a perspectiva de relação entre eles, e previsibilidade no preço de um referencial com fundamento no comportamento das outras. O efeito do petróleo na economia brasileira e possível não-linearidade desse efeito é abordado no Capítulo 3. Por fim, conclui-se acerca dos principais resultados encontrados.

## CAPÍTULO 1

O trabalho de Ferraro, Rogoff e Rossi (2015) inovou ao relatar a evidência de que mudanças nos preços do principal bem de exportação de um país estão relacionadas contemporaneamente com alterações na sua taxa nominal de câmbio. O presente capítulo irá verificar se a relação encontrada entre petróleo e câmbio dólar canadense por dólar estadunidense também existe entre variações no preço do petróleo e na taxa de câmbio do real por dólar. Apesar de o petróleo somente ter assumido relevância nas exportações brasileiras nas duas últimas décadas, o atual posicionamento no *ranking* de exportações (terceiro lugar em 2018) e o potencial de reservas descobertas no período fazem com que essa *commodity* mantenha importância no futuro. Além disso, o petróleo, incluindo seus derivados, é considerado um dos principais insumos na economia moderna, representando a principal fonte de energia em diversos países. Autores como Hamilton (1983) apontaram a relação entre choques negativos (crises) no petróleo e queda no crescimento da economia. Assim, decidiu-se por manter como *commodity* explicativa do câmbio o petróleo. O papel relevante do petróleo permeia não só este, mas os demais capítulos da tese. Para investigar a sua relação com o câmbio, inicia-se expondo, na seção *infra*, os modelos de previsão estimados e testados pelos citados autores.

### **Ferraro-Rogoff-Rossi (2015)**

Com a finalidade de descrever a metodologia aplicada ao caso brasileiro, apresentam-se abaixo as principais ideias exploradas por Ferraro, Rogoff e Rossi (2015), desde a justificativa para escolha do câmbio, passado pelos principais modelos e resultados.

A relação entre o preço de petróleo e a taxa de câmbio entre o dólar canadense e o norte americano é estabelecida com fundamento no poder preditivo da primeira variável sobre a segunda. Os motivos da escolha da moeda reportado foram: (i) o fato de o óleo cru representar aproximadamente 20% das exportações do Canadá; (ii) o país ter uma longa tradição de câmbio flutuante; e (iii) o país ser uma economia aberta pequena de modo a se poder assumir que é um tomador de preços (*price taker*).

### Modelo com (Fundamento em) Preço de *Commodity*

O modelo básico considerado no estudo envolve a regressão abaixo:

$$\Delta s_t = \alpha + \beta \Delta p_t + u_t, t = 1, \dots, T$$

onde  $\Delta s_t$  é a primeira diferença do logaritmo da taxa de câmbio entre o dólar canadense e o norte-americano;  $\Delta p_t$ , a primeira diferença no logaritmo do preço do óleo,  $u_t$  é o termo aleatório com média zero e variância constante; e  $T$ , o tamanho total da amostra.

Anota-se que, a despeito de a variável explicativa,  $\Delta p_t$ , ser contemporânea à explicada e, por isso, não representar um modelo de previsão *ex-ante* propriamente, já que se utiliza o valor realizado *ex-post* do regressor, o que se avalia é o poder preditivo do modelo com base na trajetória dessa variável (“não modelada”), que é de difícil previsibilidade.

Naturalmente, a regressão usando os dados de todo o período (amostra total) não permitiria testar a capacidade preditiva do modelo. Nesse sentido, haveria três estratégias possíveis de serem seguidas: (i) estimar o modelo com base nos últimos  $R$  valores e fazer a previsão 1 período para frente, mantendo o tamanho da amostra para estimação fixa para os próximos períodos, i.e., descartando, a cada nova observação incluída, a observação mais antiga, método este denominado de janela rolante de tamanho fixo (*rolling window*); (ii) estimar o modelo com um janela fixa (*fixed window*)  $R$ , mantendo os valores dos parâmetros sem novas estimações por todo o período de previsão; ou (iii) estimar o modelo, aumentando o tamanho da amostra a cada observação para obter a previsão um período para frente, i.e., para os próximos períodos, apenas incluir a nova observação na regressão, sem excluir as observações mais antigas, sendo o método chamado de recursivo (*recursive*). No artigo, os autores deram ênfase à primeira estratégia<sup>8</sup>, inclusive para outras hipóteses testadas, chegando a reportar os resultados da segunda abordagem somente para o caso base - modelo com preço do petróleo - para efeitos de comparação.

---

<sup>8</sup> A rigor, a explicação de não se utilizar a estimação recursiva é que, caso um modelo seja idêntico ao outro, exceto por variáveis excluídas em apenas um deles, este estaria englobado ou incorporado (*nested*) no outro. Nessa situação, aponta-se que testes como de Diebold e Mariano (1995) e Giacomini e White (2006) não poderiam ser aplicados. Essa discussão será aprofundada mais adiante.

Assim, estimaram-se, por regressão linear simples, os parâmetros  $\alpha$  e  $\beta$  do modelo com janela rolante dentro da amostra e foi obtida uma sequência de pseudo previsões<sup>9</sup> condicionadas aos valores realizados (ou observados ou efetivos) dos preços da *commodity*.

$$\Delta \hat{s}_{t+1}^f = \hat{\alpha}_t + \hat{\beta}_t \Delta p_{t+1}, \text{ com } t = R, R+1, \dots, T-1,$$

onde  $\Delta \hat{s}_{t+1}^f$  é a pseudo previsão um período para frente fora da amostra,  $\hat{\alpha}_t$  e  $\hat{\beta}_t$  são os parâmetros estimados. Por projetar  $\Delta s_{t+1}$  usando  $\Delta p_{t+1}$ , corresponde a uma previsão fora da amostra, já que os dados relativos a  $t+1$  não foram utilizados para estimar  $\alpha$  e  $\beta$ , que foram estimados apenas dados disponíveis até  $t$ . Caso a previsão decorrente do uso do petróleo apresente bons resultados, se possível fosse encontrar um modelo de previsão para o preço do barril, poder-se-ia usá-lo para prever o comportamento futuro do câmbio.

A série de previsões sequenciais pelo modelo acima para o câmbio pode ser comparada com os dois principais modelos de referência: o *random walk* e o *random walk com drift*. Para tanto, recorre-se ao teste de igualdade do poder preditivo de Diebold e Mariano (1995) usando o critério de erro quadrático de previsão médio, *Mean Squared Forecast Errors* (MSFEs), do modelo em relação aos dois *benchmarks*.

O referido teste tem como primitivas duas séries de previsões – e não os modelos – possibilitando a comparação do desempenho das previsões conforme um critério definido. Assim, a princípio, sequer se exige o conhecimento dos modelos utilizados, mas apenas das previsões deles decorrentes. Por isso, a rigor, o teste não permite concluir qual modelo é melhor, mas apenas qual sequência de previsões, advinda desses modelos, foi superior, de acordo com o critério de perda escolhido e para o período amostral utilizado. Na sequência apresenta-se o teste de Diebold e Mariano (ou DM).

### Teste Diebold e Mariano (1995)

O teste de Diebold e Mariano parte das previsões e considera a função de perda  $L$  e as variações amostrais das perdas médias. Assume-se que existem duas séries de previsão e, portanto, tem-se duas séries de perdas  $L(f_{1,t+1|t}, y_{t+1})$  e  $L(f_{2,t+1|t}, y_{t+1})$ . A diferença entre as perdas  $d_{t+1} = L(f_{1,t+1|t}, y_{t+1}) - L(f_{2,t+1|t}, y_{t+1})$  é usada no teste. A hipótese de igualdade das previsões dos

---

<sup>9</sup> Na literatura, é comum denominar previsões obtidas por meio de parâmetros estimados de pseudo (ou falsa) previsão.

dois modelos, i.e.,  $E[L(f_{1,t+1|t}, y_{t+1})] = E[L(f_{2,t+1|t}, y_{t+1})]$ , pode ser testada confrontando-se a hipótese nula  $H_0: E[L(f_{1,t+1|t}, y_{t+1}) - L(f_{2,t+1|t}, y_{t+1})] = E[d_{t+1}] = 0$ , contra a alternativa univariada, caso se queira verificar se um determinado modelo é melhor do que o outro - i.e.,  $E[d_{t+1}] < 0$  se deseja-se avaliar se o modelo 1 é superior, ou, para a superioridade do modelo 2,  $E[d_{t+1}] > 0$  – ou contra alternativa bivariada, caso se deseje testar  $E[d_{t+1}] \neq 0$ . A estatística do teste  $t$  de Diebold e Mariano é dada por

$$t_{DM} = \frac{\bar{d}}{\hat{\sigma}_d} \sim N(0,1)$$

Onde  $\hat{\sigma}_d$  é o erro padrão de  $\bar{d}$ . Os autores usam  $\hat{\sigma}_d = \sqrt{T^{-1}\hat{g}(0)}$ , onde  $\hat{g}(0)$  é um estimador consistente da variância do diferencial de perda no espectro de frequência zero.

Diebold (2015) estabelece as condições sob as quais o teste pode ser conduzido. As hipóteses são

- a)  $E[d_{t+1}] = \mu_d$ , para todo  $t$ ,
- b)  $\text{Cov}(d_t, d_{t-j}) = \gamma_j$ ,
- c)  $0 < \text{var}(d_t) = \sigma^2 < \infty$ .

Destaca-se que desvio padrão de  $d$  deve ser corrigido para autocorrelação<sup>10</sup> de ordem  $h-1$ , onde  $h$  é o horizonte de previsão, podendo se utilizar de qualquer estimador consistente da variância, como o HAC (consistente) de Newey e West.

Com base no fato de o teste de Diebold e Mariano não levar consideração a nenhum ajuste em razão dos graus de liberdade no cálculo da variância, Harvey, Leybourne e Newbold (1997) propuseram a seguinte modificação na estatística do teste,

$$t_{HLN} = \left(1 + T_P^{-1}(1 - 2h) + T_P^{-2}h(h - 1)\right)^{\frac{1}{2}} t_{DM}.$$

Além disso, propõem os autores que se utilizem os valores críticos da distribuição  $t$ . O efeito dessas duas modificações é: (i) reduzir o valor da estatística  $t$  e (ii) aumentar os valores críticos, melhorando o tamanho (*size*) nominal do teste em experimentos de Monte Carlo.

Para  $h = 1$ , a correção sugerida acima recai em

---

<sup>10</sup> Nos termos de Elliott e Timmermann (2016, p. 398): “For  $h$ -step-ahead forecasts with overlapping data, an  $MA(h - 1)$  structure is induced in  $d_{t+h}$  if the underlying forecasts are rational so a window of at least  $h - 1$  observations should be used to construct the standard errors...”

$$t_{HLN} = \left(\frac{T-1}{T}\right)^{\frac{1}{2}} t_{DM}$$

o que corresponde a usar  $T - 1$  ao invés de  $T$  na fórmula do teste. Considerando o tamanho das amostras no presente estudo, tal ajuste não interfere nos resultados dos testes. Da mesma maneira, o uso da distribuição  $t$  no lugar da Gaussiana não se mostra relevante em razão da proximidade dos valores críticos de ambas quando o número de graus de liberdade na  $t$  de Student é maior do que 30.

A vantagem do teste de Diebold e Mariano associado à estimação com janelas rolantes é que pode ser implementado mesmo na situação que um modelo incorpore (*nest*) o outro e tenha parâmetros estimados<sup>11</sup>.

Para melhor entendimento acerca da incorporação (*nesting*) de um modelo pelo outro, anota-se que o passeio aleatório com constante (*random walk with drift*) é dado por

$$s_t = \alpha + s_{t-1} + \varepsilon_{t-1},$$

sendo a previsão ótima para  $t + 1$  dada por

$$\begin{aligned}\hat{s}_{t+1} &= \hat{\alpha} + s_t, \text{ ou} \\ \Delta \hat{s}_{t+1} &= \hat{\alpha}\end{aligned}$$

ou, se, no caso do *random walk* sem *drift*,

$$\Delta \hat{s}_{t+1} = 0$$

Na aplicação empírica, dada uma amostra total  $T$ , esta é dividida em uma parte para estimação  $R$ , e outra de tamanho  $P$  para previsão. Como o teste pode ser sensível ao tamanho da amostra selecionada, a estratégia adotada para demonstrar a robustez dos resultados foi calcular a estatística do teste DM para diferentes tamanhos de amostra  $R$  usado para a estimação. Caso, sistematicamente, para diferentes janelas  $R$ , encontre-se abaixo de -1.96, uma vez que a estatística apresenta distribuição assintótica Normal, conclui-se que modelo com o preço da

---

<sup>11</sup> Ver Giacomini e White (2006).



*commodity* tem desempenho melhor em previsão, de acordo o critério MSFE, do que o passeio aleatório referencial.

### **Modelo de *Commodity* com Preço Defasado**

Se o modelo de *commodity* tem desempenho melhor do que o do passeio aleatório, mas apresenta como inconveniente prático a necessidade de se conhecer valores contemporâneos do regressor, desconhecidos no momento da previsão, a questão é se seria possível usar valores defasados do preço da *commodity* para prever o câmbio.

$$\Delta s_t = \alpha + \beta \Delta p_{t-1} + u_t, t = 2, \dots, T$$

### **Modelo com Fundamento em Diferencial de Juros**

Outra questão diz respeito ao uso de outros fundamentos macroeconômicos para prever a evolução do câmbio. Especificamente, o diferencial da taxa de juros entre dois países explicando a desvalorização cambial:

$$\Delta s_t = \alpha + \beta \Delta i_t + \mu_t, t = 1, \dots, T$$

onde  $\Delta i_t$  é a diferença entre a taxa de juros entre os dois países e  $\mu_t$  é o termo imprevisível. Ou com base na teoria de paridade descoberta de juros, também refletida em argumentos de arbitragem,

$$\Delta s_t = \alpha + \beta \Delta i_{t-1} + \varepsilon_t, t = 2, \dots, T$$

### **Modelo com Preço de *Commodity***

Além disso, pode-se aventar a hipótese de alguma outra *commodity* apresentar capacidade preditiva no lugar do petróleo para explicar o câmbio, caso esse em que se utiliza-se o modelo

$$\Delta s_t = \alpha + \beta \Delta p_t + u_t, t = 1, \dots, T.$$

onde  $\Delta p_t$  é a primeira diferença no logaritmo do preço da *commodity* alternativa.

### Modelo de Cointegração<sup>12</sup>

Outro modelo a ser testado envolve o fato de poder existir relação estável de longo prazo entre  $p$  e  $s$ , de tal sorte que um desvio provocado por um choque aleatório temporário venha a ser corrigido ao longo do tempo:

$$\Delta s_t = \alpha + \beta(p_{t+1} - s_{t+1}) + u_t, t = 1, \dots, T.$$

Aponta-se que  $\beta$  indica a velocidade de ajuste com que o desvio de  $t-1$  será corrigido no próximo período  $t$ .

### Teste de Flutuação de Giacomini e Rossi (2010)

Empiricamente, observa-se que, para as principais variáveis macroeconômicas, existem instabilidades nas relações estruturais entre as variáveis econômicas e/ou nos parâmetros que definem a dinâmica das séries, alterando desempenho preditivo relativo dos modelos. Testes convencionais como Diebold e Mariano (1995), West (1996), Clark e West (2006) e Giacomini e White (2006) não se mostram adequados, posto compararem o desempenho (perda) médio por todo o período amostral ou fora da amostra. Como o diferencial de perda também evolui no tempo, Giacomini e Rossi (2010) propuseram um teste baseado na média do desempenho relativo local.

Usando o mesmo arcabouço apresentado, divide-se a amostra total  $T$  em duas partes: uma dentro da amostra,  $R$ , e outra fora da amostra,  $P$ . Existem duas sequências de previsões  $h$ -períodos para frente decorrentes de dois modelos concorrentes. Dada uma função de perda  $L$

---

<sup>12</sup> Apesar de Ferrero, Rogoff e Rossi (2015) denominarem a especificação de “cointegração”, entendemos que a terminologia não é totalmente adequada. O conceito formal de cointegração será apresentado mais adiante, porém antecipa-se que a equação representa a forma de correção de erros decorrente da cointegração, exceto por excluir as defasagens da variável do lado esquerdo da regressão, no caso o retorno do câmbio. Esses termos omitidos fazem parte da dinâmica do modelo. Além disso, a especificação traz a ideia de que a relação existente entre  $s$  e  $p$  é de um para um, o que não é o caso.

que mensura o desempenho de cada modelo (ou série de previsão), tem-se uma sequência de  $P$  diferenças de perdas de previsão<sup>13</sup>,

$$\{\Delta L_t(\hat{\theta}_{j-h,R}, \hat{\gamma}_{j-h,R})\}_{t=R+h}^T \equiv \{L^{(1)}(y_t, \hat{\theta}_{j-h,R}) - L^{(2)}(y_t, \hat{\gamma}_{j-h,R})\}_{t=R+h}^T,$$

que é função dos valores observados da variável  $y$  e da sequência de parâmetros  $\hat{\theta}_{j-h,R}$  e  $\hat{\gamma}_{j-h,R}$  estimados dentro da amostra para o modelo 1 e o modelo 2, respectivamente. A princípio, poderiam ser usados três métodos para estimação: (i) fixo - usando parâmetros estimados apenas uma vez com os dados de  $t = 1, 2, \dots, R$ ; (ii) rolante - estimado para cada  $t = R+h, \dots, T$  com uma janela de tamanho fixo  $R$  com os dados de  $t-h-R+1$  até  $t-h$ ; e (iii) recursivo - inicia-se a estimação com uma amostra de tamanho  $R$ , e a cada período o modelo é estimado incorporando a última informação disponível, elevando o tamanho da amostra. Para a discussão que se segue, assume-se a utilização de janelas rolantes.

A perda relativa local para os dois modelos é definida como a sequência de diferenças fora da amostra calculadas em cima de uma janela rolante de tamanho  $m$  centrada,

$$m^{-1/2} \sum_{j=t-m/2}^{t+m/2-1} \Delta L_t(\hat{\theta}_{j-h,R}, \hat{\gamma}_{j-h,R}), t=R+h+m/2, \dots, T-m/2+1.$$

Esse arcabouço, como apontado por Giacomini e Rossi (2010), parte de hipóteses bem gerais, desde que usados métodos rolantes ou fixos de estimação, permitindo a comparação de modelos não incorporados ou incorporados (*nested*)<sup>14</sup> e que os dados<sup>15</sup> sejam *mixing* e heterogêneos (ver a respeito Giacomini e White (2006)). A Proposição 1 de Giacomini e Rossi demonstra que a estatística

<sup>13</sup> Para o presente teste, preferiu-se manter a notação do artigo de Giacomini e White, mas, caso fosse a representação das seções anteriores, seria:

$$\{\Delta L_t(\hat{\beta}_{1t}, \hat{\beta}_{2t}, y_{t+h})\}_{t=R}^{T-h} \equiv \{L(f_{1t+h|t}(\hat{\beta}_{1t}) - y_{t+h}) - L(f_{2t+h|t}(\hat{\beta}_{2t}) - y_{t+h})\}_{t=R}^{T-h}.$$

<sup>14</sup> Neste ponto, pode-se discutir a razão da importância de a hipótese alternativa englobar (*nest*) a nula. Caso a nula seja verdadeira, se o tamanho da amostra de estimação for para infinito (ou suficientemente grande), as estimativas dos parâmetros adicionais do modelo maior irão convergir para zero, fazendo com que os dois modelos resultem em previsões iguais. Nesse caso, a variância da diferença entra as perdas irá para zero, inviabilizando o teste. Ao limitar a amostra de estimação em  $R$ , mas permitindo  $P$  crescer, faz-se com que haja um viés de estimação que garante a variância da diferença de perdas ser positiva.

<sup>15</sup> Em outras palavras, permitem diversos tipos de dependência da série.

$$F_{t,m}^{OOS} = \hat{\sigma}^{-1} m^{-1/2} \sum_{j=t-\frac{m}{2}}^{t+\frac{m}{2}-1} \Delta L_t(\hat{\theta}_{j-h,R}, \hat{y}_{j-h,R})$$

$t=R+h+m/2, \dots, T-m/2+1$ , onde  $\hat{\sigma}^2$  é um estimador consistente da variância de  $\Delta L_t$ , sob a hipótese nula  $H_0: E\{\Delta L_t(\hat{\theta}_{j-h,R}, \hat{y}_{j-h,R})\} = 0$  para qualquer  $t = R+h, \dots, T$ ,

$$F_{t,m}^{OOS} \Rightarrow \frac{[B(\tau+\mu/2)-B(\tau-\mu/2)]}{\sqrt{\mu}},$$

onde  $t = \{\tau P\}$ ,  $m = \{\mu P\}$  e  $B(\cdot)$  é um movimento Browniano univariado.

Os valores críticos  $k_\alpha$  para os níveis de significância  $\alpha = 5\%$  e  $10\%$ , unilateral e bilateral, e proporções  $\mu$  do tamanho da amostra de previsão encontram-se tabulados em Giacomini e Rossi (2010). A hipótese nula é rejeitada em favor da alternativa bilateral  $H_0: E\{\Delta L_t(\hat{\theta}_{j-h,R}, \hat{y}_{j-h,R})\} \neq 0$  se  $\max_t |F_{t,m}^{OOS}| > k_\alpha$ . Para hipóteses alternativas unilaterais, como  $H_0: E\{\Delta L_t(\hat{\theta}_{j-h,R}, \hat{y}_{j-h,R})\} > 0$ , a hipótese nula é rejeitada se  $\max_t F_{t,m}^{OOS} > k_\alpha$ . Caso seja  $H_0: E\{\Delta L_t(\hat{\theta}_{j-h,R}, \hat{y}_{j-h,R})\} < 0$ , é rejeitada se  $\min_t F_{t,m}^{OOS} < -k_\alpha$ .

A estatística  $F_{t,m}^{OOS}$  corresponde a do teste de Diebold e Mariano (1995) e a do teste incondicional de Giacomini e White (2006) calculadas em janelas rolantes de tamanho  $m$ .

Já na estatística de Clark e West (2006)<sup>16</sup> para modelos incorporados (*nested*), as diferenças encontram-se: (i) na função de diferencial de perda<sup>17</sup> usada, já que erro quadrático da previsão deveria ser ajustado para reduzir o viés para cima decorrente da estimação de parâmetros de valor zero sob a hipótese nula; (ii) no fato de ser unilateral e de subtrair o erro quadrático do modelo com mais parâmetros do erro quadrático do modelo referencial,

<sup>16</sup> Clark e West propõem o ajuste em razão de o erro quadrático esperado do modelo (alternativo) com variáveis adicionais ser menor do que o modelo da hipótese nula, exatamente, por conter regressores a mais. Nessa situação, o valor esperado da diferença de perdas não seria zero e daí a necessidade de correção na estatística do teste.

<sup>17</sup> Chamando a previsão do modelo mais parcimonioso por  $\hat{y}_{1,t+1}$  e do modelo maior por  $\hat{y}_{2,t+1}$ , o diferencial da função de perda passaria a ser:  $\Delta L(\cdot) = (y_{t+1} - \hat{y}_{1,t+1})^2 - [(y_{t+1} - \hat{y}_{2,t+1})^2 - (\hat{y}_{1,t+1} - \hat{y}_{2,t+1})^2]$ . No artigo específico, o modelo da hipótese nula é um passeio aleatório sem constante, logo,  $\hat{y}_{1,t+1} = 0$ .

invertendo o sinal da estatística em relação ao teste de Diebold e Mariano (1995). Desse modo, a hipótese de igualdade de desempenho dos modelos é rejeitada se<sup>18</sup>  $\max_t W_{t,m}^{OOS} > k_\alpha$

Os resultados dos testes de Diebold e Mariano para diferentes tamanhos de amostra, dos testes de flutuação e a capacidade preditiva de outros fundamentos serão apresentadas a partir da próxima seção.

## Dados

A série referente à taxa de câmbio real por dólar estadunidense (BRL/USD) foi coletada no sítio do Banco Central do Brasil<sup>19</sup>, enquanto os dados referentes ao preço do barril de petróleo Brent e WTI foram extraídos do banco de dados do Federal Reserve de Saint Louis (FRED)<sup>20</sup>. Em razão dos fortes resultados encontrados por Ferraro, Rogoof e Rossi (2015), concentrou-se no presente estudo em testes com dados diários. O período utilizado foi de 01/02/1999 a 30/06/2019. Seguindo os trabalhos principais na área e ante a preocupação com a previsibilidade de curto prazo, analisa-se apenas previsões para um dia,  $h = 1$ . Apesar de existirem série de preços mais antigas, decidiu-se por iniciar-se a amostra no período em que a taxa de câmbio passou a ser flutuante - após o período de mini bandas que prevaleceu até o início de 1999, quando a crise cambial, com a respectiva queda nas reservas internacionais, levou a autoridade monetária a adotar o regime flutuante.

## Resultados

Os resultados a seguir acompanham a sequência dos principais testes apresentados por Ferraro, Rogoff e Rossi (2015)<sup>21</sup>.

### Modelo de Preço de *Commodity* (Petróleo)

---

<sup>18</sup> No artigo de Giacomini e Rossi (2010), a estatística aparece como  $\max_t m^{-1/2} W_{t,m}^{OOS} > k_\alpha$  em virtude de as autoras considerarem a razão entre a média e a variância da diferença entre os erros quadráticos para computar  $W$ . Para manter a notação do teste de Diebold e Mariano (1995), que já incorpora a divisão por  $m^{-1/2}$  na estatística, alteramos a representação em relação ao trabalho das autoras.

<sup>19</sup> Sítio na *Internet*: <<https://www.bcb.gov.br>>.

<sup>20</sup> Sítio: <<https://fred.stlouisfed.org>>.

<sup>21</sup> Com exceção dos que não seriam relevantes na discussão para o caso brasileiro, como o uso de periodicidade mensal e trimestral e anúncios macroeconômicos.

A Figura 01.01 apresenta os valores da estatística de Diebold e Mariano (1995) para diferentes janelas de estimação,  $R$ , variando de  $\frac{1}{2}$  a  $\frac{1}{20}$  da amostra total<sup>22</sup>, com o passeio aleatório e o passeio aleatório com constante como *benchmarks*<sup>23</sup>. A linha com círculos representa a estatística para o desempenho, medido pela diferença de EQM, do modelo de retorno no preço do barril de petróleo Brent como previsor do retorno do câmbio em relação ao modelo de passeio aleatório. Já a linha com losângulos traz os valores do teste para o modelo com retorno do petróleo em comparação com o *random walk* com *drift*. Caso a estatística esteja abaixo de -1,96, é significativa a 5% no teste bilateral, rejeitando-se a hipótese de igualdade de desempenho, concluindo-se que o modelo com o preço do petróleo apresenta previsões melhores do que o *benchmark*. Nota-se que, nas janelas apresentadas, o modelo de preço com petróleo supera o desempenho dos passeios aleatórios referenciais, em linha com os achados de Ferraro, Rogoff e Rossi (2015). Entretanto, percebe-se o aumento no valor da estatística conforme o valor de  $R$ , tamanho da amostra *in-sample*, diminui.

Indo além das janelas exploradas no artigo em questão, realizou-se o teste para tamanhos menores chegando-se a  $\frac{1}{100}$  da amostra total, com proporção crescendo na razão  $\frac{1}{10}$ . A Figura 1.02 apresenta os resultados do teste para essas janelas menores. Conforme se diminui o tamanho da amostra, a estatística passa a se aproximar do valor crítico de 5% e, para  $R = \frac{1}{90}$  ou  $\frac{1}{100}$ , já não se pode rejeitar a hipótese de equivalência das previsões dos modelos caso o *benchmark* seja o passeio aleatório sem constante. No caso, para a menor proporção analisada, ter-se-ia aproximadamente 50 observações na amostra de estimação. A questão é relevante, pois, na prática de mercados financeiros, é comum utilizarem-se, para dados diários, de janelas mais curtas como 20, 40 ou 60 observações, exatamente para captar movimentos mais recentes das séries. Assim, análise técnica de médias móveis curtas ou médias e estimativas de volatilidade baseadas em desvio-padrão utilizam-se de janelas com tamanhos nessa faixa de observações. Em situações nas quais há instabilidade de parâmetros, a previsão pode ser melhorada com a redução do tamanho da amostra, já que diminui-se o viés do estimador – i.e., coeficiente estimado aproximando-se mais do novo valor verdadeiro dos parâmetros –, mas às custas de um aumento na variância (ver a respeito Timmermann e Elliott

---

<sup>22</sup> Na presente análise  $R$  representa a proporção do tamanho da amostra usada na estimação em relação ao tamanho total da amostra  $T$ . Destoa-se da notação utilizada somente para manter facilitar comparações com o estudo de Ferraro, Rogoff e Rossi (2015). Na notação anterior, essa variável corresponderia a  $R/T$ .

<sup>23</sup> Nas figuras contendo os resultados dos testes, o eixo horizontal representa o tamanho da amostra e o eixo vertical corresponde aos valores da escala do teste. Para series temporais e para o teste de flutuação, o eixo horizontal traz as datas das observações.

(2016)). O valor da estatística do teste apresentou menor valor para amostras de  $R = 1/5$ , em torno de 1000 (mil) observações, o que corresponde a aproximadamente 4 anos de dados diários. Existe a possibilidade de essa queda no desempenho da previsão para uma amostra de estimação curta ter decorrido de instabilidades no período testado. A questão da instabilidade será abordada mais a frente.

O artigo de Ferraro, Rogoff e Rossi (2015) utiliza a série de preços do WTI. Para verificar a robustez dos resultados para a mudança no tipo de petróleo de Brent para referencial norte-americano, os teste foram refeitos com os preços do WTI e os resultados para  $R$  de  $1/2$  a  $1/20$  encontram-se na Figura 01.03, enquanto para janelas mais curtas para  $R$  de  $1/10$  até  $1/100$ , com fração aumentada por  $1/10$ , são apresentados na Figura 01.04. Pode-se notar que os resultados são consistentes, independente do tipo de petróleo usado como referencial.

A robustez do resultados também é verificada pelo teste de Clark e West (2006) – Tabela 01.01 - e, no mesmo sentido de Ferraro, Rogoff e Rossi (2005), mostram-se ainda mais fortes para capacidade preditiva, com P-valores de praticamente zero, rejeitando a igualdade de desempenho entre o modelo com preço de *commodity* e o *random walk* em favor da alternativa de melhor desempenho do modelo com petróleo como variável explicativa<sup>24</sup>.

---

<sup>24</sup> Os autores concluem que, como os testes de Clark e West foram mais significativos do que os de Diebold e Mariano para os tamanhos  $R$  dentro da amostra, o teste DM representaria um limite inferior (*lower bound*) conservador da evidência da capacidade relativa do modelo de preço de *commodity*. Na realidade, para efeitos práticos, no nosso caso, ao corrigir o viés decorrente da estimação do parâmetro desnecessário sob a hipótese nula, por meio da subtração desse termo do erro quadrático do modelo mais completo (hipótese alternativa), acaba-se por deslocar o equivalente a uma estatística  $t$  para cima, fortalecendo o resultado de superioridade da capacidade preditiva – recordando que o teste foi desenhado para rejeitar a nula se o valor encontrado no teste for positivo.

Figura 01.01 – Teste DM para Diferentes Tamanhos de Amostras




Figura 01.02 – Teste DM para Diferentes Tamanhos de Amostra (continuação)






Figura 01.03 – Teste DM para Diferentes Tamanhos de Amostra




Figura 01.04– Teste DM para Diferentes Tamanhos de Amostra (continuação)




Tabela 01.01 – Teste CW com Retorno do Petróleo como Regressor


<b>P-valores da Estatística do Teste de Clark e West (2006)</b>				
Tamanho da janela:	Modelo com Preço Contemporâneo		Modelo com Preço Defasado	
	Brent	WTI	Brent	WTI
1/2	0.000	0.000	0.365	0.042
1/3	0.000	0.000	0.394	0.037
1/4	0.000	0.000	0.336	0.045
1/5	0.000	0.000	0.297	0.060
1/6	0.000	0.000	0.398	0.095
1/7	0.000	0.000	0.399	0.089
1/8	0.000	0.000	0.317	0.167
1/9	0.000	0.000	0.378	0.095
1/10	0.000	0.000	0.398	0.081
1/11	0.000	0.000	0.398	0.068
1/12	0.000	0.000	0.395	0.111
1/13	0.000	0.000	0.357	0.162
1/14	0.000	0.000	0.358	0.202
1/15	0.000	0.000	0.370	0.177
1/16	0.000	0.000	0.347	0.240
1/17	0.000	0.000	0.313	0.317
1/18	0.000	0.000	0.253	0.384
1/19	0.000	0.000	0.338	0.345
1/20	0.000	0.000	0.304	0.332

### Modelo de Preço de *Commodity* Defasado

Como os analistas não conhecem o preço do petróleo no momento da previsão, dada a contemporaneidade do modelo da seção anterior, mais útil seria usar, para explorar ganhos com variações cambiais, se o modelo pudesse ser alimentado com dados defasados do regressor, o retorno do petróleo. Os resultados dos testes DM do desempenho Brent e do WTI em relação ao passeio aleatório sem constante (linhas com círculos) e com constante (linhas com losângulos) na previsão do câmbio estão representados nas Figuras 01.05 e 01.06, respectivamente. Assim como em Ferraro, Rogoff e Rossi (2015), o modelo com preço de petróleo defasado em um dia não apresentou capacidade preditiva melhor do que o *random walk*. Infere-se que os efeitos são de curtíssimo prazo, a ponto de não persistirem até o dia subsequente. Pelos valores da estatística de Diebold e Mariano, o passeio aleatório, tanto com quanto sem constante, apresentam capacidade preditiva superior ao modelo com preço da *commodity*,  $DM > 0$ , exceto quando o referencial de petróleo utilizado é o WTI e somente para janelas longas ( $R$  de  $\frac{1}{2}$  a  $\frac{1}{7}$  para o *random walk* com *drift* e  $R$  de  $\frac{1}{2}$  a  $\frac{1}{3}$  para o *random walk*),


resultando em valores da estatística DM negativos. No entanto, mesmo nos casos onde a capacidade preditiva do modelo com petróleo é superior, com DM negativo, não é estatisticamente significativa, i.e., inferior a -1,96, rejeitando-se que o modelo com *commodity* seja superior em termos preditivos ao passeio aleatório em qualquer de suas versões. Os P-valores da estatística de Clark e West (2016) encontram-se na Tabela 01.01. Ao contrário do teste DM, para janelas de  $\frac{1}{2}$  a  $\frac{1}{4}$  com o WTI, pode-se, ao nível de significância de 5% no teste unilateral, rejeitar a hipótese de igualdade da capacidade de previsão em favor do modelo de preços defasados<sup>25</sup>.

Figura 01.05– Teste DM para Diferentes Tamanhos de Amostra



<sup>25</sup> A esse respeito, Ferraro, Rogoff e Rossi (2015, p. 128) pronunciam-se nos seguintes termos: “It is clear that our results are extremely robust to the use of this alternative test statistics, which even find statistically significant predictive ability for large windows sizes for the daily model.”

Figura 01.06– Teste DM para Diferentes Tamanhos de Amostra



### Modelos com Fundamentos Econômicos: Diferencial de Taxa de Juros


Sabe-se da teoria econômica e de finanças que o câmbio deve, por argumentos de arbitragem, sofrer efeitos de alterações na taxa de juros doméstica e internacional. Isso porque, tudo o mais constante, aumentos na taxa interna deveriam estimular investimentos no Brasil para explorar o aumento no diferencial de juros, o que pressionaria a demanda por moeda nacional, elevando o seu valor relativo e causando a queda na relação real por dólar. Da mesma forma, elevações na taxa externa têm o condão de desvalorizar o real. A imensa literatura (ver Rossi (2013), que estudou essa relação após os estudos de Meese e Rogoff (1983 e 1988)) não encontrou evidência de que o diferencial de juros explicasse variações no câmbio<sup>26</sup>. Para analisar essa questão de fundamentos efetuam-se os testes de Diebold e Mariano no modelo com diferencial de taxa juros contemporâneo e defasado em um período. Os dados diários referentes aos juros domésticos, a Selic efetiva, foram extraídos da página do Banco Central do

<sup>26</sup> O modelo com preço de *commodity* representa, na prática, a troca de um modelo com fundamento estabelecido na teoria, o de diferencial de juros, por outro em que o fundamento passaria a ser o preço do petróleo ou outro bem transacionado internacionalmente.

Brasil. Já para os juros externos, utilizou-se a taxa efetiva dos Fed Funds disponibilizada no FRED. Utilizou-se o período entre 05 de março de 1999 a 30 de agosto de 2019<sup>27</sup>.

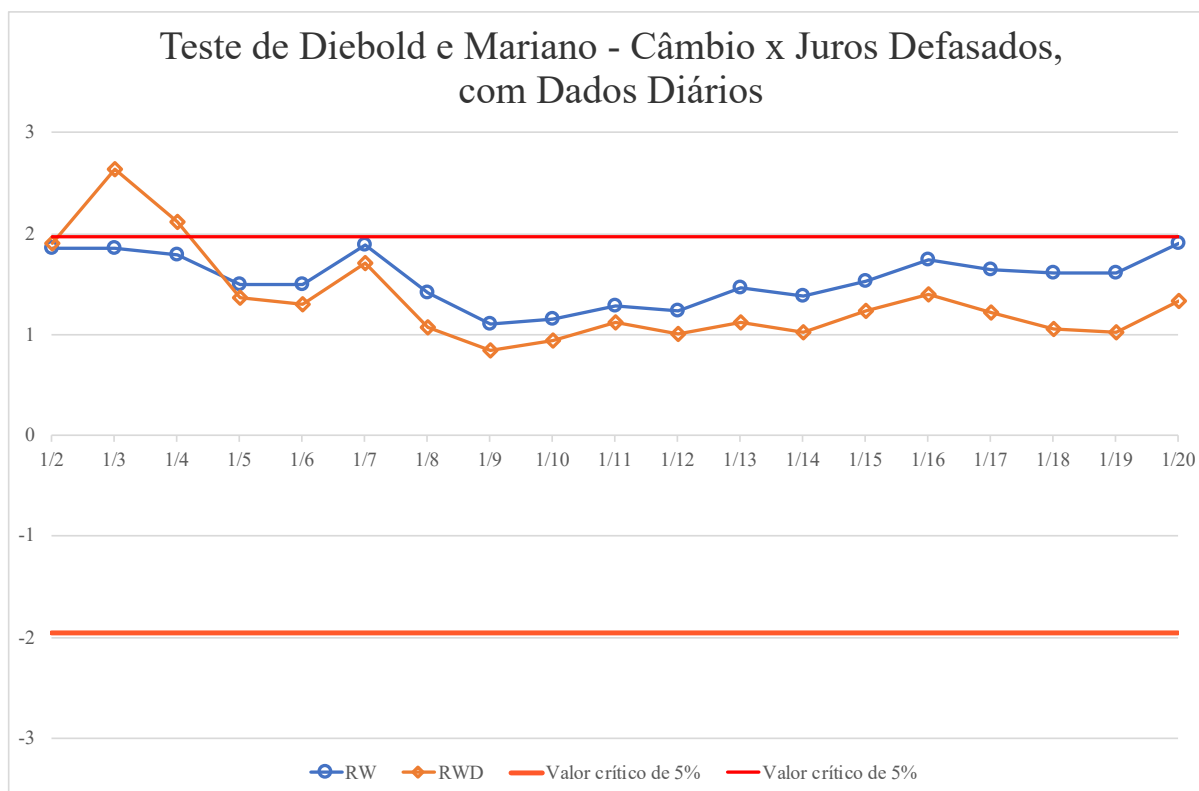
As Figuras 01.07 e 01.08 apresentam os resultados do teste de Diebold e Mariano (1995) para diferentes tamanhos de janela dentro da mostra, de  $\frac{1}{2}$  a  $\frac{1}{20}$  da amostra total nos modelos de diferencial de juros e de diferencial de juros defasado, respectivamente. Sobressai que, para nenhuma janela, o modelo de diferencial de juros tem desempenho superior ao passeio aleatório sem constante (linhas com círculos) e com constante (linhas com losângulos). De fato, para janelas com tamanho  $\frac{1}{3}$  e  $\frac{1}{4}$ , o passeio aleatório com *drift* apresentou performance melhor do que a do modelo com fundamento de diferencial de juros.

Figura 01.07– Teste DM para Diferentes Tamanhos de Amostra



<sup>27</sup> Como os retornos foram calculados em por meio da diferença de logaritmos, aplicou-se nos juros a transformação contínua  $\ln(1+i)$  onde  $i$  é a taxa de juros diária. No caso brasileiro  $i = (1+I)^{1/252} - 1$  e, no norte-americano,  $i=I/360$ , onde  $I$  é a taxa reportada.

Figura 01.08– Teste DM para Diferentes Tamanhos de Amostra



### Teste de Flutuação

A instabilidade tanto das séries quanto das relações e parâmetros estimados, especialmente na presença de choques como os observados nos mercados cambiais, e, mormente, do petróleo levaram Ferraro, Rogoff e Rossi (2015) a aplicar o teste de flutuação de Giacomini e Rossi (2010)<sup>28</sup> descrito no capítulo anterior. O objetivo é analisar a estabilidade da capacidade preditiva ao longo do período. Para avaliar a possível instabilidade no desempenho relativo do modelo com preço do petróleo em relação ao passeio aleatório na previsão do câmbio, foi implementado o teste de flutuação do modelo com petróleo em relação ao passeio aleatório sem e com constante. A proporção  $R$  usada foi de  $\frac{1}{2}$  e o tamanho da amostra  $m$  foi de 500 observações diárias. As Figuras 01.09 e 01.10 apresentam a evolução do teste DM usando o preço do Brent e do WTI, respectivamente. Para a maior parte do período entre abril de 2009

<sup>28</sup> Ferraro, Rogoff e Rossi (2015), ao aplicar o teste de flutuação, ao contrário do preconizado por Giacomini e Rossi (2010), não centram a estatística do teste e, por isso, ao concluírem que a partir de 2005 o desempenho relativo do modelo do *commodities* é superior, em linha com o fato de o Canadá ter se transformado em exportador líquido de petróleo em meados da década de 1990, equivaleria, no teste original, a deslocar a estatística em um ano para trás, i.e., para 2004, pois os autores usam janelas fora da amostra de 500 observações diárias.

e até meados de 2016, o modelo com preço de petróleo teve desempenho melhor do que os passeios aleatórios, em razão de a estatística DM ter apresentado valores negativos. As marcas em cruz na reta com o valor crítico indicam que a estatística foi significativa para o período, i.e., menor do que -1,96, do início do período (centralizado) testado - abril de 2009 - até o final de 2011, aproximadamente. Isso equivale a dizer que, com dados até o final de 2012, houve superioridade preditiva.

Figura 01.09 – Teste de Flutuação de Giacomini e Rossi (Estatística DM)





Figura 01.10 – Teste de Flutuação de Giacomini e Rossi (Estatística DM)



### Desempenho Dentro da Amostra Total

Uma vez verificada a capacidade do modelo para a mostra de previsão  $P$ , o ajuste do modelo com preço de petróleo contemporâneo para o período total  $T$  da amostra é apresentado na Tabela 01.02 abaixo. Nota-se que, tanto para o Brent quanto para o WTI, o coeficiente  $\alpha$  não é significativo, mas a estimativa de  $\beta$  é altamente significativa. O  $R^2$  é maior quando se utiliza a série de preços de WTI do que a série do petróleo Brent.

Tabela 01.02 -

<u>Ajuste <i>in-sample</i> do modelo com petróleo</u>		
<u>Coefficiente</u>	<u>Estimado</u>	<u>Estat. <i>t</i> robusta</u>
Brent		
$\alpha$	0.000	1.174
$\beta$	-0.077	-8.162
$R^2$		0.032
WTI		
$\alpha$	0.000	1.133
$\beta$	-0.077	-7.659



$$\frac{R^2}{0.036}$$

### Alteração dos Fundamentos: Soja, Ouro e Cobre

A hipótese central de Ferraro, Rogoff e Rossi (2015) é de que o preço do principal produto de exportação do país ajuda na previsão do câmbio local. Entretanto, os próprios autores reconhecem que outras *commodities* que não são o principal item da pauta de comércio apresentaram poder preditivo, como o ouro para o Canadá e para a Noruega. Por isso, chegam a afirmar que, apesar de isso não eliminar explicações baseadas em termos de troca, também não podem excluir explicações decorrentes de motivos de rebalanceamento ou choques comuns não observáveis.

Para avaliar se a substituição de fundamentos, no caso, petróleo, por outro item importante das exportações brasileiras, como a soja, ou com menor peso na balança de comércio, como o ouro e o cobre, produziria capacidade preditiva superior ao *random walk*, repetiu-se os testes DM para essas *commodities*. Os dados de preços internacionais de soja e do cobre foram obtidos no sítio da Macrotrends<sup>29</sup>. Já os preços do ouro foram extraídos do FRED. Os dados referentes ao preço de cobre e do ouro abrangem o período de 01 de fevereiro de 1999 a 28 de junho de 2019. Para a soja, a amostra total inicia-se em 01 de julho de 1999. No caso do cereal, cujo retorno no preço serviu como variável explicativa para o retorno do câmbio, foram efetuados os testes de DM para tamanhos de amostra, em proporção da amostra total, diferentes, de  $\frac{1}{2}$  a  $\frac{1}{20}$  (Figura 01.11), e até  $\frac{1}{100}$  (Figura 01.12), teste de flutuação de Giacomini e Rossi (Figura 01.13), e de cointegração (Figura 01.14). O padrão dos resultados é semelhante aos obtidos com o petróleo como regressor. Para o teste de flutuação, o desempenho superior da soja ocorreu até o final do período de 2 anos centrado em 2010.

No caso do ouro, o desempenho preditivo superior do modelo de *commodity* em relação ao passeio aleatório com constante (linhas com losângulos) e sem constante (linhas com círculos) persistem para proporção de tamanho amostra de estimação de  $\frac{1}{12}$  e de  $\frac{1}{18}$ , respectivamente, conforme pode ser observado na Figura 01.15.

Por fim, caso o cobre seja a *commodity* a ser usada no modelo, os resultados são bem fortes em favor da capacidade preditiva do modelo com o preço contemporâneo do metal (Figura 01.16). Ressalta-se que, assim como o ouro, cobre não se encontra nos itens de

<sup>29</sup> Sítio: <<https://www.macrotrends.net>>.

principais produtos exportados pelo país. A Tabela 01.03<sup>30</sup> contém as participações percentuais e posição relativa (*ranking*) de alguns itens<sup>31</sup> da pauta de exportação brasileira em termos de valores relacionados à *commodities* utilizadas no presente estudo, trazendo o bem na forma bruta, alguns derivados e outros fortemente relacionados, como o etanol, entre 1999 e 2018.

Tabela 01.03

Item	Ano					Média
	2018	2014	2009	2004	1999	
<b>Participação nas Exportações Totais</b>						
Soja mesmo triturada	13.8%	10.3%	7.5%	5.6%	3.3%	7.0%
Óleos brutos de petróleo	10.6%	7.3%	6.0%	2.6%	0.0%	5.2%
Farelo e resíduos da extração de óleo de soja	2.8%	3.1%	3.0%	3.4%	3.1%	2.8%
Óleos combustíveis (óleo diesel,fuel-oil, etc.)	1.2%	1.5%	1.3%	1.2%	0.4%	1.2%
Minérios de cobre e seus concentrados	1.1%	0.8%	0.5%	0.2%	0.0%	0.5%
Ouro em formas semimanufaturadas,para uso não monetário	0.8%	0.7%	0.9%	0.4%	0.7%	0.7%
Polímeros de etileno, propileno e estireno	0.7%	0.9%	0.9%	0.7%	0.6%	0.8%
Gasolina	0.3%	0.1%	0.6%	0.6%	0.4%	0.5%
Etanol	0.4%	0.4%	0.9%	0.5%	0.1%	0.6%
Óleo de soja em bruto	0.4%	0.4%	0.7%	1.2%	1.2%	0.7%
Hidrocarbonetos e seus derivados halogenados, etc.	0.3%	0.5%	0.5%	0.5%	0.5%	0.5%
Cobre, em barras, perfis, fios, chapas, folhas e tiras	0.2%	0.1%	0.1%	0.2%	0.2%	0.2%
Catodos de cobre	0.1%	0.1%	0.3%	0.1%	0.1%	0.2%
Coque, betume e outros resíduos de óleo de petróleo	0.1%	0.1%	0.0%	0.0%	0.0%	0.1%
Óleos lubrificantes	0.0%	0.1%	0.0%	0.0%	0.0%	0.0%
Proteínas de soja, peptonas e seus derivados	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
<b>Ranking nas Exposições Totais</b>						
Soja mesmo triturada	1	2	2	1	4	
Óleos brutos de petróleo	2	3	3	6	381	
Farelo e resíduos da extração de óleo de soja	5	5	6	5	5	
Óleos combustíveis (óleo diesel,fuel-oil, etc.)	17	14	17	22	55	
Minérios de cobre e seus concentrados	19	28	43	90	400	
Ouro em formas semimanufaturadas,para uso não monetário	26	32	25	54	32	
Polímeros de etileno, propileno e estireno	28	25	24	38	39	
Gasolina	58	102	38	45	47	
Etanol	48	50	27	46	102	
Óleo de soja em bruto	46	46	36	25	25	
Hidrocarbonetos e seus derivados halogenados, etc.	60	39	45	51	40	
Cobre, em barras, perfis, fios, chapas, folhas e tiras	81	90	128	85	88	
Catodos de cobre	89	87	64	179	174	
Coque, betume e outros resíduos de óleo de petróleo	91	110	177	264	285	
Óleos lubrificantes	162	133	197	251	278	
Proteínas de soja, peptonas e seus derivados	204	310	307	246	254	

Fonte: Elaboração própria com dados do MDIC/Ministério da Economia

<sup>30</sup> A base de dados encontra-se em: <<http://www.mdic.gov.br/index.php/comercio-exterior/estatisticas-de-comercio-exterior/base-de-dados-do-comercio-exterior-brasileiro-arquivos-para-download>>.

<sup>31</sup> Omitiram-se itens com participações insignificantes no período.

Figura 01.11 - Teste DM para Diferentes Tamanhos de Amostra




Figura 01.12 - Teste DM para Diferentes Tamanhos de Amostra




Figura 01.13 – Teste de Flutuação de Giacomini e Rossi (Estatística DM)

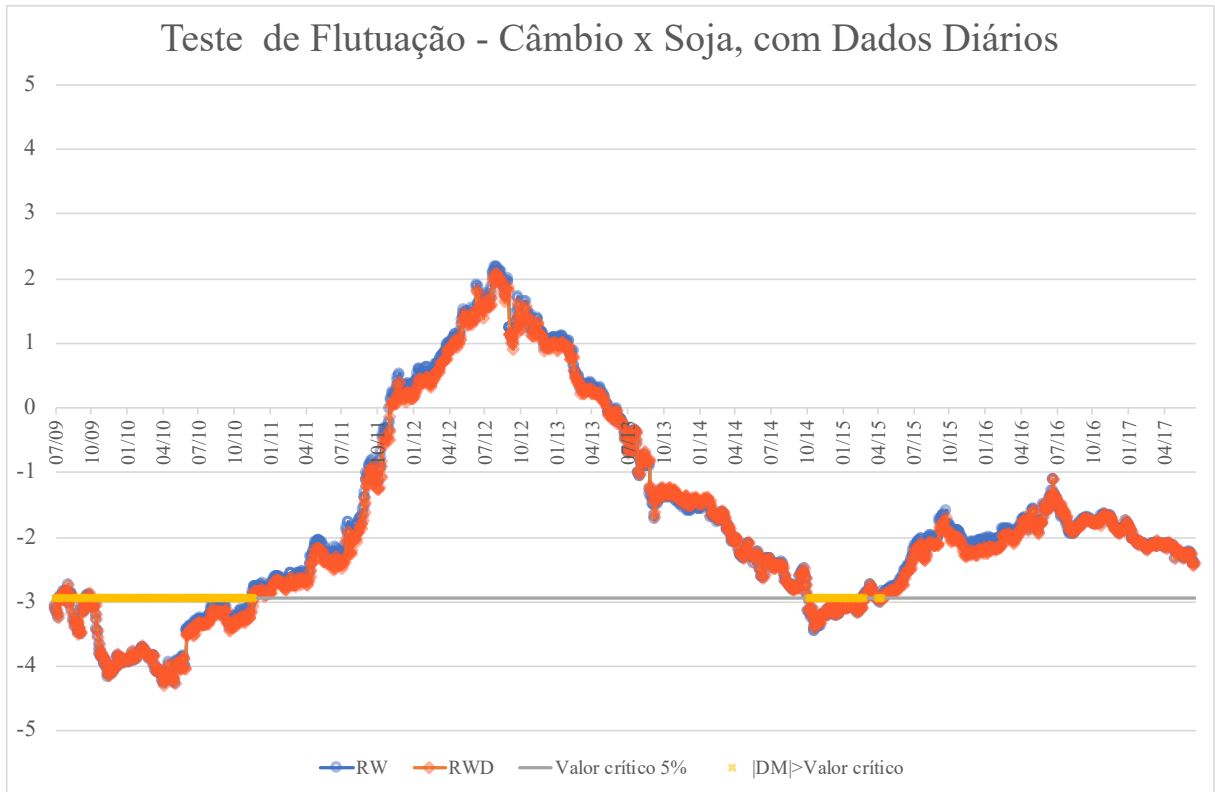


Figura 01.14 Teste DM (Cointegração com soja) para Diferentes Tamanhos de Amostra




Figura 01.15 – Teste DM para Diferentes Tamanhos de Amostra





Figura 01.16 – Teste DM para Diferentes Tamanhos de Amostra



Em resumo, dentre os resultados obtidos para o caso brasileiro acerca da previsibilidade usando o preço do petróleo, destacam-se: (a) ocorre para períodos muito curtos, no sentido de ser significativa e robusta para dados diários contemporâneos, mas não, defasados; (b) não é observada para outros fundamentos econômicos tradicionalmente vistos na teoria, como o diferencial entre a taxa de juros doméstica e externa; (c) é muito estável, no sentido de que não depende do tamanho da amostra para frações menores da amostra total, e é confirmado por testes de flutuação, com desempenho relativo variando ao longo do período de previsão; (e) encontra-se tanto fora da amostra (*out-of-sample*) como dentro da amostra total (*in-sample*); (f) é observado para outros “fundamentos” como soja, ouro e cobre.

## Conclusão

Apesar de os resultados serem muito similares aos encontrados por Ferraro, Roggoff e Rossi, parece-nos que o argumento de que “o preço da principal *commodity* de exportação de um país pode prever movimentos em sua taxa de câmbio nominal num exercício de pseudo previsão fora da amostra”, justificado pelo fato de que, numa economia aberta pequena que exporta *commodities*, a taxa de câmbio reflete movimentos nos preços desses produtos de forma imediata, não está totalmente correto. Isso porque não foi somente o principal produto – soja - da atual pauta de exportação do Brasil que explica o câmbio, mas itens como o cobre, que tem pouco peso no comércio exterior do país, também apresentaram capacidade preditiva superior ao passeio aleatório. Ademais, o Brasil não pode ser considerado um país com tradição de câmbio flutuante, apesar de no período analisado, ter sido estabelecido um regime de flutuação com intervenções da autoridade monetária sob pretexto de reduzir a volatilidade, e, tampouco, uma economia aberta, em termos de comércio exterior, pequena, mesmo sendo um *price taker* no mercado de petróleo. O outro argumento aventado de rebalanceamento também não parece prosperar, já que o país passou por diferentes políticas fiscais e monetárias, com grande oscilação no risco país, com períodos de crescimento positivo e negativo, descoberta de reservas de petróleo e instabilidade política, com troca de governantes, e mesmo assim, o preço, em moeda estrangeira, de *commodities* ajudou a explicar o câmbio. A causa mais provável é a de haver um fator estocástico comum influenciando em diversas variáveis do lado real a nível mundial, refletindo nos preços - tanto das *commodities* quanto da moeda local – que são variáveis nominais e, portanto podem oscilar rapidamente - ao contrário de *quantum* reais - de forma imediata por meio de expectativas. Em todo o caso, para efeito de previsão, confirmou-se,

derradeiramente, que o petróleo, assim como outros bens transacionados internacionalmente, apresenta(m) capacidade preditiva na taxa de câmbio real por dólar americano.

## CAPÍTULO 2

O capítulo anterior concluiu que o preço do petróleo apresentou capacidade preditiva sobre o câmbio a nível diário. Além disso, verificou-se que o resultado independia se o preço do barril de petróleo utilizado era o Brent ou o WTI e que possivelmente haveria uma força comum por trás de diversas variáveis. O presente capítulo irá analisar a relação entre os preços de três referenciais de petróleo com dados mensais, os dois mencionados mais o Dubai, e se há estabilidade entre eles. A questão do fator comum também será tratada. Por fim, aborda-se a formação de preços do diesel com base no câmbio e no preço do petróleo. Antes, serão apresentados os conceitos econométricos associados aos testes que ainda não foram utilizados.

### Conceitos e Testes

#### Estacionariedade

Definição:  $y_t$  é (fracamente) estacionário se

- a)  $E(y_t) = \mu$ , para todo  $t$ ,
- b)  $E(y_t - \mu)^2 = \sigma^2 < \infty$ , para todo  $t$ , e
- c)  $E(y_t - \mu)(y_{t-j} - \mu) = \gamma_j$ , para todo  $t$  e  $j$ .

Ou seja, tanto a média de  $y_t$  quanto a variância ( $\gamma_0$ ) são constantes (independem de  $t$ ), assim como as covariâncias de ordem  $j$ . Assim,  $\gamma_j$  dependem apenas da distância  $j$  entre as observações e não da data  $t$ . Um processo fracamente estacionário também é chamado de covariância estacionário, estacionário de segunda ordem ou estacionário em sentido amplo (*latu sensu*).

Um exemplo de modelo estacionário é autorregressivo de ordem ( $p$ ), ou  $AR(p)$ , que descreve uma variável  $Y$  como uma função de seus últimos  $p$  valores passados a essa data  $t$ ,

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + u_t,$$

onde  $u_t$  é um ruído branco *i.i.d.*(0,  $\sigma^2$ ).

A sigla *i.i.d.* (0,  $\sigma^2$ ) representa que a variável é independente e identicamente distribuída, com média 0 e variância  $\sigma^2$ , constante, ou seja, o valor de  $u$  observado em  $t$  não afeta os valores de nenhum outro período e a variável apresenta distribuição idêntica em



qualquer data. Para que o modelo seja fracamente estacionário<sup>32</sup>, as raízes do polinômio  $1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p$  devem encontrar-se fora do círculo unitário. Para um AR(1), basta o valor absoluto de  $\phi_1$  ser inferior a 1 para  $Y$  ser estacionário. Se o parâmetro for 1, o processo apresenta uma raiz unitária e é não estacionário. A previsão de um modelo AR(1) é dada por  $\Delta \hat{Y}_{t+1} = \hat{\phi}_0 + \hat{\phi}_1 Y_t$ .

## Teste de Raiz Unitária

### *Dickey-Fuller*

Os testes de Dickey e Fuller foram desenvolvidos por Fuller (1976) e Dickey e Fuller (1979 e 1981) com o objetivo de testar a existência de raiz unitária nas séries.

### *Teste $\tau$*

O teste analisa a série AR(1) sem constante e sem tendência determinista

$$y_t = \rho y_{t-1} + u_t,$$

com  $u_t \sim iidN(0, \sigma^2)$ , para  $t = 1, 2, \dots, T$ .

Denotando  $\gamma = \rho - 1$ :

$$\Delta y_t = \gamma y_{t-1} + u_t.$$

A raiz unitária corresponde ao caso  $\rho = 1$  ou  $\gamma = 0$ . Assim, para testar a hipótese existência de raiz unitária, deve-se verificar se  $\gamma$  é estatisticamente diferente de zero. O usual seria recorrer ao teste  $t$  ou Normal para verificar a significância do parâmetro. O problema é que, caso a série tenha raiz unitária, a estatística não segue uma distribuição padrão como as duas citadas. Por meio de simulações de Monte Carlo, Dickey e Fuller construíram uma tabela de valores críticos apropriados para diferentes tamanhos de amostra. A hipótese nula do teste corresponde à existência de raiz unitária, i.e.,  $H_0: \gamma = 0$  (ou  $\rho = 1$ ). Já a hipótese alternativa é

---

<sup>32</sup> Ver a respeito Hamilton (1994).

$H_a: \gamma < 0$  (ou  $\rho < 1$ ), pois no caso de  $\gamma > 0$  ( $\rho > 1$ ) a série apresentaria comportamento explosivo e não seria estacionária. Por isso, a raiz unitária somente será rejeitada se o valor calculado da estatística  $\tau$  abaixo for inferior ao valor crítico. A estatística, calculada com a mesma fórmula de um teste  $t$ , é dada por

$$\tau = \frac{\hat{\gamma}}{s_{\hat{\gamma}}}$$

onde  $\tau$  é a estatística de Dickey e Fuller,  $\hat{\gamma}$  representa a estimativa de  $\gamma$ , e  $s_{\hat{\gamma}}$  corresponde ao erro padrão da estimativa de  $\gamma$ .

#### Teste $\tau_{\mu}$

O teste é aplicável para série AR(1) com constante e sem tendência determinista

$$y_t = \mu + \rho y_{t-1} + u_t,$$

com  $u_t \sim iidN(0, \sigma^2)$ , para  $t = 1, 2, \dots, T$ .

Alternativamente,

$$\Delta y_t = \mu + \gamma y_{t-1} + u_t.$$

Ainda neste caso, a raiz unitária equivale a  $\rho = 1$  ou  $\gamma = 0$ . Assim, da mesma forma, para se verificar a presença de raiz unitária, deve-se testar se  $\gamma$  é menor do que zero na equação. Como no teste anterior, caso a série tenha raiz unitária, a estatística não segue uma distribuição padrão e os valores críticos foram obtidos por meio de simulações. A hipótese nula  $H_0$  do teste é de existência de raiz unitária, i.e.,  $\gamma = 0$  (ou  $\rho = 1$ ) e a hipótese alternativa é  $H_a: \gamma < 0$  ( $\rho < 1$ ). A regra de decisão continua sendo rejeitar a hipótese nula somente se o valor calculado da estatística  $\tau_{\mu}$  for inferior ao valor crítico da tabela.

$$\tau_{\mu} = \frac{\hat{\gamma}}{s_{\hat{\gamma}}}.$$

Deve-se notar que os valores críticos foram encontrados simulando um passeio aleatório sem constante. Uma pergunta natural é se a tabela ainda seria válida caso o processo verdadeiro que gerou os dados seja um passeio aleatório com constante. Pode-se mostrar que, caso  $\mu \neq 0$ , então, a estatística converge em distribuição para uma Normal, e, deste modo, pode-se utilizar a tabela Normal para testar a significância do  $\gamma$ . No entanto, para amostras finitas, a distribuição da estatística depende do valor de  $\mu/\sigma$ . Quanto maior  $\mu/\sigma$ , mais os valores críticos se aproximam de uma Normal e, quanto menor  $\mu/\sigma$ , mais se aproximam dos valores críticos de Dickey e Fuller.

Além disto, como a regressão do teste  $\tau_\mu$  apresenta uma constante a ser estimada, os valores críticos são, para um mesmo tamanho de amostra e um dado nível de significância, inferiores aos valores críticos para o teste  $\tau$ , isto é,  $\tau_\mu < \tau$ .

É comum, atualmente, o uso dos valores críticos encontrados por meio da superfície de resposta de MacKinnon (1991), que dá os valores críticos para qualquer tamanho de amostra, dados os níveis de significância e os termos deterministas do teste.

#### *O Teste de Dickey-Fuller Aumentado -- ADF*

A observação de que os resíduos da regressão de Dickey e Fuller não se comportavam em muitos casos como um ruído branco, fez com que fosse feita uma modificação nos testes, a fim de eliminar a autocorrelação comumente existente. Como a série  $y$  pode na verdade ser um processo<sup>33</sup> AR, MA ou ARMA, a inclusão de  $p$  defasagens da variável dependente  $\Delta y$  amenizaria o problema, já que pode-se mostrar que um processo ARMA pode ser representado por um  $AR(\infty)$  e ser aproximado por um  $AR(p)$  com defasagem  $p$  eventualmente grande, mas finito:

$$\Delta y_t = \gamma y_{t-1} + \sum_{i=1}^p \beta_i \Delta y_{t-i} + u_t$$

$$\Delta y_t = \mu + \gamma y_{t-1} + \sum_{i=1}^p \beta_i \Delta y_{t-i} + u_t$$

---

<sup>33</sup> Por não se estimar modelos de médias móveis (MA) ou autorregressivo com médias móveis, não apresentaremos esses modelos.

$$u_t \sim iidN(0, \sigma^2), \text{ para } t=1, 2, \dots, T.$$

Os testes de raiz unitária ADF acima correspondem aos testes  $\tau$ , e  $\tau_\mu$ , respectivamente, “aumentados” de  $p$  defasagens da variável dependente. Apesar de haver variáveis a mais nas regressões, o valor calculado das estatísticas  $\tau$ 's continua sendo computado da mesma forma e as mesmas tabelas podem ser utilizadas, desde que  $p$  não seja grande em relação ao tamanho da amostra  $T$ . A significância dos parâmetros  $\beta$ 's pode ser testada, para amostras grandes, pelos testes  $t$  e  $F$  tradicionais. Em geral, o nível de significância usado para as defasagens é maior do que nos testes tradicionais (p.e., 10%).

Como o valor de  $p$  não é conhecido *a priori*, um procedimento é fixar um  $p$  máximo,  $p_{\max}$ , e, a partir daí, reduzir as defasagens uma a uma, ou até conjuntamente, aplicando testes  $t$  sequenciais ou  $F$ . No primeiro caso, começa-se com  $p_{\max}$  e verifica-se se essa defasagem é significativa. Caso não seja, reduz-se  $p$  em uma defasagem e testa-se a significância desta. O procedimento é repetido até encontrar-se uma defasagem significativa. Na situação de nenhuma ser estatisticamente diferente de zero, não se incluem defasagens na regressão do teste, recaindo-se no teste de Dickey-Fuller original. Outra alternativa, consiste em usar critérios de informação como o de Akaike, Schwartz ou Hannan-Quinn (ou versões modificadas delas), escolhendo-se a especificação com número de defasagens que minimize esse critério.

Um critério de escolha de  $p_{\max}$ , proposto por Schwert, é

$$p_{\max} = \text{int} [12(T/100)^{1/4}],$$

onde  $\text{int} [x]$  é a parte inteira do número  $x$ .

Já critérios de informação recaem em problemas de selecionar o modelo que minimize funções da seguinte forma

$$IC(k) = -2T^{-1} \ln p(\hat{\beta}_k | z) + h(n_k) g(T),$$

onde  $p(\hat{\beta}_k | z)$  é a verossimilhança dos dados com os parâmetros estimados<sup>34</sup>,  $h(n_k)$  é uma função crescente que penaliza o número de parâmetros do modelo,  $n_k$ , e  $g(T)$  é uma função decrescente

---

<sup>34</sup> Nas aplicações, a verossimilhança é substituída pela soma dos quadrados dos resíduos.

do tamanho da amostra,  $T$ . O critério de Schwartz ou Bayesiano, denominado de BIC, usa  $h(n_k) = n_k$  e  $g(T) = \ln(T)/T$ . Já o critério de Akaike, ou AIC, tem  $h(n_k) = n_k$  e  $g(T) = 2/T$ .

### O Teste Phillips e Perron

O teste de Phillips e Perron (1988) também corrige o problema de autocorrelação dos erros da regressão de Dickey-Fuller. Mas, ao contrário do teste ADF, que aproxima um processo ARMA( $p, q$ ) por um AR( $p$ ), o teste lida com a autocorrelação (e possível heterocedasticidade) modificando de forma não-paramétrica a estatística  $t$ . As estatísticas do teste para os dois casos são as seguintes:

(a) sem constante

$$Z_t = \frac{s_e}{s_{T_\ell}} t - \frac{1}{2} \frac{s_{T_\ell}^2 - s_e^2}{s_{T_\ell} (T^{-2} \sum_{t=1}^T y_{t-1}^2)^{1/2}}$$

(b) com constante

$$Z_t = \frac{s_e}{s_{T_\ell}} t - \frac{1}{2} \frac{s_{T_\ell}^2 - s_e^2}{s_{T_\ell} [T^{-2} \sum_{t=1}^T (y_{t-1} - \bar{y}_{-1})^2]^{1/2}}$$

com  $\bar{y}_{-1} = T^{-1} \sum_{t=1}^{T-1} y_t$ .

Os valores críticos para os testes  $Z_t$  são os mesmos dos testes  $t$ 's de Dickey e Fuller. Em geral, como estimador consistente de  $s_e^2$  é utilizado  $\hat{s}_e^2 = T^{-1} \sum_{t=1}^T e_t^2$  e, para a variância na presença de autocorrelação, é utilizado o estimador de Newey e West, também conhecido como estimador do espectro na frequência zero ou soma de covariância,

$$\tilde{s}_{T_\ell} = T^{-1} \sum_{t=1}^T \epsilon_t^2 + 2T^{-1} \sum_{i=1}^{\ell} \omega_i \sum_{t=i+1}^T \epsilon_t \epsilon_{t-i}$$

onde  $\omega_i = 1 - i/(\ell + 1)$  representa o peso da autocovariância de ordem  $i$ , estrutura essa conhecida como triangular ou de Bartlett. A vantagem é que os pesos definidos dessa forma garantem que a variância será não negativa.

Para escolher o parâmetro de truncamento de defasagens  $\ell$  é comum utilizar-se

$$\ell = \text{int}[(4 \cdot T/100)^{2/9}].$$

Note que, se não há autocorrelação,  $\hat{s}_\epsilon^2 = \hat{s}_\rho^2$ , e a estatística  $Z_t$  coincide com a  $\tau$  de Dickey e Fuller. Uma vantagem do teste de Phillips e Perron em relação ao teste ADF é que ele é robusto também para a presença de heterocedasticidade.

Como regra, os testes ADF e PP tem baixo poder, este definido como  $1-P$ , ou erro tipo II, i.e., aceita-se, com frequência maior do que esperada,  $H_0$  quando ela é falsa em relação à alternativa verdadeira que seja próxima à raiz unitária, por exemplo,  $\rho = 0,95$ . O poder do teste ainda é comprometido pela presença de termos deterministas como uma constante  $\mu$ . Além disso, simulações mostram que em séries integradas com componente MA da forma  $y_t = y_{t-1} + \epsilon_t + \theta\epsilon_{t-1}$ , com  $\theta$  próximo de -1, os testes de raiz unitária rejeitam, com frequência maior do que a esperada,  $H_0$ , quando, de fato, há uma raiz unitária. Para testes com maior poder contra alternativas próximas a 1, e menos sensíveis a termos deterministas, foram elaborados testes como os de Elliot, Rothenberg e Stock (1996) e Ng e Perron (2001).

### Os testes de Elliot, Rothenberg e Stock (ou ADF-GLS)

O teste ADF-GLS de Elliot, Rothenberg e Stock (1996) inicia-se fixando a alternativa pontual  $\bar{\rho} = 1 + \bar{c}/T$ . A partir desse valor de  $\bar{\rho}$ , transformam-se as variáveis  $y$  e o regressor determinista 1, aplicando uma quase-diferenciação:

$$\begin{aligned} y_{\bar{\rho}} &= (y_1, y_2 - \bar{\rho}y_1, y_3 - \bar{\rho}y_2, \dots, y_T - \bar{\rho}y_{T-1})' \\ 1_{\bar{\rho}} &= (1, 1 - \bar{\rho} \cdot 1, 1 - \bar{\rho} \cdot 1, \dots, 1 - \bar{\rho} \cdot 1)' \\ t_{\bar{\rho}} &= (1, 2 - \bar{\rho} \cdot 1, 3 - \bar{\rho} \cdot 2, \dots, T - \bar{\rho} \cdot (T - 1))' \end{aligned}$$

Note que a primeira observação não é transformada. Se existe a constante, deve-se fixar  $\bar{c} = -7$ .

Agora, deve-se regredir a variável transformada  $y_{\bar{\rho},t}$  contra os elementos deterministas (constante) quase-diferenciados:

$$y_{\bar{\rho},t} = \beta_{\bar{\rho},0} \cdot 1_{\bar{\rho}} + \hat{\beta}_{\bar{\rho},1} \cdot t_{\bar{\rho}}$$

Com os parâmetros estimados  $\widehat{\beta}_{\bar{\rho}}$ , "destendenciar" (extrair a tendência) por GLS a série original  $y_t$ , de forma a obter a nova série  $y_t^d$ :

$$y_t^d = y_t - \hat{\beta}_{\bar{\rho},0} - \hat{\beta}_{\bar{\rho},1} \cdot t.$$

Por último, deve-se fazer a regressão ADF sem constante na variável "destendenciada" por GLS<sup>35</sup>:

$$\Delta y_t^d = \gamma y_{t-1}^d + \sum_{i=1}^p \beta_i \Delta y_{t-i}^d + \epsilon_t,$$

e testar de  $H_0: \gamma = 0$ .

Se a transformação foi feita considerando a existência apenas da constante (i.e.,  $\bar{c} = -7$ ), pode-se utilizar os valores críticos da distribuição de Dickey e Fuller.

#### *Teste Ótimo no Ponto*

Elliot, Rothemberg e Stock (1996) também propuseram um teste assintoticamente ótimo para a alternativa pontual  $\bar{\rho} = 1 + \bar{c}/T$  com base nas variáveis transformadas  $y_{\bar{\rho}}$ ,  $1_{\bar{\rho}}$  e  $t_{\bar{\rho}}$ . São realizadas duas regressões, uma com as variáveis quase-diferenciadas (usando  $\bar{\rho}$ ) descritas e outra com  $\rho = 1$ . A estatística do teste é dada por

$$P_T = \frac{S(\bar{\rho}) - \bar{\rho}S(1)}{\hat{s}_{AR}^2},$$

com<sup>36</sup>

<sup>35</sup> A sigla GLS vem da expressão em inglês *generalized least squares*, ou mínimos quadrados generalizados, método que inspirou a transformação utilizada.

<sup>36</sup> A fórmula do estimador para a variância de longo prazo pode ser empregada no lugar do estimador de Newey e West para qualquer teste que utilize o espectro na frequência zero.

$$\hat{S}_{AR}^2 = \frac{\widehat{\sigma}_p^2}{(1-\widehat{\alpha}(1))^2},$$

onde  $S(\rho)$  é a soma dos quadrados dos resíduos,  $\widehat{\sigma}_p^2 = (T-p)^{-1} \sum_{t=p+1}^T \widehat{\epsilon}_t^2$  e  $\widehat{\alpha}(1) = \sum_{i=1}^p \widehat{\alpha}_i$  são computados na regressão por mínimos quadrados<sup>37</sup>.

$$\Delta y_t = a + \gamma y_{t-1} + \sum_{i=1}^p \alpha_i \Delta y_{t-i} + \epsilon_t.$$

Rejeita-se  $H_0$  se o valor calculado de  $P_T$  for menor do que o valor crítico contido no artigo de Elliot, Rothenberg e Stock (1996).

### Phillips-Perron Modificado (Ng e Perron(2001))

Com base no método proposto no artigo ERS para destendenciar uma série, Ng e Perron (2001) propõem uma modificação no teste de PP para torná-lo eficiente, no sentido de ter menor distorções de tamanho (nível nominal do teste) e maior poder do que o teste de PP. Para tanto calculam-se

$$MZ_t = MZ_\rho \cdot MSB$$

$$MZ_\rho = \left( T^{-1} (y_T^d)^2 - \widehat{s}_{AR}^2 \right) \left( 2T^{-2} \sum_{t=1}^T (y_{t-1}^d)^2 \right)^{-1}$$

$$MSB = \left( T^{-2} \sum_{t=1}^T \frac{(y_{t-1}^d)^2}{\widehat{s}_{AR}^2} \right)^{1/2}.$$

Os valores críticos do teste são idênticos ao do teste ADF-GLS. Em geral, utiliza-se no cálculo de  $\hat{S}_{AR}^2$  a regressão com as séries destendenciadas por GLS.

### *Critério de Escolha de Defasagem*

---

<sup>37</sup> A regressão ADF a seguir pode ser tanto nas variáveis originais, quanto nas variáveis destendenciadas por MQO ou por GLS.



O tamanho e o poder do teste dependem da defasagem  $p$  usada na regressão auxiliar do teste. Ng e Perron (2001) argumentam que para séries com raiz unitária, os critérios de informação tradicionais não funcionam, propondo em seu lugar o critério modificado

$$MIC(p) = \ln(\hat{\sigma}_p^2) + \frac{(\tau_T(p) + p) C_T}{T - p_{max}}$$

$$\tau_T(p) = \frac{\hat{\gamma}^2 \sum_{t=p_{max}}^T (y_{t-1}^d)^2}{\hat{\sigma}_p^2}$$

$$\hat{\sigma}_p^2 = \frac{1}{T - p_{max}} \sum_{t=p_{max}+1}^T \hat{\epsilon}_t^2$$

Se  $C_T = 2$ , o critério é denominado de Akaike modificado; se  $C_T = \ln(T - p_{max})$ , de Schwartz ou BIC modificado; e, se  $C_T = 2 \ln(\ln(T - p_{max}))$ , de Hannan-Quinn modificado. Ng e Perron realizaram várias simulações e recomendam o uso do Akaike modificado, MAIC. O modelo selecionado é aquele que minimiza o critério de informação escolhido. Note que o número de resíduos utilizados no cálculo é igual, independentemente do número de defasagens efetivamente perdidas, para que o critério tenha o mesmo número de observações  $T - p_{max}$ .

### Testes de Estacionariedade (KPSS)

Os testes vistos até agora têm como hipótese nula a existência de raiz unitária, o que implica que a série é não-estacionária. Existem poucos testes que partem da hipótese nula de estacionariedade, que não têm tido popularidade. Um desses teste foi o desenvolvido por Kwiatkowski, Phillips, Schmidt e Shin (1992) e, por isso, é conhecido pela sigla KPSS. Dado

$$y_t = \mu + \beta_t + \xi_t + \epsilon_t$$

$$\xi_t = \xi_{t-1} + u_t$$

onde  $\epsilon_t \sim I(0)$ ,  $\xi_t$  é um passeio aleatório e  $u_t \sim iid(0, \sigma_u^2)$ .

O teste tem como hipóteses nula  $H_0: \sigma_u^2 = 0$ . Note que, se ela é verdadeira,  $\xi_t$  é uma constante e, portanto,  $y_t$  é um processo tendência estacionária. A estatística do teste é

$$LM = \frac{\sum_{t=1}^T S_t^2}{\hat{s}_{T_\ell}^2},$$

onde  $S_t = \sum_{t=1}^T e_t$  é a soma parcial de  $e_t$ , o resíduo da regressão de  $y_t$  contra os termos deterministas (constante e/ou tendência), e  $\hat{s}_{T_\ell}^2$  é um estimador consistente da variância de longo prazo do resíduo  $e_t$ . É prática comum usar o estimador de Newey e West para calcular essa variância. Os valores críticos do teste KPSS encontram-se no artigo original dos autores. A regra de decisão é rejeitar  $H_0$  se o valor calculado de estatística de KPSS é maior do que o valor crítico ao nível de significância desejado.

### Cointegração

A cointegração permite não apenas estimar a relação de longo prazo entre variáveis integradas como também a dinâmica do ajuste de curto prazo das variáveis ao equilíbrio de longo prazo. Antes, precisamos definir que  $y \sim I(0)$  representa que  $y$  é uma variável estacionária. Já  $y \sim I(d)$  significa que  $y$  deve ser diferenciada  $d$  vezes para que se torne estacionária, dizendo-se que é integrada de ordem  $d$ .

Se duas variáveis  $y$  e  $x$  são ambas  $I(1)$ , então, em geral, a combinação linear entre elas também será  $I(1)$ . Suponha agora que estas duas variáveis estejam relacionadas no longo prazo, tal que uma não se afaste da outra permanentemente. Caso ocorra um choque que cause um desvio temporário, haverá uma dinâmica que faz como que a relação se restabeleça ao logo do tempo. Nesse caso, é possível encontrar uma combinação linear entre elas que seja  $I(0)$ , i.e, de uma ordem de integração inferior à ordem das variáveis originais:

$$\varepsilon_t = y_t + \beta x_t.$$

Ou, no caso de  $n$  variáveis  $y_i, i = 1, \dots, n$ .

$$\varepsilon_t = \beta_1 y_{1,t} + \beta_2 y_{2,t} + \dots + \beta_n y_{n,t}.$$

O vetor  $\beta = (\beta_1, \beta_2, \dots, \beta_n)'$  é chamado de vetor de cointegração.

Como essa combinação linear entre os  $y$ 's é estacionária, multiplicar o vetor por uma constante  $k$  também resulta numa série estacionária. Por isso, normaliza-se um dos parâmetros para que tenha valor 1. Observe que neste caso, fica mais fácil interpretar a equação como uma regressão:

$$y_{1,t} = -\beta_2 y_{2,t} - \dots - \beta_n y_{n,t} + \varepsilon_t,$$

onde  $\varepsilon_t$  é o resíduo da regressão.

### **Regressão Espúria**

Os coeficientes de um modelo de regressão linear entre variáveis  $I(1)$ , estimados por mínimos quadrados ordinários, não são consistentes, fazendo com que as estatísticas  $t$  e  $F$  e o  $R^2$  tornem-se arbitrariamente grandes, mesmo que as variáveis não guardem relação entre elas. Neste caso, diz-se que ocorre uma “regressão espúria”, já que aparenta haver relação entre variáveis, quando na verdade não existe. Por isso o cuidado verificar a estacionariedade das séries antes das estimações.

### **Teste de Cointegração Baseado em Resíduos**

Os resíduos da regressão por mínimos quadrados entre variáveis  $I(1)$  devem apresentar tendência estocástica, i.e.,  $I(1)$ , se as variáveis são não cointegradas e devem ser estacionários,  $I(0)$ , se há cointegração. Baseado nessa ideia, Granger e Engle (1987) propuseram um teste para cointegração fundamentado na aplicação do teste de Dickey e Fuller Aumentado em cima dos resíduos de cointegração<sup>38</sup>. No entanto, como os resíduos são estimados e dependem dos parâmetros da regressão original, verificou-se que a distribuição da estatística dependia do número de variáveis, não se podendo usar a tabela de Dickey-Fuller. Os valores críticos foram encontrados por Phillips e Ouliaris (1990) e completados por MacKinnon em uma série de artigos. Note que se a relação de longo prazo é conhecida e, por isso, não precisa ser estimada, utiliza-se a própria tabela de Dickey-Fuller. A seguir descreve-se o método de Engle-Granger para o caso de haver apenas um vetor de cointegração, ou cointegrante, ( $\beta$ ) e as variáveis serem todas  $I(1)$ .

---

<sup>38</sup> Anota-se que, como o teste é aplicado nos resíduos, o teste não envolve constante ou tendência.

*Procedimentos do Teste em Dois Passos (Granger-Engle)*

1º Passo: Testar se as variáveis  $(y_1, y_2, \dots, y_n)$  são integradas de ordem 1, aplicando um teste de raiz unitária em cada uma delas. Se todas forem  $I(1)$ , prosseguir no passo 2.

2º Passo: Escolher uma das variáveis como variável dependente. Suponha que seja a variável  $y_1$ . Regredir contra as demais variáveis  $(y_2, \dots, y_n)$ .

$$y_{1,t} = -\beta_0 - \beta_2 y_{2,t} - \dots - \beta_n y_{n,t} + \varepsilon_t$$

Armazenar  $\hat{\varepsilon}_t$ , os resíduos da regressão.

3º Passo: Aplicar a regressão de Dickey-Fuller Aumentada nos resíduos da regressão acima.

$$\Delta \hat{\varepsilon}_t = \gamma \hat{\varepsilon}_{t-1} + \sum_{i=1}^p \gamma_i \Delta \hat{\varepsilon}_{t-i} + u_t$$

Caso os resíduos sejam  $I(1)$ , i.e., não se rejeita  $H_0$ , então não há cointegração. Se os resíduos são  $I(0)$ , i.e., rejeita-se  $H_0$ , conclui-se que há cointegração e pode-se estimar o modelo VEC do passo a seguir.

4º Passo: Estimar o modelo de vetor de correção de erros (VEC).

$$\Delta y_{1t} = \alpha_1 \cdot \varepsilon_{t-1} + \text{defasagens de } \Delta y's + v_{1t}$$

$$\Delta y_{2t} = \alpha_2 \cdot \varepsilon_{t-1} + \text{defasagens de } \Delta y's + v_{2t}$$

$$\vdots$$

$$\Delta y_{nt} = \alpha_n \cdot \varepsilon_{t-1} + \text{defasagens de } \Delta y's + v_{nt}$$

Como o modelo é próximo a um vetor autorregressivo (VAR) nas diferenças das variáveis  $y's$ , pode-se estimar cada equação separadamente por mínimos quadrados ordinários. O vetor de correção de erros  $\alpha$  descreve o comportamento de curto prazo das variáveis como

uma função do desvio na relação de longo prazo. Em razão disso, os  $\alpha$ 's são interpretados como sendo a velocidade de ajuste.

### Formação de preços

Pela lei do preço único<sup>39</sup>,  $P = S \cdot P^*$ , onde  $P$  é o preço doméstico do bem,  $S$  é a taxa nominal de câmbio em moeda local por moeda estrangeira, e  $P^*$  é o preço do bem no exterior, posto que o mesmo bem deve igual preço em dois países diferentes, após a conversão para a moeda local.

No caso do petróleo, assumindo a possibilidade de diferenças decorrentes das características do óleo ou custo de refino, transporte etc, mantendo uma proporção constante  $K$  entre preços,  $P = K \cdot S \cdot P^*$ , ou  $p = k + s + p^*$ , onde as letras minúsculas representam o logaritmo neperiano das variáveis correspondentes.

### Dados

Os dados de preços do barril de petróleo WTI, Brent e Dubai em dólares estadunidenses foram obtidos no sítio do Federal Reserve de Saint Louis (FRED). Em razão de se ter a disposição apenas os dados mensais para Dubai e de a cointegração aparecer em dados de frequência mais baixa, por envolver relações estáveis de longo prazo entre as variáveis, utilizou dados nessa periodicidade a partir da data em que todas séries estavam disponíveis: de janeiro de 1990, até junho de 2019, perfazendo 355 observações. As séries dos logaritmos naturais dos preços do barril de petróleo Brent, WTI e Dubai estão na Figura 02.01. A Figura 02.02 subsequente (02.02) apresenta as mesmas séries em retornos logarítmicos. Destaca-se que as séries de logaritmos de preços apresentam dinâmica muito semelhante, descolando-se em alguns períodos, mas apresentam movimentos conjuntos em seus níveis. Já nas diferenças, ou retornos, o comportamento é tal que são praticamente indistinguíveis.

---

<sup>39</sup> Omitimos o subscritos  $t$  para simplificar a notação.

Figura 02.01 – Séries Temporais do Logaritmo de Preços do Barril de Petróleo





Figura 02.02 – Séries Temporais do Retorno de Preços do Barril de Petróleo



## Resultados

Inicialmente, para o estudo da cointegração, deve-se verificar se as séries em questão têm raiz unitária, i.e., integradas de ordem 1 (um), o que é verificado de forma simples por meio dos diversos testes citados, cujos resultados não serão apresentados. A partir da verificação que todas as séries de logaritmos do preço petróleo são  $I(1)$ , procede-se ao teste de raiz unitária da diferença de uma série contra outra<sup>40</sup> para testar existência da relação de longo prazo entre elas. Caso a diferença seja  $I(0)$ , não se pode rejeitar a hipótese de cointegração. As séries  $\ln(\text{Brent}) - \ln(\text{Dubai})$ ,  $\ln(\text{WTI}) - \ln(\text{Brent})$  e  $\ln(\text{WTI}) - \ln(\text{Dubai})$ , onde  $\ln(x)$  representa o logaritmo do preço do barril de petróleo do referencial  $x$ , encontram-se na Figura 02.03. A primeira delas mostra uma persistência com queda do nível no início da série, enquanto a segunda, na década final. A terceira é combinação das duas primeiras, posto que  $\ln(\text{Brent}) - \ln(\text{Dubai}) + \ln(\text{WTI}) - \ln(\text{Brent}) = \ln(\text{WTI}) - \ln(\text{Dubai})$ . É nesse ponto que chamamos atenção ao fato de que os testes apresentaram resultados conflitantes, com a grande maioria indicando não haver cointegração<sup>41</sup>. Como os testes de raiz unitária são sensíveis a instabilidade nos parâmetros, procedeu-se a testes de raiz unitária com quebras estruturais, mas os resultados também foram conflitantes, não se podendo sequer indicar a data provável da maior quebra pelos testes tradicionais de mudanças estruturais como o de Zivot e Andrews (1992) ou Bai e Perron (1998).

Nessas situações, a racionalidade econômica, justificada por argumentos de arbitragem e pela lei do preço único, associada à análise visual das séries, demanda estudo mais detalhado da evidência de relação estável entre as variáveis. Para tanto, nas Figuras 02.04 e 02.05 são apresentados, respectivamente, os diagramas de dispersão (*scatter plots*) dos logaritmos e dos retornos de preço dos diferentes *benchmarks* de petróleo. Como pode ser observado, existe uma forte relação linear entre as variáveis, tanto nos níveis<sup>42</sup> quanto nas diferenças. Não há, no período analisado, descolamento, após um choque ou possível mudança estrutural em alguma delas, que persista no longo prazo.

Supondo que não haja cointegração, a diferença de logaritmos de cada série em relação a seu valor passado transforma-se em uma série  $I(0)$ . Como há evidência visual e justificativa teórica de que um preço de um barril encontra-se associado ao preço de outro, procedemos às

---

<sup>40</sup> Em virtude da lei do preço único, não é necessário se estimar os parâmetros da relação de cointegração.

<sup>41</sup> Inconsistência semelhante foi encontrada nos testes de Johansen a nível trivariado.

<sup>42</sup> A existência de relação entre as variáveis nos níveis é importante, pois pelo teorema de representação de Granger, se há cointegração, existe um fator comum, possivelmente não observável, que permeia o comportamento das séries. Além disso, existe, também, uma representação de correção de erros para cada variável cointegrada do sistema.

análises com modelos estimação e de previsão de uma variável sobre a outra, mas agora em termos de retornos.

Para o modelo univariado de retorno do petróleo, ou seja, valores passados da variável explicando o seu valor corrente, toma-se por base de comparação (hipótese nula) um autorregressivo de ordem um, AR(1),

$$\Delta p_t = c + \phi \Delta p_t + u_t.$$

O motivo para a escolha é que o correlograma indica a existência de autocorrelação de primeira ordem nas séries de retorno. É contra esse modelo AR(1) que se fará a comparação de desempenho do modelos com o outro referencial de petróleo. Da mesma forma que no capítulo 1, faz-se uma previsão contemporânea entre o retorno de um barril e de outro tipo.



Figura 02.03 – Diferença entre Logaritmo de Preços






Figura 02.04 – Diagramas de Dispersão do Logaritmo de Preços



Nota: Diagramas de dispersão do logaritmo de preços do Barril de petróleo Brent (LBRENT), Dubai (LDUBAI) e WTI (LWTI).

Figura 02.05 - Diagramas de Dispersão do Retorno de Preços



Nota: Diagramas de dispersão do logaritmo de preços do Barril de petróleo Brent (LBRENT), Dubai (LDUBAI) e WTI (LWTI).

Considerando-se que interesse precípua diz respeito à capacidade preditiva de um preço sobre o outro, aplicam-se teste de flutuação de Giacomini e Rossi (2015) tanto pela estatística de Diebold e Mariano quanto pela estatística de Clark e West. No primeiro caso, a superioridade da capacidade preditiva é comparada à do AR(1) nos retornos e os resultados encontram-se nas Figuras 02.06 (desempenho da previsão do modelo de retorno do Brent explicado pelo Dubai em relação ao AR(1)), 02.07 (modelo de retorno do WTI explicado pelo Brent frente ao AR(1)) e 02.08 (modelo de retorno do WTI explicado pelo Dubai relativo ao AR(1)). Com fins de comparação com seção anterior, apresenta-se também os resultados em relação tanto ao *random*

*walk* (linhas com círculos) quanto ao *random walk* com *drift* (linhas com losângulos) nos Figuras 02.06a, 02.07a e 02.08a. Independente do modelos base, autoregressivo ou *random walks*, o modelo com o retorno contemporâneo do outro referencial de petróleo apresenta capacidade preditiva superior pelos testes de flutuação, com as estatísticas DM sendo sempre negativas e mantendo-se significativas praticamente por toda a série. Para todas as séries, o teste rejeita a hipótese de igualdade da capacidade preditiva do teste, mostrando que uma série ajuda a prever a outra. O desempenho relativo do modelo com o preço do outro referencial é melhor para todo o período amostral ( $DM < 0$ ).

Figura 02.06 – Teste de Flutuação de Giacomini e Rossi (Estatística DM)




Figura 02.06a – Teste de Flutuação de Giacomini e Rossi (Estatística DM)




Figura 02.07 – Teste de Flutuação de Giacomini e Rossi (Estatística DM)




Figura 02.07a – Teste de Flutuação de Giacomini e Rossi (Estatística DM)




Figura 02.08 – Teste de Flutuação de Giacomini e Rossi (Estatística DM)





Figura 02.08a – Teste de Flutuação de Giacomini e Rossi (Estatística DM)



Resultados semelhantes são indicados pelo teste de flutuação com a estatística de Clark e West com relação ao passeio aleatório com constante contidos nas Figuras 02.09, 02.10 e 2.11. Com base nos resultados obtidos nos testes, concluímos que o retorno do preço de um barril de petróleo referencial pode ser previsto pelo retorno do preço de outro referencial, evidenciando que existe uma ligação forte entre os mercados dos três *benchmarks*. Testes com o outro tipo de petróleo defasados mostraram que este não tem poder preditivo superior ao AR(1) ou *random walks* e, por isso, foram omitidos.

Resta saber se existe uma (pre)dominância de algum referencial sobre o outro e como seria o comportamento do fator comum que permeia a dinâmica dos três *benchmarks*.

Figura 02.09 – Teste de Flutuação de Giacomini e Rossi (Estatística CW)




Figura 02.10 – Teste de Flutuação de Giacomini e Rossi (Estatística CW)







Figura 02.11 – Teste de Flutuação de Giacomini e Rossi (Estatística DM)



## Fator Comum

Para se ter uma ideia do fator comum por trás do comportamento das três séries de preços, procedeu-se a uma análise de componentes principais (PCA)<sup>43</sup> tradicional da série de retornos. O primeiro componente principal explica 96,05% da variação conjunta das séries. Os pesos normalizados encontrados para o retorno WTI, Brent e Dubai foram 0.331, 0.336 e 0.333, respectivamente, indicando, como esperado, que o comportamento ou variabilidade de nenhuma das séries se sobressai às demais. De fato, esses valores para o autovetor do primeiro componente correspondem, praticamente, à combinação com pesos iguais das séries. O retorno das séries construídas com os pesos do primeiro componente e com pesos iguais encontra-se na Figura 02.12 e, como era de se esperar, são praticamente idênticas. Testes de raízes unitárias na Tabela 02.01 mostram que, exceto pelo teste de Ng e Perron com critério de informação modificado de Akaike, todos os demais rejeitam a hipótese de existência de raiz unitária (ou de

<sup>43</sup> Acerca do uso de fatores em previsão, nas palavras de Stock e Watson (2011): “one step ahead forecasts of a variable  $y_t$  (which may or may not be an element of  $X_t$  used to estimate the factors) can be computed by regressing  $y_{t+1}$  on  $F$ ,  $y_t$ , lags of  $y_t$ , and (optionally) additional lags of  $F$ ...”, onde  $F$  são os fatores. No caso, os autores não estão analisando situações em que haja variáveis contemporâneas como regressores.

não estacionariedade, no caso do teste KPSS)<sup>44</sup>. Na tabela, \* indica que o coeficiente é significativo a 5% e \*\*, significativo a 1%. Em termos de capacidade preditiva, os modelos de componentes principais defasados e de combinação com pesos iguais defasados tiveram desempenho semelhante ao de um AR(1) e, por isso, não se reportam aqui os resultados.

Em função desses achados, entendemos que podemos usar quaisquer das séries, WTI, Brent ou Dubai para avaliar a formação de preços do óleo diesel no Brasil na seção a seguir.

Figura 02.12 – Séries Temporais do Retorno do Fator (PCA e *Equally Weighted*)




Tabela 02.01 – Resultados dos Testes de Raiz Unitária nos Fatores

	Critério ou <i>kernel</i>	Pesos (PCA)		Pesos Iguais	
		Estatística	Significância	Estatística	Significância
ADF	Akaike mod.	-13.434	**	-13.432	**
	Schwarz mod.	-13.434	**	-13.432	**
PP	Newey-West	-12.796	**	-12.794	**
ADF-GLS	Akaike mod.	-2.197	*	-2.200	**
	Schwarz mod.	-2.629	**	-2.633	**
KPSS	Newey-West	0.072	**	0.072	**
ERS-OP	Newey-West	0.324	**	0.324	**
NP	Newey-West	-	**	-	**
	Akaike mod.	-	x	-	x

<sup>44</sup> Esse resultado é interessante, pois foi mais comum não poder se rejeitar, na margem de significância, a existência de raiz unitária em alguns dos retornos individuais do que na série combinada.


Em síntese, apontamos que:

- testes de raiz unitária e cointegração não indicam a real relação entre variáveis com várias quebras estruturais (instabilidade de parâmetros);
- testes de instabilidade de desempenho preditivo (relativo) apontam melhor a relação entre os diferentes tipos de barris de petróleo;
- fator comum (PCA ou pesos iguais) apresenta mesma capacidade preditiva do que a própria série univariada (AR(1)); e
- Choques não fazem séries se descolar, havendo relação de longo prazo (choques comuns em bens – relativamente - substitutos).

### **Formação de preços do diesel**


Historicamente, o preço dos combustíveis sofreu no país intervenções por parte do governo. A motivação pode se dar por diversos fatores como: subsídios cruzados para viabilizar o álcool (etanol) – alternativa à dependência de petróleo – ou o diesel, que abastece a frota de caminhões, principal meio de transporte de cargas; controle da inflação ou por razões políticas. A Figura 02.13 apresenta o preço médio mensal do óleo diesel na bomba desde julho de 2001 e do barril de petróleo WTI convertido em real pelo câmbio médio do mês correspondente. Os dados relativos ao valor médio do combustível, a nível nacional, foram extraídos do sítio da Agência Nacional de Petróleo, enquanto para o WTI foi utilizado os dados mensais coletados no já mencionado banco de dados FRED do Federal Reserve de Saint Louis. Já o valor médio do dólar foi retirado em consulta à página do Banco Central do Brasil. Apresentam-se linhas verticais para mostrar a evolução de preços por governo. A linha tracejada vertical representa o mês em que ocorreu a greve dos caminhoneiros. Tanto a série de preços do diesel como do petróleo em real encontram-se transformados de forma a terem base 100 no início da Figura 02.13.

Figura 02.13 – Séries Temporais do Preço do Diesel na Bomba e do Preço do WTI



Chama a atenção o comportamento referente ao preço do diesel, que, por quase todo o período, ascendeu em pulos espaçados temporalmente sem periodicidade definida. O fato é observável na Figura 02.14, que traz o retorno logarítmico. Os picos são quase sempre positivos e de magnitude variável e, até meados de 2016, tendiam a ser maiores conforme a duração em relação ao reajuste anterior fosse maior, refletindo a elevação acumulada nos preços do petróleo no mercado internacional. A partir de 2016, o comportamento é alterado com oscilações para cima e para baixo mais frequentes. Anota-se, após a greve de 2018, nos poucos meses de informação disponíveis, o aumento da oscilação, tanto no campo positivo quanto no negativo, em relação à média de retornos histórica, indicando aumento na volatilidade no retorno do diesel.

Figura 02.14 - Série Temporal do Retorno do Diesel



Para efeito de comparação com a dinâmica do preço internacional de petróleo, a Figura 02.15 apresenta os retornos logarítmicos do diesel e do WTI em reais a partir de junho de 2016. Observa-se claramente que a volatilidade de preços internacionais é muitas vezes maior do que a oscilação do diesel. Como não é claro se os efeitos das mudanças da política de preços da Petrobrás foram benéficos aos consumidores finais de diesel, a Figura 02.16 apresenta os que ocorreu com o preços, a partir de maio de 2016, tomado como base cem (100), para séries até junho 2018, quando é recalculada nova base a partir deste mês para as séries. Observa-se que, se nos meses que se seguiram à greve o aumento de preços do diesel (linha com cruzes) foi inferior à elevação do petróleo internacional (linha com círculos), ao final do ano, o preço do combustível doméstico não acompanhou o declínio do valor do barril.



A Tabela 02.02 apresenta a correlação entre retornos dos preços de diesel e petróleo, mais uma vez evidenciando que o preço indígena do diesel somente acompanha o externo a partir de meados para final do ano de 2016.

Tabela 02.02 – Correlações do Retorno do Diesel e do WTI em real

Período	Governo	Correlação
2003-2006	Lula 1	0.020
2007-2010	Lula 2	0.126
2010-2014	Dilma 1	0.001
2014-2016	Dilma 2	0.223
2016-2018	Temer	0.437

Dessa forma, com fins de analisar a questão da dinâmica da formação de preços<sup>45</sup> recente, apresenta-se um modelo simples para mensurar os efeitos das duas principais variáveis apontadas pelas autoridades e pela Petrobrás como responsáveis pela variação do preço de diesel<sup>46</sup>. Para a formação de preços, assumido que os principais custos são dados pela variação cambial e pelo preço internacional em dólar do barril de petróleo,

$$P_d = C.(S.P)^\beta,$$

onde  $P_d$  é o preço do derivado,  $S$  é a taxa de câmbio,  $P$  é o preço internacional do barril de petróleo. Anota-se que  $S.P$  corresponde ao preço do barril do petróleo em real. Denotando por letras minúsculas o logaritmo natural das variáveis, ou  $p_d = c + \beta.(s + p)$ . No caso, a constante  $c$  incorpora todos os demais custos e despesas, incluindo tributos, além de margens de lucro, assumindo-se que sejam todas razoavelmente estáveis<sup>47</sup>. Caso se defase a equação em um período e subtraia esta da equação acima, tem-se

$$r_d = \beta(r_s + r_p),$$

<sup>45</sup> O site da ANP traz preços por municípios/estados, mas como o interesse reside em previsões macro relacionadas ao diesel e não à estimação de fatores fixos por localidade ou características regionais, procedeu-se à análise usando o preço médio no país.

<sup>46</sup> Ver a respeito <https://www.camara.leg.br/noticias/529808-especialistas-temem-greve-de-caminhoneiros-em-protesto-ao-aumento-do-diesel/>. Acesso em 02.set. de 2018.

<sup>47</sup> O site da Petrobrás trazia a seguinte composição de preços para o diesel: 12% para distribuição e revenda, 13% de custo de etanol anidro, 30% de ICMS (tribute estadual), 16% de CIDE, PIS/PASEP e COFINS (tributos federais) e 29% para realização da Petrobras. Consulta a: <http://www.petrobras.com.br/pt/produtos-e-servicos/composicao-de-precos-de-venda-ao-consumidor/diesel/> em 30 de agosto de 2019.

onde  $r_x$  corresponde ao retorno da variável  $x$ . Os resultados da regressão do retorno do diesel contra o preço do barril em real para o período relativo ao governo Temer<sup>48</sup> encontra-se na Tabela 02.03 abaixo.

Tabela 02.03 – Estimação *In-Sample* do Modelo de Formação de Preços

Coefficiente	Estimativa	Estatística $t$ robusta
$\beta$	0.145	3.840
$R^2$	0.163	

Ainda em relação à dinâmica de formação de preços com base nos custos, pode-se imaginar que o efeito do câmbio esteja dissociado em alguma magnitude do valor em dólar do petróleo. Suponha que a Petrobrás importe e exporte barris de petróleo bruto para refino, mas importe equipamentos e derivados de óleo. Desse modo, a demanda de divisas já não é um para um em relação à quantidade de petróleo bruto. Além disso, considerados os valores envolvidos na indústria, suponha também que realize operações de *hedge* no mercado financeiro. Naturalmente, o custo da proteção é consideravelmente maior para o petróleo, dada a volatilidade de preço da *commodity*, além dos prazos e preços contratados serem diferentes. Na situação descrita, a especificação da formação de preços do diesel passa a ser

$$P_d = C.S^{\beta_1}.P^{\beta_2},$$

ou  $p_d = c + \beta_1.s + \beta_2.p$ , ou ainda,  $r_d = \beta_1 r_s + \beta_2 r_p$ . Os parâmetros dessa nova especificação, que separam as variáveis câmbio e preço internacional do barril, para o período relativo ao governo Temer encontram-se na Tabela 02.04 abaixo. Nota-se que o câmbio deixa de ser significativo e o coeficiente do preço do petróleo se eleva ligeiramente, assim com o valor da estatística  $t$  do retorno do petróleo e o  $R^2$ .

Tabela 02.04 – Estimação *In-Sample* do Modelo de Formação de Preços (Duas Variáveis)

Coefficiente	Estimativa	Estatística $t$ robusta
$\beta_1$	0.020	0.227
$\beta_2$	0.164	3.914

<sup>48</sup> Apesar de a política de preços da Petrobrás de se balizar nos preços internacionais ter sido adotada a partir de novembro de 2016, utilizam-se os dados de junho de 2016 a dezembro de 2018 na estimação.



$R^2$ 

0.197

Em razão dos poucos dados disponíveis, seis meses, não se apresentará aqui exercício de previsão para diesel dado o preço do petróleo, mas, das especificações testadas, com parâmetros estimados para diferentes datas para observação inicial, podemos mencionar que o preço médio do diesel na bomba ficou acima do esperado pelo modelo nos meses de setembro, outubro e novembro de 2018.

## Conclusão

Sumarizando os resultados encontrados e as inferências de nossa parte decorrentes:

- (i) A relação dos preços dos *benchmarks* de petróleo não foi constante ao longo do tempo com desvios em termos de preços mais perceptíveis, em período recente, do WTI em relação aos demais referenciais, Brent e Dubai, entre 2010 e 2015<sup>49</sup>. Há, entretanto, fator(es) não-observável(is) que determinam a dinâmica conjunta entre elas, permitindo que uma das séries, ou uma combinação entre elas, auxilie na previsão da outra. No período compreendido entre janeiro de 1990 e junho de 2019, o desempenho médio de um referencial para prever o outro é superior ao do modelo AR(1) e ao passeio aleatório, com ou sem *drift*, com a mesma superioridade ocorrendo de forma localizada para a maior parte da amostra.
- (ii) A formação do preço dos combustíveis na bomba não foi dada diretamente pelo custo do principal insumo, seguindo padrões de aumentos esporádicos maiores em períodos espaçados - exceto por curto período recente, a partir do final de 2016, sendo que, mesmo assim, o efeito de uma variação do câmbio sobre o preço do diesel é inferior a de uma variação no preço do petróleo. Após a greve dos caminhoneiros, em maio de 2018, a despeito da redução inicial no preço e congelamento temporário, aumentou a volatilidade no preço do diesel, representando um exemplo de intervenção estatal na economia com efeitos adversos.
- (iii) A alteração na política de preços de combustíveis após a referida greve, teve como efeito, além de aumentar a volatilidade, de manter o preço do diesel acima

---

<sup>49</sup> Investigação interessante seria avaliar se o desenvolvimento de tecnologia de extração de combustível a partir do xisto betuminoso (*gas of shale*), barateando o custo e viabilizando sua produção, pode ter permitido o descolamento para baixo de preços do WTI em relação ao Brent e ao Dubai.

do nível de preços esperado pela dinâmica do câmbio e do preço internacional do petróleo, no sentido de que a forte queda no preço do barril de petróleo observada nos meses de outubro e de novembro de 2018 não foi acompanhada por declínio correspondente no preço do combustível domesticamente, mesmo com o governo federal eliminando a cobrança da Cide-combustíveis e com alguns Estados (Rio de Janeiro e São Paulo) anunciando a redução do ICMS.

## CAPÍTULO 3

O petróleo se constitui num dos principais insumos da economia<sup>50</sup>. Sua escassez e a elevação em seu preço a nível internacional afeta o crescimento não só domesticamente, mas globalmente. Em influente artigo, James Hamilton (1983) afirmou que sete de oito recessões norte-americanas ocorridas no pós-guerra foram antecedidas de um acentuado aumento no preço do petróleo. Em 2010, o mesmo autor havia contabilizado 10 de 11 recessões após choques nos preços do petróleo. O presente capítulo investiga se existe evidência de efeito no preço do petróleo sobre o crescimento econômico brasileiro, incluindo a discussão da existência de não-linearidade nessa relação.

### Modelos

#### Sazonalidade

No caso da haver sazonalidade, que claramente corresponde ao caso do produto interno bruto, PIB, alguns conceitos adicionais serão precisos e, por isso, abordados a seguir.

#### AR Sazonal (Aditivo) ou AR Degenerado

No AR( $p$ ) sazonal aditivo, aqui representado, por simplicidade,  $Y_t$  é uma função de  $Y_{t-p}$ , apenas,

$$Y_t = \phi_0 + \phi_1 Y_{t-p} + \varepsilon_t,$$

onde  $\varepsilon_t$  é um ruído branco *i.i.d.*(0,  $\sigma^2$ ). Esse tipo de modelo, como mencionado, pode ser entendido como um caso especial que representa variáveis com sazonalidade, já que se espera um padrão com base no mês ou trimestre da observação. Por isso, para variáveis mensais, pode-

---

<sup>50</sup> Como mostra Hamilton (2011), a participação do consumo de petróleo na economia foi de apenas 4% do PIB norte-americano. Assim, mecanismos de transmissão via demanda teriam importância maior para explicar o efeito do aumento do preço do petróleo sobre o crescimento do que formulações baseadas no lado da oferta. De fato, entendemos que trata-se de insumo cujo participação pode ser pequena, mas que afeta indiretamente diversos setores da economia de forma e com dificuldade de se substituir por outro insumo, envolvendo toda uma mudança de tecnologia.

se utilizar  $p = 12$  e, para dados trimestrais,  $p = 4$  no caso de o padrão de sazonalidade se repetir no mesmo período do ano.

### **Raiz Unitária Sazonal**

Tal como o passeio aleatório, pode ser entendido como um caso de autorregressivo de ordem 4 ou 12, com  $\phi_1 = 1$ ,

$$Y_t = \phi_0 + \phi_1 Y_{t-4} + u_t,$$

onde  $u_t$  é um ruído branco *i.i.d.*(0,  $\sigma^2$ ). Trata-se de um modelo não-estacionário, sem média definida e com variância explosiva no tempo. No passeio aleatório, um choque  $u_t$  é incorporado para sempre em  $Y_{t+h}$  e, por isso, seria como se a média do processo se deslocasse, sendo assim chamado de modelo com tendência estocástica, tendo cada choque o efeito de alterar o nível ou a tendência da série após sua ocorrência.

No caso de  $\phi_0 = 0$ , o melhor predictor futuro é seu último valor conhecido, independentemente da data futura a que se refira a previsão, i.e.,  $E(Y_{t+h}|t) = Y_t$  ( $h > 0$ ), posto que o valor esperado, ou média, de  $u_t$  é igual a zero ( $E(u_t) = 0$ ). Se  $\phi_0 \neq 0$ ,  $\phi_0$  é adicionado a cada período. Nesse caso, se  $\phi_0 > 0$ , a variável  $Y_t$  aumenta em  $\phi_0$  a cada período.

Transformar uma variável por meio da sua diferença sazonal equivale dizer que a variável tem uma raiz unitária sazonal.

### **Hamilton (2018)**

Por influência de recente artigo para discussão de Hamilton (2018), analisa-se um modelo de projeção de componentes transitórios. O interessante aqui é que a equação a ser estimada por mínimos quadrados ordinários é um  $AR(p)$  com alguns coeficientes de menor ordem iguais a zero.

Em sua crítica à aplicação do filtro de Hodrick-Prescott para ajuste de tendência, Hamilton (2018) propõe a utilização da diferença entre o valor efetivo de uma variável em uma data futura  $t+h$ , com  $h > 0$ , em relação ao seu valor esperado com base no comportamento observado até  $t$ . A utilização desse método, ao contrário do que possa parecer, não requer nem

o conhecimento do tipo de não-estacionariedade da série e tampouco o modelo correto de previsão.

Pode-se demonstrar (ver artigo de Hamilton (2018)) que os resíduos da regressão por mínimos quadrados ordinários de  $y_{t+h}$  em função dos 4 valores mais recentes de  $y_t$  conhecidos em  $t$  resultam em uma série de componentes transitórios, contanto que a série torne-se estacionária por meio da quarta diferenciação,  $I(d)$ , com  $d \leq 4$ , ou ela seja de tendência polinomial temporal estacionária até a quarta ordem ( $u_t = y_t - \delta_0 - \delta_1 t - \delta_2 t^2 - \dots - \delta_d t^d$ , com  $d \leq 4$ ):

$$\hat{v}_{t+h} = y_{t+h} - \hat{\beta}_0 - \hat{\beta}_1 y_t - \hat{\beta}_2 y_{t-1} - \hat{\beta}_3 y_{t-2} - \hat{\beta}_4 y_{t-3}$$

Conforme, ainda, o artigo, o uso de modelos mais sofisticados para extrair o componente é desnecessário, mesmo que a variável seja parte de sistema vetorial com dinâmica não linear. Outra questão colocada é que, quanto maior  $h$ , maior o tamanho da amostra  $T$  requerido. Por isso, o autor recomenda  $p = 4$  e  $h = 8$  para dados trimestrais, considerando-se um ciclo econômico usual e que  $p$  e  $h$  sejam múltiplos do número de observações por ano.

## Petróleo e PIB

A relação entre o crescimento do PIB e o preço do petróleo tem sido analisada por meio de equações como

$$y_t = a + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \beta_3 y_{t-3} + \beta_4 y_{t-4} + \beta_5 s_{t-1} + \beta_6 s_{t-2} + \beta_7 s_{t-3} + \beta_8 s_{t-4} + u_t$$

onde  $y$  é a variação trimestral do logaritmo do PIB real,  $s$  é a diferença de logaritmo do preço do barril de petróleo e  $u$  corresponde ao termo aleatório. São reportados os testes  $t$  das estimativas individuais para os coeficientes relativos ao petróleo ( $H_0: \beta_j = 0$ , onde  $j = 5, \dots, 8$ ) e/ou o teste  $F$  para a significância conjunta desses coeficientes ( $H_0: \beta_5 = \beta_6 = \beta_7 = \beta_8 = 0$ ). Por meio desse tipo de regressão, Hamilton (1983) mostrou que o preço do petróleo explicava o crescimento da economia.

## Não Linearidade dos Efeitos do Petróleo

Mais recentemente, passou-se a investigar possíveis relações de não-linearidade entre o *commodity* e o crescimento da economia. Hamilton (2003 e 2011) propõe a seguinte especificação<sup>51</sup>

$$s_t^\# = \max\{0, s_t - \max\{s_{t-1}, \dots, s_{t-12}\}\},$$

Onde  $s_t$  é o logaritmo do nível de preço do petróleo. Ou seja, mede-se o efeito apenas se o petróleo atingiu o preço máximo dos últimos três anos, considerando os dados de periodicidade trimestral.

## Resultados

Os dados relativos ao PIB (valores encadeados a preços de 1995) foram extraídos do IBGE<sup>52</sup> e aos preços do petróleo Brent foram obtidos no banco de dados FRED. Utilizou-se a média trimestral que estava disponível para o último. Considerando que há diferentes medidas possíveis de crescimento do PIB, utilizou-se como variável dependente as seguintes variações:  $(1-L)y_t$ ,  $(1-L^4)y_t$  e  $(1-L)(1-L^4)y_t$ , que correspondem: (a) à taxa de crescimento do PIB em relação ao trimestre imediatamente anterior, (b) à taxa de crescimento em relação ao mesmo trimestre do ano anterior e (c) à variação na taxa de crescimento trimestral, respectivamente, onde  $L$  representa o operador de defasagens, i.e.,  $L^j y = y_{t-j}$ . Além disso, em razão do artigo de Hamilton (2018), que sugere uma metodologia para extração de tendência da séries, incluímos  $(1-L)\hat{y}_h$ , onde  $\hat{y}_h$  é a série de componentes transitórios, com *lead* de  $h = 4$  ou  $8$ . A Figura 03.01 apresenta as séries temporais das taxas de crescimento de acordo com as diferentes medidas, notando-se na última Figura menor à esquerda a forte sazonalidade no crescimento em relação a trimestre imediatamente anterior. Por sua vez, para reforçar essa questão da sazonalidade e de crescimento, a Figura 03.02 separa as observações de cada série, agrupando-as por trimestre. Assim, cada bloco de cada subgráfico mostra as observações de um mesmo trimestre, ordenados crescentemente por ano. As linhas horizontais no centro de cada gráfico menor representam a média do grupo. Nota-se que, na última Figura, as médias são bem diferentes entre trimestres, refletindo a sazonalidade. Além disso, caso haja uma tendência de aumento, poderá ser

<sup>51</sup> A intuição sugerida é que agentes consumidores podem não reagir a uma elevação de 10% se essa foi precedida de uma queda de 20% no preço.

<sup>52</sup> Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9300-contas-nacionais-trimestrais.html?=&t=o-que-e>>.

observado por meio da elevação do valor, para um mesmo trimestre, de um ano para outro. Essa análise visual auxilia na avaliação que quais medidas são mais apropriadas, tanto em termos de regressando quanto de covariadas (regressores).

Para cada uma das medidas de crescimento, estimou-se a especificação com os seguintes regressores: valores passados do regressando, valores passados das variações do preço de petróleo e valores passados da variável que captura a não-linearidade ( $s^{\#}$ ). As Tabelas 03.01  $[(1-L)y_t$ , taxa de crescimento no trimestre em relação ao trimestre], 03.02  $[(1-L^4)y_t$ , taxa de crescimento em relação ao mesmo trimestre do ano anterior], 03.03  $[(1-L)(1-L^4)y_t$ , variação na taxa de crescimento em relação ao mesmo trimestre do ano anterior], 03.04 [crescimento na séries de componentes transitórios, com  $h = 8$ ] e 03.05 [crescimento na séries de componentes transitórios, com  $h = 4$ ] trazem os resultados das estimações em relação a: (1) valores passados da variável dependente e (2)  $(1-L)s_t$ , (3)  $(1-L^4)s_t$  e (4)  $[(1-L)(1-L^4)s_t$  do Brent. Os valores de erro padrão da estimativa encontra-se abaixo, descolados à direita. Os P-valores da estatística  $F$  deixam claro que a medida a ser utilizada deve ser a taxa de retorno do petróleo de um trimestre em relação ao imediatamente anterior, independentemente do conceito de crescimento. Os sinais destes coeficientes estimados foram contrários ao esperado, já que se esperava que a maioria deles fosse negativo, em especial a primeira defasagem. Já a Tabela 03.06, mostra para cada conceito de crescimento (na coluna) as estimações contra suas defasagens e a medida de não-linearidade proposta por Hamilton. Destaca-se que a significância a nível individual existe ao nível de significância de 5% apenas para a primeira defasagem<sup>53</sup> em quatro modelos, sendo que apresenta sinal positivo. De todo modo, pode-se se dizer que existe relação entre o preço do petróleo e a taxa de crescimento, sendo o resultado mais fraco em relação à não-linearidade na relação.

---

<sup>53</sup> Estimou-se os modelos sem as defasagens 2 (dois) a 4 (quatro), mas isso não teve o condão de alterar o sinal ou aumentar a significância da variável de preço.

Figura 03.01 – Séries de Crescimento do PIB por Diferentes Conceitos

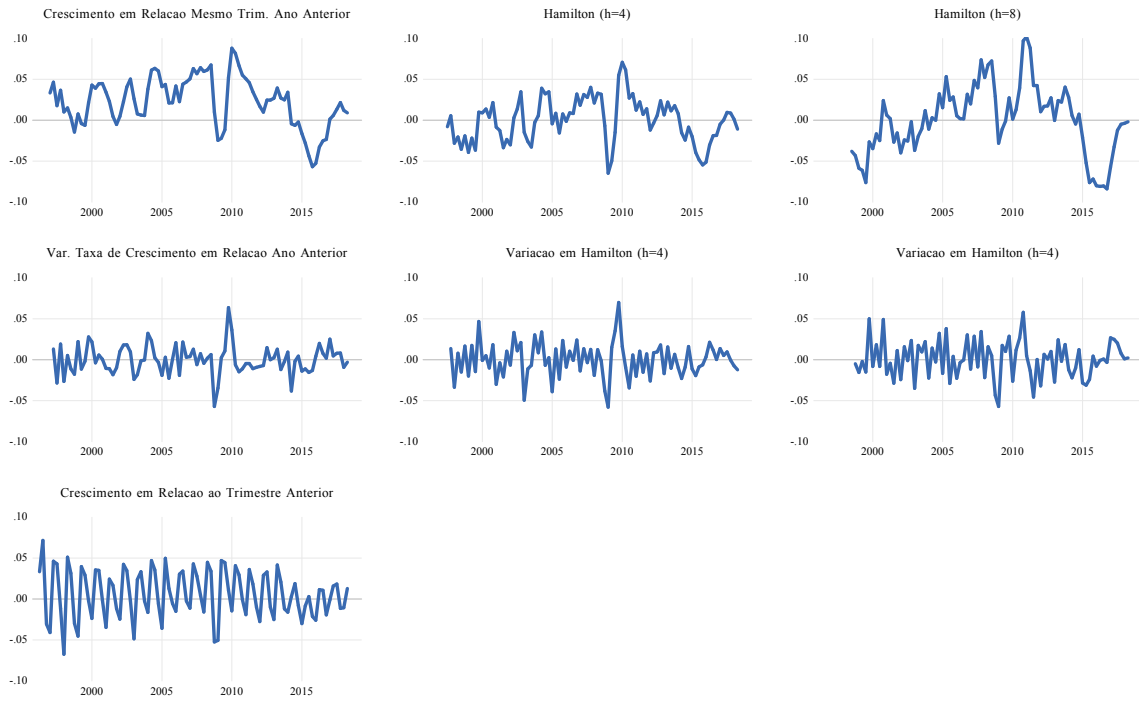


Figura 03.02 – Crescimento do PIB Agrupado por Trimestre

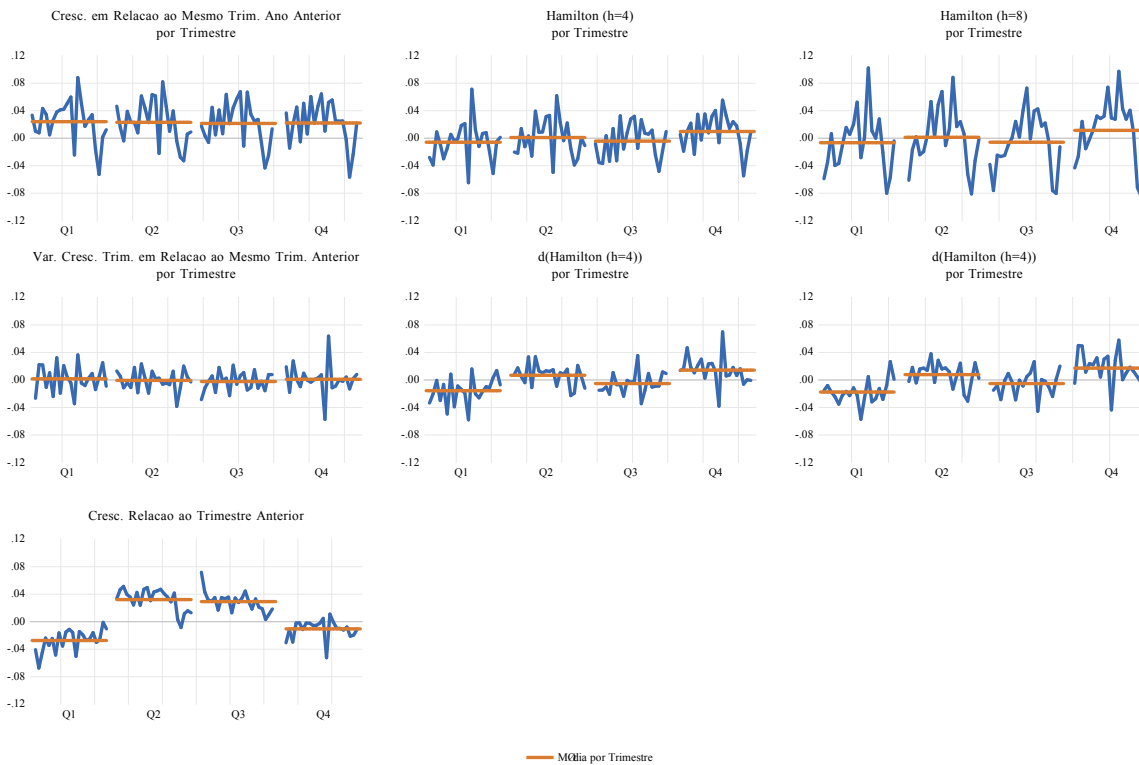




Tabela 03.01 – Estimativas dos Modelos PIB e Petróleo

<b>Variável dependente: <math>(1-L)y_t</math></b>				
	(1)	(2)	(3)	(4)
$\alpha$	0.004	0.004	0.003	0.003
	0.002	0.002	0.002	0.002
$(1-L)y_{t-1}$	0.002	-0.105	0.018	0.020
	0.087	0.096	0.089	0.090
$(1-L)y_{t-2}$	-0.241	-0.284	-0.249	-0.266
	0.086	0.095	0.091	0.091
$(1-L)y_{t-3}$	-0.022	-0.042	-0.038	-0.022
	0.084	0.094	0.091	0.089
$(1-L)y_{t-4}$	0.609	0.612	0.633	0.648
	0.084	0.092	0.090	0.091
$(1-L)s_{t-1}$		0.038		
		0.011		
$(1-L)s_{t-2}$		0.009		
		0.012		
$(1-L)s_{t-3}$		0.007		
		0.012		
$(1-L)s_{t-4}$		-0.022		
		0.012		
$(1-L^4)s_{t-1}$			-0.002	
			0.007	
$(1-L^4)s_{t-2}$			-0.006	
			0.011	
$(1-L^4)s_{t-3}$			-0.001	
			0.011	
$(1-L^4)s_{t-4}$			-0.001	
			0.007	
$(1-L)(1-L^4)s_{t-1}$				-0.003
				0.005
$(1-L)(1-L^4)s_{t-2}$				-0.009
				0.008
$(1-L)(1-L^4)s_{t-3}$				-0.007
				0.008
$(1-L)(1-L^4)s_{t-4}$				-0.003
				0.005
$F$		4.531	0.369	0.577
P-valor		0.003	0.830	0.680
$R^2$	0.71	0.76	0.71	0.71

Tabela 03.02 – Estimativas dos Modelos PIB e Petróleo (continuação)

Variável dependente: $(1-L^4)y_t$				
	(1)	(2)	(3)	(4)
$\alpha$	0.002	0.005	0.005	0.005
	0.002	0.002	0.002	0.002
$(1-L^4)y_{t-1}$	1.000	0.936	1.108	1.100
	0.087	0.124	0.114	0.114
$(1-L^4)y_{t-2}$	-0.255	-0.134	-0.235	-0.246
	0.087	0.162	0.169	0.165
$(1-L^4)y_{t-3}$	0.596	-0.008	-0.083	-0.050
	0.090	0.156	0.172	0.171
$(1-L^4)y_{t-4}$	-0.429	-0.041	-0.027	-0.042
	0.090	0.108	0.112	0.116
$(1-L)s_{t-1}$		0.027		
		0.012		
$(1-L)s_{t-2}$		0.013		
		0.013		
$(1-L)s_{t-3}$		0.011		
		0.013		
$(1-L)s_{t-4}$		-0.025		
		0.012		
$(1-L^4)s_{t-1}$			-0.002	
			0.007	
$(1-L^4)s_{t-2}$			-0.003	
			0.010	
$(1-L^4)s_{t-3}$			0.007	
			0.010	
$(1-L^4)s_{t-4}$			0.005	
			0.007	
$(1-L)(1-L^4)s_{t-1}$				-0.005
				0.004
$(1-L)(1-L^4)s_{t-2}$				-0.011
				0.007
$(1-L)(1-L^4)s_{t-3}$				-0.006
				0.007
$(1-L)(1-L^4)s_{t-4}$				-0.002
				0.004
$F$		3.270	1.206	1.231
P-valor		0.016	0.316	0.295
$R^2$	0.83	0.78	0.76	0.76

Tabela 03.03 – Estimativas dos Modelos PIB e Petróleo (continuação)

Variável dependente: $(1-L)(1-L^4)y_t$				
	(1)	(2)	(3)	(4)
$\alpha$	0.000	0.000	0.000	0.000
	0.002	0.002	0.002	0.002
$(1-L)(1-L^4)y_{t-1}$	0.224	0.119	0.251	0.244
	0.099	0.106	0.101	0.102
$(1-L)(1-L^4)y_{t-2}$	-0.075	-0.085	-0.047	-0.089
	0.100	0.104	0.111	0.105
$(1-L)(1-L^4)y_{t-3}$	-0.003	0.044	0.001	0.014
	0.098	0.101	0.100	0.104
$(1-L)(1-L^4)y_{t-4}$	-0.442	-0.377	-0.430	-0.418
	0.096	0.099	0.098	0.097
$(1-L)s_{t-1}$		0.020		
		0.011		
$(1-L)s_{t-2}$		0.010		
		0.012		
$(1-L)s_{t-3}$		-0.004		
		0.012		
$(1-L)s_{t-4}$		-0.026		
		0.011		
$(1-L^4)s_{t-1}$			0.000	
			0.006	
$(1-L^4)s_{t-2}$			0.005	
			0.010	
$(1-L^4)s_{t-3}$			0.012	
			0.010	
$(1-L^4)s_{t-4}$			0.008	
			0.006	
$(1-L)(1-L^4)s_{t-1}$				-0.005
				0.004
$(1-L)(1-L^4)s_{t-2}$				-0.009
				0.007
$(1-L)(1-L^4)s_{t-3}$				-0.005
				0.007
$(1-L)(1-L^4)s_{t-4}$				-0.001
				0.004
		2.836	1.247	1.082
		0.030	0.299	0.372
$R^2$	0.29	0.38	0.33	0.33

Tabela 03.04 – Estimativas dos Modelos PIB e Petróleo (continuação)

<b>Variável dependente: <math>(1-L)y^*_t</math> (Hamilton, <math>h=4</math>)</b>				
	(1)	(2)	(3)	(4)
$\alpha$	0.000	0.000	0.000	0.000
	0.002	0.002	0.002	0.002
$(1-L)y^*_{t-1}$	0.946	0.814	1.028	1.021
	0.103	0.109	0.107	0.113
$(1-L)y^*_{t-2}$	0.097	0.187	0.138	0.066
	0.119	0.116	0.123	0.126
$(1-L)y^*_{t-3}$	-0.751	-0.640	-0.839	-0.826
	0.117	0.114	0.119	0.126
$(1-L)y^*_{t-4}$	0.450	0.370	0.427	0.496
	0.101	0.095	0.100	0.107
$(1-L)s_{t-1}$		0.047		
		0.011		
$(1-L)s_{t-2}$		-0.001		
		0.012		
$(1-L)s_{t-3}$		-0.003		
		0.012		
$(1-L)s_{t-4}$		-0.013		
		0.012		
$(1-L^4)s_{t-1}$			0.017	
			0.007	
$(1-L^4)s_{t-2}$			0.030	
			0.010	
$(1-L^4)s_{t-3}$			0.032	
			0.010	
$(1-L^4)s_{t-4}$			0.016	
			0.007	
$(1-L)(1-L^4)s_{t-1}$				0.006
				0.005
$(1-L)(1-L^4)s_{t-2}$				0.012
				0.008
$(1-L)(1-L^4)s_{t-3}$				0.016
				0.008
$(1-L)(1-L^4)s_{t-4}$				0.009
				0.005
$F$		5.424	2.600	1.291
P-valor		0.001	0.043	0.282
$R^2$	0.69	0.76	0.73	0.71

Tabela 03.05 – Estimativas dos Modelos PIB e Petróleo (continuação)

<b>Variável dependente: <math>(1-L)y^*_t</math> (Hamilton, <math>h=8</math>)</b>				
	(1)	(2)	(3)	(4)
$\alpha$	0.001	-0.001	0.001	0.001
	0.002	0.002	0.002	0.002
$(1-L)y^*_{t-1}$	0.900	0.817	0.925	0.982
	0.112	0.114	0.113	0.114
$(1-L)y^*_{t-2}$	0.223	0.206	0.279	0.231
	0.139	0.137	0.143	0.140
$(1-L)y^*_{t-3}$	-0.577	-0.539	-0.616	-0.690
	0.139	0.137	0.136	0.141
$(1-L)y^*_{t-4}$	0.311	0.376	0.266	0.346
	0.111	0.112	0.108	0.109
$(1-L)s_{t-1}$		0.051		
		0.015		
$(1-L)s_{t-2}$		0.005		
		0.016		
$(1-L)s_{t-3}$		0.010		
		0.016		
$(1-L)s_{t-4}$		0.015		
		0.016		
$(1-L^4)s_{t-1}$			0.020	
			0.008	
$(1-L^4)s_{t-2}$			0.035	
			0.012	
$(1-L^4)s_{t-3}$			0.038	
			0.012	
$(1-L^4)s_{t-4}$			0.016	
			0.008	
$(1-L)(1-L^4)s_{t-1}$				0.011
				0.005
$(1-L)(1-L^4)s_{t-2}$				0.022
				0.009
$(1-L)(1-L^4)s_{t-3}$				0.029
				0.009
$(1-L)(1-L^4)s_{t-4}$				0.016
				0.005
$F$		3.268	3.130	3.123
P-valor		0.017	0.020	0.020
$R^2$	0.77	0.81	0.81	0.81

Tabela 03.06 – Estimativas dos Modelos PIB e Petróleo com não-linearidade

Variável dependente:					$(1-L)y_t$	$(1-L)y_t$
	$(1-L)y_t$	$(1-L^4)y_{t-1}$	$(1-L)(1-L^4)y_{t-1}$	Hamilton ( $h=4$ )	Hamilton ( $h=8$ )	
$\alpha$	0.004	0.005	0.001	0.001	0.000	
	0.002	0.002	0.002	0.002	0.003	
Var. Dependente $_{t-1}$	-0.012	1.081	0.193	0.922	0.886	
	0.091	0.116	0.102	0.105	0.115	
Var. Dependente $_{t-2}$	-0.232	-0.261	-0.117	0.110	0.230	
	0.091	0.165	0.102	0.119	0.140	
Var. Dependente $_{t-3}$	-0.006	-0.041	0.002	-0.732	-0.579	
	0.087	0.162	0.098	0.118	0.141	
Var. Dependente $_{t-4}$	0.622	-0.020	-0.421	0.463	0.324	
	0.088	0.111	0.096	0.100	0.109	
$s\#_{t-1}$	0.078	0.082	0.060	0.080	0.131	
	0.040	0.041	0.038	0.040	0.050	
$s\#_{t-2}$	-0.042	-0.034	-0.051	-0.036	-0.032	
	0.041	0.043	0.039	0.042	0.054	
$s\#_{t-3}$	-0.056	-0.039	-0.037	-0.068	-0.075	
	0.041	0.043	0.040	0.042	0.054	
$s\#_{t-4}$	-0.013	-0.004	-0.037	-0.013	0.004	
	0.039	0.042	0.039	0.041	0.053	
$\chi^2(4)$	6.564	4.696	6.882	6.992	7.726	
P-valor	0.161	0.320	0.1423	0.136	0.102	
$R^2$	0.73	0.76	0.35	0.71	0.79	

A questão da curta amostra trimestral – ou mesmo o fato de terem sido encontrados novos campos de petróleo com o advento do “Pré-Sal” - ser responsável pela positividade do efeito do aumento do preço do petróleo sobre o crescimento do PIB, fez-nos promover regressão com dados anuais. A Tabela 03.07 traz os resultados das regressões usando como covariadas a taxa de crescimento do PIB defasada (RPIB(-1)), retorno anual do WTI do começo do ano (RWTI\_BEG), retorno anual do WTI médio do ano (RWTI\_AVE) e retorno anual do WTI do fim do ano anterior (RWTI\_END(-1)), onde começo e fim referem-se a retornos calculados a partir dos preços de janeiro e dezembro, respectivamente. A média diz respeito ao retorno apurado pela média de preços mensais no ano<sup>54</sup>. Foram reportadas as especificações envolvendo retorno do WTI com P-valores inferiores a 10%. Os dados de crescimento do PIB foram extraídos do IpeaData<sup>55</sup> e do WTI são provenientes do FRED, e compreendem o período de 1946 a 2017. Independentemente do conceito de retorno do WTI, observa-se que o choque no

<sup>54</sup> Sobre a questão da periodicidade, Rossi (2013) relata, para o caso do câmbio, diferenças em resultados de previsão se usados dados médios em comparação com fim de período.

<sup>55</sup> Disponível em < <http://ipeadata.gov.br/Default.aspx>>.

preço do petróleo afeta positivamente a economia no período de um ano, em linha com os resultados encontrados com os dados trimestrais.

Tabela 03.07 – Taxas de Crescimento do PIB e Retorno WTI

<b>Crescimento anual do PIB</b>		
Variável	Estimativa	Estatística <i>t</i>
Constante	0.022	3.488
RPIB(-1)	0.503	4.926
$R^2$	0.260	
Constante	0.022	3.541
RPIB(-1)	0.476	4.668
RWTI_BEG	0.024	1.746
$R^2$	0.313	
Constante	0.022	3.526
RPIB(-1)	0.472	4.601
RWTI_AVE	0.029	1.673
$R^2$	0.289	
Constante	0.021	3.395
RPIB(-1)	0.517	5.083
RWTI_END(-1)	0.025	1.791
$R^2$	0.318	

## Conclusão

No presente capítulo, pode-se apontar os seguintes achados:

- conceito de retorno do PIB é relevante para medir sensibilidade a variações no preço do petróleo;
- medida relevante para explicar o PIB é retorno nominal do (log) preço do petróleo em relação ao trimestre anterior;
- por este conceito, efeito do petróleo é significativo para os quatro trimestres anteriores e sempre positivo no primeiro trimestre anterior, ao contrário do caso norte-americano em que os parâmetros referentes ao óleo eram negativos;

- evidência de não-linearidade é mais fraca do que a encontrada por Hamilton, existindo apenas para o primeiro trimestre anterior e também com sinal positivo.

Assim, não há dúvida de que variações passadas no preço do petróleo se mostram relevantes por anteceder variações no crescimento do PIB. Contudo, não foi observada forte não-linearidades como no caso norte-americano<sup>56</sup>.

---

<sup>56</sup> Mesmo no caso estadunidense, a evidência de não-linearidade é questionada, v.g., Killian e Vigfusson (2009). Hamilton (2011) criticou a medida usada pelos autores, baseada no logaritmo do preço máximo nos últimos anos. Por essa razão, utilizou-se a variável que captura a não-linearidade sugerida por este último autor.



## CONCLUSÃO

Estimar relações econômicas e fazer previsões certamente são importantes passos no dia a dia dos economistas. Para uma variável-chave como o câmbio, cuja previsibilidade era colocada em xeque, mostrar que se encontra, de alguma forma, ligada ao preço de *commodities* e, em especial, que não seja necessariamente a principal exportação do país, ilustra a importância de se entender as técnicas econométricas de previsão existentes, que muitas vezes parecem complexas, mas que podem ser implementadas por simples regressões lineares. Apesar da contemporaneidade das variáveis, dificultando oportunidades de arbitragem, pode-se estimar os efeitos e tomar-se decisões mais racionais. Na realidade, sugere-se que existem fatores interligando economias diversas, como visto no mercado específico de petróleo, em que os referenciais de diferentes continentes têm dinâmica semelhante e, de alguma forma, mantêm vínculo entre si.

Num exercício contrafactual, tivesse a formação de preços do diesel seguido o preço do mercado internacional, seu preço teria sido inferior ao observado nos meses finais do ano de 2018, mas a manutenção do valor e o aumento da oscilação possivelmente mais prejudicou do que auxiliou que reivindicou tal medida, recaindo em mais um caso de intervenção governamental com efeito contrário ao esperado. Ademais, conclui-se que, caso se espere alguma crise no mercado internacional de petróleo, isso afetará a economia, positiva ou negativamente. Ao fim dessas colocações, espera-se ter contribuído de forma efetiva para o estudo das previsões macroeconômicas.

## BIBLIOGRAFIA

- Alquist, R.; Kilian, L.; Vigfusson, R.J. Forecasting the Price of Oil. In: G. Elliott; Timmermann, A. **Handbook of Economic Forecasting**, Vol. 2, Elsevier, 2011.
- Andrews, D. Tests for Parameter Instability and Structural Change with Unknown Change Point. **Econometrica**, 71:821–56, 1993.
- Bai, J.; Ng, S. Determining the Number of Factors in Approximate Factor Models. **Econometrica**, 70:191–221, 2002.
- Bai, J.; Perron, P. Estimating and Testing Linear Models with Multiple Structural Changes. **Econometrica**, 66:47–78, 1998.
- \_\_\_\_\_. Computation and Analysis of Multiple Structural Change Models. **Journal of Applied Econometrics**, 18:1–22, 2003.
- Berkowitz, J.; Giorgianni, L. Long-horizon Exchange Rate Predictability?. **Review of Economics and Statistics**, 83, 81—91, 2011.
- Bernanke, B.S.; Gertler M.; Watson M. Systematic Monetary Policy and the Effects of Oil Price Shocks. **Brookings Papers on Economic Activity**, 1, 91-142, 1997.
- Bollerslev, T. Generalized Autoregressive Conditional Heteroskedasticity. **Journal of Econometrics**, 31:307–27, 1986.
- Box, G. E.; Jenkins, G. M. **Time series analysis; Forecasting and control**. San Francisco: Holden-Day, 1970.
- Capistrán, C. Bias in Federal Reserve Inflation Forecasts: Is the Federal Reserve Irrational or Just Cautious? **Journal of Monetary Economics**, 55:1415–27, 2008.
- Chen, Y.; Rogoff, K.S.; Rossi B. Can Exchange Rates Forecast Commodity Prices?. **Quarterly Journal of Economics**, 2010.
- Clark, T. E.; McCracken, M. W. Tests of Equal Forecast Accuracy and Encompassing for Nested Models. **Journal of Econometrics**, 105:85–110, 2001.
- \_\_\_\_\_. The Power of Tests of Predictive Ability in the Presence of Structural breaks. **Journal of Econometrics**, 124:1–31, 2005.

- \_\_\_\_\_. Tests of equal predictive ability with real-time data. **Journal of Business & Economic Statistics**, 27:441–54, 2009.
- Clark, T.; West, K. D. Using Out-of-sample Mean Squared Prediction Errors to Test the Martingale Difference Hypothesis. **Journal of Econometrics**, 135, 155-186, 2006.
- Clark, T. E.; West, K. D. Approximately Normal Tests for Equal Predictive Accuracy in Nested Models. **Journal of Econometrics**, 138:291–311, 2007.
- Dickey, D. A.; Fuller, W. A. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. **Journal of the American Statistical Association**, 74:427–31, 1979.
- Diebold, F.X.; Kilian, L. Measuring Predictability: Theory and Macroeconomic Applications. **Journal of Applied Econometrics**, 16: 657-669, 2001.
- Diebold, F. X.; Mariano, R.S. Comparing Predictive Accuracy. **Journal of Business and Economic Statistics**, 13: 253-63, 1995.
- Elliott, G.; Timmermann, A. Forecasting in Economics and Finance. **Annual Review of Economics**, 8: 81-110, 2016.
- \_\_\_\_\_. **Economic Forecasting**. Princeton: Princeton University Press, 2016.
- Elliott, G.; Komunjer, I.; Timmermann, A. Biases in Macroeconomic Forecasts: Irrationality or Asymmetric Loss? **Journal of the European Economic Association**, 6:122–57, 2008.
- Engle, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, 50:987–1007, 1982.
- Engle, R. F.; Granger, C. W. Co-integration and Error Correction: Representation, estimation, and testing. **Econometrica**, 5:251–76, 1987.
- Ferraro D.; Rogoff, K. S.; Rossi, B. Can Oil Prices Forecast Exchange Rates? **Journal of International Money and Finance**, 54: 116-141, 2015.
- Giacomini, R.; Komunjer, I. Evaluation and combination of conditional quantile forecasts. **Journal of Business and Economic Statistics**, 23: 416-431, 2005
- Giacomini, R.; Rossi, B. Detecting and Predicting Forecast Breakdowns. **Review of Economic Studies**, 76:669–705, 2009.
- \_\_\_\_\_. Forecast Comparisons in Unstable Environments, **Journal of Applied Econometrics**, 25(4), 595-620, 2010.

- Giacomini, R.; White, H. Tests of Conditional Predictive Ability. **Econometrica**, 74(6): 1545-1578, 2006.
- Granger, C. W. J. Investigating Causal Relations by Econometric Models and Cross-spectral Methods. **Econometrica**, 37:424–438, 1969.
- Granger, C. W. J.; Newbold. P. Some Comments on the Evaluation of Economic Forecasts. **Applied Economics**, 5:35–47, 1973.
- Granger, C. W. J.; Newbold. P. **Forecasting Economic Time Series**. Orlando: Academic Press, 1986.
- Hamilton, J. D. Oil and the Macroeconomy since World War II. **Journal of Political Economy**, 91 (21):228-247, 1983.
- \_\_\_\_\_. **Time Series Analysis**. Princeton: Princeton University Press, 1994.
- \_\_\_\_\_. This is What Happened to the Oil Price–Macroeconomy Relationship. **Journal of Monetary Economics**, 38:215–20, 1996.
- \_\_\_\_\_. What Is an Oil Shock?. **Journal of Econometrics**, 113, 363-398, 2003.
- \_\_\_\_\_. “Nonlinearities and the Macroeconomic Effects of Oil Prices,” **Macroeconomic Dynamics**, 15, no. S3: 364-378, 2011.
- \_\_\_\_\_. Why You Should Never Use the Hodrick-Prescott Filter. **Review of Economics and Statistics** 100: 831-843, 2018.
- Harvey, D.; Leybourne, S.; Newbold, P. Testing the Equality of Prediction Mean Squared Errors. **International Journal of Forecasting**, 13:281–91, 1997.
- \_\_\_\_\_. Tests for Forecast Encompassing. **Journal of Business & Economic Statistics**, 16:254–59.
- Inoue, A.; Kilian, L. In-sample or Out-of-sample Tests of Predictability: Which One Should We Use? **Econometric Reviews**, 23:371–402, 2005.
- Johansen, S.; Juselius, K. Maximum Likelihood Estimation and Inferences on Cointegration - with Applications to the Demand for Money. **Oxford Bulletin of Economics and Statistics**, 52: 169–210, 1990.
- Kwiatkowski, D.; Phillips, P. C. B.; Schmidt, Peter; Shin Y. Testing the Null Hypothesis of Stationary against the Alternative of a Unit Root. **Journal of Econometrics**, 54, 159-178, 1992.

- Kilian, L.; Taylor, M. P. Why Is It So Difficult to Beat the Random Walk Forecast of Exchange Rates? **Journal of International Economics**, 60:85–107, 2003.
- Marcellino, M. Forecast Bias and MSFE Encompassing. **Oxford Bulletin of Economics and Statistics** 62:533–42, 2000.
- MacKinnon, J. G. Critical Values for Cointegration Tests. *In* R. F. Engle e C. W. J. Granger (eds.), **Long-run Economic Relationships: Readings in Cointegration**. Oxford: Oxford University Press, 1991.
- \_\_\_\_\_. Numerical Distribution Functions for Unit Root and Cointegration Tests. **Journal of Applied Econometrics**, 11: 601-618, 1996.
- MacKinnon, J. G.; Haug, A. A.; Micheli, L. Numerical Distribution Functions of Likelihood Ratio Tests for Cointegration, **Journal of Applied Econometrics**, 14, 563-577, 1999.
- Meese, R.; Rogoff, K.S. Exchange Rate Models of the Seventies. Do They Fit Out of Sample?. **Journal of International Economics**, 14: 3-24, 1983.
- \_\_\_\_\_. Was It Real? The Exchange Rate-Interest Differential Relation Over the Modern Floating Rate Period. **Journal of Finance**, 43: 933-948, 1988.
- Newey, W. K.; West, K. D. A Simple, Positive Semi-Definite, Heteroskedasticity and Autocorrelation-Consistent Covariance Matrix. **Econometrica** 55 (3):703–8, 1987.
- \_\_\_\_\_. Automatic Lag Selection in Covariance Matrix Estimation. **Review of Economic Studies**, 61, 631-653, 1994.
- Patton, A. J.; Timmermann, A. Properties of Optimal Forecasts under Asymmetric Loss and Nonlinearity. **Journal of Econometrics** 140:884–918, 2007a.
- \_\_\_\_\_. Testing Forecast Optimality under Unknown Loss. **Journal of the American Statistical Association**, 102:1172–84, 2007b.
- Perron, P. The Great Crash, the Oil Price Shock, and the Unit Root Hypothesis. **Econometrica**, 57:1361–401, 1989.
- Pesaran, M. H.; Pettenuzzo, D.; Timmermann, A. Forecasting time series subject to multiple structural breaks. **Review of Economic Studies**, 73:1057–84, 2006.
- Pesaran, M. H. e Timmermann, A. Small Sample Properties of Forecasts from Autoregressive Models under Structural Breaks. **Journal of Econometrics**, 129 (1-2): 183-217, 2005.

- \_\_\_\_\_. Selection of Estimation Window in the Presence of Breaks. **Journal of Econometrics**, 137:134–61, 2007.
- Phillips, P.C.B.; Perron, P. Testing for a Unit Root in Time Series Regression. **Biometrika**: 75, 335–346, 1988.
- Rogoff, K. S. The Purchasing Parity Puzzle. **Journal of Economic Literature**, 34: 647-668, 1996.
- Rossi, B. Testing Long-Horizon Predictive Ability with High Persistence, and the Meese-Rogoff Puzzle. **International Economic Review**, 46(1): 61-92, 2005.
- \_\_\_\_\_. Are Exchange Rates Really Random Walks: Some Evidence Robust to Parameter Instability. **Macroeconomic Dynamics**, 10(1): 20-38, 2006.
- \_\_\_\_\_. Optimal Tests for Nested Model Selection with Underlying Parameter Instability. **Econometric Theory**, 21:962–90, 2005a.
- \_\_\_\_\_. Exchange Rate Predictability. **Journal of Economic Literature**, 51:1063–119, 2013.
- Rossi, B.; Inoue, A. Out-of-sample Forecast Tests Robust to the Choice of Window Size. **Journal of Business & Economic Statistics**, 30:432–53, 2012.
- Rossi, B.; Inoue A.; Jin, and L. Optimal Window Selection in the Presence of Possible Instabilities. **Journal of Econometrics**, 196(1): 55-67, 2017.
- Schwarz, G. Estimating the Dimension of a Model. **Annals of Statistics**, 6:461–4, 1978.
- West, K. D. Asymptotic Inference about Predictive Ability. **Econometrica** , 64:1067–84, 1996.
- \_\_\_\_\_. Tests for Forecasts Encompassing When Forecasts Depend on Estimated Regression Parameters. **Journal of Business & Economic Statistics**, 19:29–33, 2001.
- West, K. D.; McCracken, M. W. Regression-based Tests of Predictive Ability. **International Economic Review**, 39:817–840, 1998.
- White, H. **Estimation, Inference and Specification Analysis**. Cambridge University Press, 1996.
- \_\_\_\_\_. A Reality Check for Data Snooping. **Econometrica**, 68(5): 1097-1126, 2000.

Zivot, E.; Andrews, Donald W. K. Further Evidence on the Great Crash, the Oil-Price Shock, and the Unit-Root Hypothesis. **Journal of Business & Economic Statistics**, 10: 251–270, 1992.